

Département de Géomatique Appliquée
Faculté des Lettres et Sciences Humaines
Université de Sherbrooke

Utilisation de la télédétection pour l'analyse de la dynamique de la biomasse aérienne sèche totale des forêts et des palmiers à huile d'une plantation mature dans le Bassin du Congo

Pierre MIGOLET

Directeur de recherche : Kalifa GOÏTA

Thèse présentée pour l'obtention du grade de Philosophiae Doctor (PhD) en télédétection,
cheminement en physique de télédétection

Avril 2022

© Pierre MIGOLET, 2022

Identification du jury

Directeur de recherche : Professeur Kalifa Goïta, Université de Sherbrooke, Canada ;

Membre du jury interne : Professeur émérite Goze Bertin Bénié, Université de Sherbrooke, Canada ;

Membre du jury interne : Professeur Mickaël Germain, Université de Sherbrooke, Canada ;

Membre du jury externe: Professeur Cheikh Mbow, Future Africa, University of Pretoria, South-Africa ;

Présidente du jury: Professeure Thérèse Audet, Vice-doyenne à la recherche, Faculté des lettres et sciences humaines, Université de Sherbrooke, Canada.

III

- ✓ « Le succès vient de la curiosité, de la concentration, de la persévérance et de l'autocritique »

Albert Einstein (1879-1955)

- ✓ « L'art de la réussite consiste à savoir s'entourer des meilleurs »
- ✓ « La plus grande erreur que vous puissiez faire dans la vie c'est d'avoir peur de faire des erreurs ».

John Fitzgerald Kennedy (1917-1963)

- ✓ « Faites ce que vous aimez »

Manfred Steiner (1932 à nos jours)

- ✓ « Nous ne pouvons pas devenir ce que nous voulons être en restant ce que nous sommes »

Oprah-Winfrey (1954 à nos jours)

Résumé

Le stockage de la biomasse aérienne (BA) sèche totale des forêts est indispensable à la lutte contre les changements climatiques. Depuis quelques décennies, il y a une tendance à l'introduction de cultures agro-industrielles, comme les plantations de palmiers à huile, dans les forêts tropicales dans le Bassin du Congo. Ces conversions participent à l'augmentation ou à la diminution des émissions ou absorptions de dioxyde de carbone (CO_2) dans l'atmosphère, tout en occasionnant des changements climatiques. Dans cette région, la disponibilité des données de terrain et de télédétection est relativement limitée pour évaluer la BA. L'estimation de la BA des palmiers à huile n'est également pas maîtrisée dans le Bassin du Congo. Les incertitudes rapportées dans les études précédentes utilisant la télédétection demeurent encore élevées. Plusieurs approches à fort potentiel restent encore à développer ou à évaluer. À titre d'exemple, l'approche MARS (régressions multivariées par spline adaptative) pour estimer la BA n'a pas encore été testée, notamment avec des données combinées optiques, LiDAR et radar. Les pertes et les gains de la BA dus aux changements des forêts en palmiers à huile dans le Bassin du Congo, particulièrement au Gabon, n'ont pas encore été quantifiés. La présente étude vise alors à contribuer au développement des méthodes d'estimation de la BA par l'utilisation de la télédétection pour comprendre l'impact des plantations des palmiers à huile sur les variations de la BA des forêts.

Au cours de la présente étude, nous avons développé les premiers modèles allométriques d'estimation de la BA des palmiers à huile à l'aide de mesures *in situ* originales, que nous avons acquises dans le Bassin du Congo. Des modèles de BA des palmiers à huile ont également été établis avec MARS et les régressions linéaires multiples (RLM) en utilisant des indices dérivés de la transformée de Fourier (indices FOTO) à partir d'images satellitaires FORMOSAT-2 et PlanetScope. Finalement, cette thèse propose aussi des modèles MARS qui combinent des données de télédétection optiques (SPOT 7), LiDAR et radar polarimétrique interférométrique (PolInSAR) pour estimer la BA des forêts tropicales. À l'aide des estimations fournies par les modèles construits, la dynamique des BA des forêts et des plantations de palmiers à huile a été analysée.

Les résultats ont montré que le modèle allométrique local de BA, utilisant la variable composée formée par le diamètre à hauteur de poitrine, la hauteur et la densité, ou le nombre de feuilles, permettait d'avoir les meilleures estimations (erreur quadratique moyenne relative (%RMSE) = 5,1 %). Un modèle allométrique de BA relativement performant a également été construit en utilisant seulement le diamètre et la hauteur (%RMSE = 8,2 %). Pour l'estimation des BA des

palmiers à partir d'images FORMOSAT-2 et PlanetScope, les résultats démontrent que l'approche MARS permet les évaluations les plus précises ($\%RMSE \leq 9,5\%$). Cela est particulièrement vrai lorsque les images FORMOSAT-2 sont considérées ($\%RMSE \leq 6,4\%$). Les modèles de régression linéaire multiple donnent aussi des résultats avec des erreurs faibles, mais n'atteignent pas l'approche MARS ($\%RMSE \geq 6,6\%$). Cette dernière a été utilisée pour développer une série de modèles afin d'estimer les BA des forêts de la région d'étude. Les résultats montrent que le modèle utilisant la variable individuelle de la hauteur médiane de la canopée (RH50) dérivée des données LiDAR a estimé la biomasse avec plus de précision ($\%RMSE = 28\%$). La combinaison de données de télédétection (optique, LiDAR et radar) a réduit de près de 4 % les erreurs d'estimation de la biomasse du modèle exploitant la variable individuelle (RH50).

Les analyses de la dynamique de BA due aux remplacements des forêts en palmeraies ont enfin permis de constater que les forêts sont plus des vecteurs de gains de BA que les palmeraies particulièrement pour les forêts matures (512 t ha^{-1} de plus de BA que les palmeraies, soit un surplus de 88 %). Ce constat est identique pour les forêts secondaires vieilles (168 t ha^{-1} , soit 70 % de surplus de BA que les palmeraies) et les forêts secondaires jeunes-adultes ou inondables (74 t ha^{-1} de plus que les palmeraies, soit un excédent de 51 %). En revanche, l'installation de plantations de palmiers à huile dans les zones de sols nus ou forêts en repousse pourrait être gagnante en termes de BA, car celles-ci ne présentent que 72 t ha^{-1} de BA (100 % moins que les palmiers). C'est le cas aussi dans les zones occupées par les forêts secondaires jeunes-adultes avec des BA minimales et des sols nus ou des forêts en repousse avec des BA maximales de 52 t ha^{-1} (20 t ha^{-1} , soit 38 % de BA de moins que les palmeraies).

Mots-clés : Biomasse aérienne sèche totale, palmiers à huile des plantations agro-industrielles, forêts, Bassin du Congo, mesures *in situ*, télédétection, régression multivariée par spline adaptative, régression linéaire multiple, dynamique de la biomasse.

Table des matières

Résumé	IV
Liste des figures	X
Liste des tableaux	XIII
Liste des acronymes	XV
Liste des unités et des symboles	XX
Remerciements	XXI
Avant-propos	XXIII
CHAPITRE 1. Introduction générale.....	1
1.1 Rôles globaux de la forêt et de l'agriculture	1
1.2 Conséquences des changements des terres forestières et agricoles sur la biomasse	1
1.3 Importance du choix thématique de la conversion des forêts en palmeraies	3
1.4 Estimation de la biomasse.....	4
1.5 Problématique de l'étude.....	5
1.6 Objectifs	9
1.7 Hypothèses	10
1.8. Structure de la thèse.....	10
CHAPITRE 2. Cadre théorique.....	13
2.1 Estimation de la biomasse de la végétation à partir des mesures <i>in situ</i>	13
2.1.1 Méthode destructive	13
2.1.2 Équations allométriques de biomasse	16
2.2 Estimation de la biomasse des peuplements par télédétection	17
2.2.1 Estimation de la biomasse à partir des données optiques.....	17
2.2.1.1 Indices FOTO.....	19
2.2.1.2 Indices de texture de la matrice de co-occurrence de niveau de gris.....	21
2.2.2 Estimation de la biomasse à partir des données LiDAR.....	23
2.2.3 Estimation de la biomasse à partir des données PolInSAR	26
2.2.4 Estimation de la biomasse avec l'approche MARS	29
CHAPITRE 3. Sites et données de l'étude	33
3.1 Sites de l'étude	33
3.2 Données collectées	35
3.2.1 Données <i>in situ</i>	35
3.2.1.1 Données <i>in situ</i> des palmiers à huile abattus.....	35
3.2.1.2 Données <i>in situ</i> des palmiers à huile sur pied	35
3.2.1.3 Données <i>in situ</i> des arbres sur pied de la forêt.....	35
3.2.4 Données de télédétection	37
CHAPITRE 4. Méthodologie globale	40
4.1. Approche pour l'objectif 1	41
4.2. Approche pour l'objectif 2	42

4.3 Approche pour l'objectif 3	44
CHAPITRE 5. Estimation of Aboveground oil palm biomass in a mature plantation in the Congo Basin (Article 1)	45
 5.1 Présentation de l'Article	45
 5.2 Introduction	50
 5.3 Materials and Methods	52
 5.3.1 Study Area.....	52
 5.3.2 Data Collection.....	54
 5.3.2.1 Field Data Measurement.....	54
 5.3.2.2 Laboratory Measurements	55
 5.3.3 Establishment and Validation Allometric Models.....	56
 5.3.4 Comparisons with Existing Biomass Allometric Models	57
 5.4 Results	58
 5.4.1 Distribution of biomass proportions	58
 5.4.2 Relationships between variables	59
 5.4.3 Allometric Biomass models that were developed	61
 5.4.4 Validation of local allometric models	63
 5.4.5 Validation of existing allometric biomass models.....	66
 5.5 Discussion	69
 5.5.1 Interpretation of biomass distribution	69
 5.5.2 Evaluation of local allometric biomass equations.....	69
 5.5.3 Comparison of local models to existing allometric biomass models	70
 5.6 Conclusions	73
Author Contributions	73
Funding	74
Acknowledgments.....	74
Conflicts of Interest.....	74
Appendix 5.A	75
References	76
CHAPITRE 6. Evaluation of FORMOSAT-2 and PlanetScope imagery for aboveground oil palm biomass estimation in a mature plantation in the Congo Basin (Article 2)	81
 6.1 Présentation de l'article	81
 6.2 Introduction	86
 6.3 Materials and methods.....	88
 6.3.1 Description of the study area.....	88
 6.3.2 Data.....	89
 6.3.2.1 Satellite data.....	89
 6.3.2.2 In-situ measurements	90
 6.3.3 Use of the FOTO method and estimation of aboveground biomass	91

6.3.3.1 Textural index generation using the FOTO approach.....	92
6.3.3.2 Estimation of AGB by multiple regression	95
6.3.3.3 Estimation of AGB using MARS.....	96
6.3.3.4 Validation of the estimate	97
6.4 Results	97
 6.4.1 Textural indices using the FOTO approach	97
 6.4.2 Estimation of AGB by multiple regression	100
 6.4.3 Biomass estimation using MARS	102
 6.4.4 Validation of estimate.....	104
6.5 Discussion.....	105
 6.5.1 Potential of FOTO indices for oil palms.....	105
 6.5.2 Estimation of aboveground biomass	107
6.6 Conclusion.....	109
Author Contributions	110
Funding	110
Acknowledgments.....	110
Conflicts of Interest.....	110
Appendix 6.A	111
References	113
CHAPITRE 7. Estimation of the total dry aboveground biomass in the tropical forests of Congo Basin using optical, LiDAR, and radar data (Article 3).....	119
7.1 Présentation de l'article	119
7.2. Introduction	123
7.3. Materials and methods.....	126
 7.3.1. Study area.....	126
7.3.2 Data collection	126
 7.3.3 Methodology.....	129
 7.3.3.1 Production of texture indices.....	130
 7.3.3.2 Model development and validation.....	133
 7.3.3.2.1 Preliminary processing and analysis	133
 7.3.3.2.2 AGB models development and validation	134
7.4. Results	135
 7.4.1 Characterization of FOTO indices.....	135
 7.4.2 MARS-based AGB models.....	138
 7.4.2.1 Autocorrelation analysis of AGB sample plots	138
 7.4.2.2 Developed AGB models.....	141
 7.4.3. Biomass model validation	145
7.5. Discussion	147
7.6. Conclusion.....	152

Acknowledgements.....	152
References	153
Appendices 7	171
CHAPITRE 8. Analyse de la dynamique de la biomasse due au remplacement des forêts par les palmeraies.....	177
 8.1 Introduction	177
 8.2 Méthode.....	178
 8.3 Résultats et discussion.....	179
 8.3.1 Pertes de biomasses dues au remplacement des arbres de forêts par les palmiers	179
 8.3.2 Gains de biomasses dus au remplacement des forêts par les palmeraies...	182
 8.3.3 Cartographie des biomasses pour la conversion ou non des forêts en palmeraies	184
 8.4 Conclusion.....	186
CHAPITRE 9. Discussion générale	188
 9.1 Estimation de la biomasse <i>in situ</i>	188
 9.2 Estimation de la biomasse en utilisant la méthode FOTO	189
 9.3 Estimation de la biomasse par combinaison des données de télédétection	190
 9.4 Analyse de la dynamique de la biomasse due au remplacement des forêts par les palmeraies	194
CHAPITRE 10. Conclusion et perspectives.....	197
 10.1 Conclusion.....	197
 10.2 Contributions originales	198
 10.3 Perspectives.....	198
Références (hors articles).....	200
Annexe (hors articles)	210

Liste des figures

Figure 1.1. Changement dans le stock de carbone de la biomasse de la forêt selon les régions entre 1990-2020.....	3
Figure 1.2. Localisation de quelques projets de plantations des palmiers à huile et d'hévéa dans le Bassin du Congo (couleur rouge).....	6
Figure 1.3. Photographie de la localisation spatiale des données d'inventaires forestiers des placettes scientifiques et des concessions forestières d'Afrique centrale utilisées par Ploton et <i>al.</i> , (2020) pour estimer la biomasse du Bassin du Congo.....	7
Figure 2.1. Compartiments des feuilles et du tronc d'un palmier à huile (a et b) et d'un arbre de forêt.....	14
Figure 2.2. Organisation d'un chantier de biomasse avec 7 postes.....	14
Figure 2.3. Réflectances des constituants d'une feuille verte	18
Figure 2.4. Schéma des étapes de mise en œuvre de la méthode FOTO avec une taille de fenêtre sur une image satellitaire.....	21
Figure 2.5. Sous-produits d'un nuage de points LiDAR aérien à retour discret en zone forestière : cas du modèle numérique de terrain (MNT), du modèle numérique de surface (MNS) et du modèle numérique de hauteur (MNH).	23
Figure 2.6. Extraction des variables obtenues à partir d'un nuage de points LiDAR selon trois échelles : arbre (a), placette (b) ou production de données raster (c).....	24
Figure 2.7. Illustration d'un modèle linéaire ordinaire des observés de terrain (a) et du modèle non linéaire issus de MARS à l'aide des données identiques (b).....	31
Figure 2.8. Schéma de fonctionnement de MARS	31
Figure 3.1. Zone d'étude des palmiers à huile	34
Figure 3.2. Zone d'étude des forêts.....	34
Figure 4.1. Organigramme méthodologique de la thèse	40
Figure 5.1 Study area.....	53
Figure 5.2. Mean proportions of the aboveground biomass for the 18 oil palms, Makouké, central Gabon.	59
Figure 5.3. Allometric relationships between the variables and the DBH of the 11 oil palms used in this study to develop local biomass models: (a) relationship between total height vs. DBH; (b) relationship between stem height vs. DBH; (c) relationship between infra-density vs. DBH; and (d) relationship between number of leaves vs. DBH.	60
Figure 5.4. Allometric relationships between the biomass components of 11 oil palms and their corresponding DBH.	63

Figure 5.5. Comparison of the selected existing allometric models with the best allometric models that were proposed in this study: (a) biomass variation according to DBH; (b) relative error variation according to DBH.....	67
Figure 5.6. Errors in the allometric models when considering the two DBH classes (48–52 cm, 52–58 cm).....	72
Figure 6.1 Study site location.....	89
Figure 6.2. Plot sampling scheme.	89
Figure 6.3. Organizational flowchart for the study.	91
Figure 6.4. Nyquist and spatial frequencies as a function of mean r-spectra for window sizes ranging from 24 to 38 pixels for PlanetScope (top row) and 38 to 60 pixels for FORMOSAT-2 (bottom row).....	94
Figure 6.5. Spatial frequencies as a function of mean r-spectra from Fourier transformations in textural ordination (FOTO) analysis of the near infrared spectral bands of PlanetScope and FORMOSAT-2 (a); variance proportions explained by the 3 principal components (PCs) (b); ordination of plot scores on PCs 1 and 2 for FORMOSAT-2 (c) and PlanetScope (d).	98
Figure 6.6. FOTO maps of oil palm canopy texture derived from actual RGB values of the FOTO indices of FORMOSAT-2 (a) and PlanetScope (b).....	100
Figure 6.7. Relationships between oil palm structural parameters obtained from the field plots and PC1 derived from PlanetScope and FORMOSAT-2 images.	101
Figure 6.8. Multispectral satellite image of the study area (a) and aboveground oil palm biomass map derived with MARS (Model 3) from FORMOSAT-2 FOTO indices (b).....	105
Figure 7.1. Figure 1. Location of the study area in Gabon (Central Africa). The sample plots are indicated by symbols in magenta over the SPOT-7 true color composite image.....	126
Figure 7.2. Methodological flowchart of the study	130
Figure 7.3. Relationship between the r-spectra of the 2D Fourier transform with the wave numbers by (a) window size, (b) spatial frequencies, and (c) proportions of variance explained from the principal component analysis of the r-spectra.	
Figure 7.4. Distribution of texture types in the study area according to PC1 and PC2 scores of the r-spectra for the different window sizes: (a) 75 m, (b) 100 m, (c) 125 m, (d) 150 m, and (e) 175 m.....	137
Figure 7.5. Textural variation over the study area.	138
Figure 7.6. Spatial distribution of clusters based on Anselin local Moran I for the 75 AGB sample plots in the study	140
Figure 7.7. Spatial distribution of clusters based on Anselin local Moran I for the original AGB sample plots of AfriSAR field campaign	140

Figure 7.8. (a) Map of total dry aboveground forest biomass (b) SPOT-7 pan-sharpened color-composite of the study area.....	147
Figure 8.1. Valeurs des biomasses aériennes sèches totales des sites d'étude des forêts du Cap Estérias et des palmiers à huile de la plantation agro-industrielle mature à Makouké au Gabon dans le Bassin du Congo	181
Figure 8.2. Gains ou pertes des biomasses aériennes sèches totales maximales (a), minimales (b) et moyennes (c) dus à la conversion des types d'occupation de terre du site d'étude de la forêt en plantation de palmiers à huile au Gabon dans le Bassin du Congo	181
Figure 8.2 (suite). Gains ou pertes des biomasses aériennes sèches totales maximales (a), minimales (b) et moyennes (c) dus à la conversion des types d'occupation de terre du site d'étude de la forêt en plantation de palmiers à huile au Gabon dans le Bassin du Congo....	182
Figure 8.3. Carte de biomasse aérienne sèche totale d'aide à l'identification des sites de conversions ou de non-conversions des forêts en palmeraies.	185

Liste des tableaux

Tableau 2.1. Description des indices de texture GLCM usuellement utilisés pour estimer la biomasse des végétaux chlorophylliens.....	22
Tableau 3.1. Caractéristiques des données <i>in situ</i> de la thèse.....	36
Tableau 3.2. Caractéristiques des données de télédétection de la thèse.....	39
Table 5.1. Summary of the field measurements for 18 felled oil palms: DBH, H _T , H _{TOT} and N _F are respectively the diameter at breast height (cm, measured 1.3 m above the ground surface), the stem height (m), the total height (m) and the leaf number per tree.....	54
Table 5.2. Summary of the infra-density, dry mass fractions and the average total dry mass of the palm components for 18 individuals that were felled in Makouké, central Gabon.....	55
Table 5.3. Existing biomass models that were considered.....	58
Table 5.4. Criteria for evaluating the allometric relationships between the DBH and the dependent variables using data from 11 oil palms in Makouké, central Gabon.....	60
Table 5.5. Local allometric biomass models that were developed in this study.....	62
Table 5.6. Validation of the allometric relationships between the individual explanatory variables (ρ , H _{TOT} , H _T and N _F) and the DBH (for estimates of a and b, see Table 5.4).....	63
Table 5.7. Validation of the local allometric models of oil palm biomass; estimates for a and b are available in Table 5.5	65
Table 5.8. Comparison of the existing allometric biomass models to the corresponding local models that were developed in this study.....	68
Table 6.1. Descriptive statistics for measurements taken from 510 oil palms distributed across 40 sample plots.....	90
Table 6.2. Correlations between FOTO FORMOSAT-2 and PlanetScope indices versus structural parameters of oil palm.....	101
Table 6.3. Multiple linear regression models developed for estimating aboveground oil palm biomass using indices estimated by textural ordinations on Fourier transforms (FOTO), which were produced from PlanetScope and FORMOSAT-2 images.....	102
Table 6.4. Aboveground biomass models estimated using multivariate adaptive spline regressions (MARS).....	103
Table 6.5. Validation of aboveground biomass models.....	104
Table 7.1. Descriptive statistics for forest parameters in the 75 sample plots (30.8 m × 30.8 m, or 0.1 ha)	128
Table 7.2. GLCM texture indices that were used in the study.....	132
Table 7.3. Characteristics of the existing AGB maps considered ..	Erreur ! Signet non défini.

Table 7.4. Statistics of spatial autocorrelation in the 75 AGB sample plots of the study using Anselin local Moran I and global Moran I.....	139
Table 7.5. Statistics of spatial autocorrelation in the 48 original AGB sample plots of NASA AfriSAR field campaign using Anselin local Moran I and global Moran I.....	139
Table 7.6. Correlations between total dry aboveground biomass and its explanatory variables of the 45 training sample plots of the study.	142
Table 7.7. Models developed based on MARS approach.....	143
Table 7.8. Best developed aboveground biomass (AGB) models that were based upon the MARS approach.....	144
Table 7.9. Validation of developed AGB models	146
Table 7.10. Evaluation of AGB errors from existing maps using AGB from 0.1 ha sample plots.	Erreur ! Signet non défini.

Liste des acronymes

AAF	Attribut de l'arbre de la forêt
ACP	Analyse en composante principale
AGB	Total dry aboveground biomass
AGEOS	Agence Gabonaise d'Études et d'Observation Spatiale
AIC	Critère d'information d'Akaike
AIC	Akaike information criterion
ANPN	Agence Nationale des Parcs Nationaux
APH	Attribut du palmier à huile
ARW	Arboretum Raponda Walker
BA	Biomasse aérienne sèche totale
BA	Basal area
BA _F	Biomasse aérienne fraîche totale
B _{aliquote bois sec, i}	Biomasse sèche de l'aliquote de bois du billon <i>i</i> du tronc d'un arbre
B _{aliquote compartiment arbre frais, i}	Biomasse fraîche de l'aliquote <i>i</i> du compartiment d'un arbre
B _{aliquote compartiment arbre sec, i}	Biomasse sèche de l'aliquote <i>i</i> du compartiment d'un arbre
B _{EF}	Biomasse d'un échantillon frais d'un compartiment d'un palmier à huile
B _{ES}	Biomasse d'un échantillon séché d'un compartiment d'un palmier à huile
B _{FT}	Biomasse fraîche totale d'un compartiment d'un palmier à huile
B _{FP}	Biomasse fraîche d'une portion d'un compartiment d'un palmier à huile (tige, folioles, pétioles, rachis et fruits)
B _p	Biomasse sèche d'une portion d'un compartiment d'un palmier à huile
B _{portion compartiment arbre frais, i}	Biomasse fraîche d'une portion d'un compartiment <i>i</i> d'un arbre
B _{portion compartiment arbre sec, i}	Biomasse sèche d'une portion d'un compartiment <i>i</i> d'un arbre
B _{sèche totale un compartiment arbre, i}	Biomasse sèche totale d'un compartiment <i>i</i> d'un arbre

B _C	Biomasse sèche totale de chaque compartiment d'un palmier à huile (tige, folioles, pétioles, rachis et fruits)
BD	Bandé Dessinée
<i>B_{FSR}</i>	Leaf biomass without rachis
BS	Bandé spectrale
<i>B_{Rachis}</i>	Rachis biomass (kg)
<i>B_{Stem}</i>	Stem biomass
CF	Correction factor
CCT	Centre Canadien de télédétection
CO ₂	Dioxyde de carbone
COP	Conférence des Parties
CP	Composante principale
2D	Deux dimensions ou Two-dimensional
D	Densité des palmiers à huile en tige par hectare ou Density of palm trees per hectare
D	Diameter at breast height (measured 1.3 m above ground surface)
DHP	Diamètre à hauteur de poitrine (mesuré à 1,3 m au-dessus du sol)
DBH	Diameter at breast height (measured 1.3 m above ground surface)
DCHM	Digital canopy height models
DSIRFN	Projet de développement d'un système d'inventaire des ressources Forestières Nationales contribuant à la gestion durable des forêts
DMF	Dry mass fraction
DSM	Digital surface model
DT	Données de télédétection
DTM	Digital terrain model
E	Est ou East
ER	Erreur relative
%ER	Erreur relative en pourcentage
ESA	European Space Agency ou Agence Européenne Spatiale
EWCM	Extended water cloud model
FAO	Food and Agriculture Organization
FFT-2D	Transformée de Fourier rapide discrète deux dimensions ou <i>Two-dimensional discrete fast-Fourier transformation</i>

fms	Fraction de masse sèche
FOTO	Transformée de Fourier basée sur l'ordination texture ou scores de l'analyse en composante principale (ACP) des spectres radiaux de la transformée de Fourier discrète rapide (FFT) deux dimensions (2D) ou textural ordination based upon Fourier transforms
GCV	Generalized Cross-Validation Criterion
GEDI	Système LiDAR spatial sur l'enquête de la dynamique des écosystèmes mondiaux
GHG	Greenhouse gas
GLAS	Geoscience Laser Altimeter System ou système géo-scientifique d'altimètre laser
GLCM	Matrice de co-occurrence de niveau de gris
GIEC	Groupe d'experts intergouvernemental sur l'évolution du climat
H_M	Hauteur maximale modélisée de l'arbre
H_R	Hauteur moyenne des arbres ou de la canopée ou Height of the canopy
H_T	Modeled maximum height of the tree ou Hauteur maximale modélisée de l'arbre
H_T	Hauteur de la tige ou Stem height
H_{Tcm}	Stem height of a palm
H_{TOT}	Hauteur totale ou Total height
HV	Polarisation Horizontale-Verticale ou Horizontal-Vertical Polarization
ICESat	Satellite d'élévation des glaces, des nuages et des terres ou Ice, Cloud and Land Elevation Satellite
ICRAF	International Centre for Research in Agroforestry
ICRAF	Centre international pour la recherche en agroforesterie
IPCC	Intergovernmental Panel on Climate Change
InSAR	Radar à synthèse d'ouverture (SAR) interférométriques ou synthetic aperture radar interferometric
IR	Infrarouge
ISS	Station spatiale internationale
L	Longueur du billon
LiDAR	Light Detection And Ranging

XVIII

LVIS	Land, Vegetation, and Ice Sensor
MARS	Régression multivariée par spline adaptative ou Multivariate adaptive regression splines
MARS-DE	Multivariate Adaptive Regression Spline Differential Evolution
ML	Machine learning
MLR	Multiple linear regressions
MNC	Modèle numérique de canopée
MNH	Modèle numérique de hauteur
MNHC	Modèle numérique de hauteur de la canopée
MNS	Modèle numérique de surface
MNT	Modèle numérique de terrain
n	Number of palms that were sampled
N	Nord ou North
N	Number of pixels in the X or Y direction
Na	Nombre total d'arbres ou Number of trees
NASA	United States National Aeronautics and Space Administration
NSERC	Natural Sciences and Engineering Research Council of Canada
NDVI	Normalized Difference Vegetation Index
N _F	Nombre de feuilles ou total number of leaves
NIR	Near infrared
N _P	Nombre total de palmiers à huile ou total number of oil palms
OPG	Olam Palm Gabon
P ou <i>p</i>	<i>p</i> -value of the model.
PCA	Principal Component Analysis.
PC	Principal component
PIB	Produit Intérieur Brut
PIR	Proche infrarouge
PollnSAR	Radar à synthèse d'ouverture (SAR) interférométriques polarimétriques ou Polarimetric synthetic aperture radar interferometric
PolSAR	Radar à synthèse d'ouverture polarimétrique ou polarimetric synthetic-aperture radar
PSPH	Paramètre structural du palmier à huile
R ²	Coefficient de détermination ou Coefficient of determination
r ²	Coefficient of determination

radar	Radio detection and ranging
RE	Relative error
REDD	Reducing emissions from deforestation and forest degradation
RH50	Hauteur médiane dérivée des données LiDAR ou median height derived from LiDAR data
RGB	Red-Green-Blue
RLM	Régressions linéaires multiples
RMSE	Erreur quadratique moyenne ou root-mean-square error
%RMSE	Pourcentage de RMSE ou percentage of RMSE
RSD	Remote sensing data
RSPO	Roundtable on Sustainable Palm Oil
RVB	Rouge-vert-bleu
RvoG	Random volume over ground
RvoG + VTD	Random Volume over Ground with Volume Temporal Decorrelation model
S	Sud ou South
SAR	Radar à synthèse d'ouverture
SCT	Société Canadienne de Télédétection
SE	Standard error for each parameter
%SE	Percentage of SE
SAR	Radar à synthèse ouverture ou Synthetic Aperture Radar
S-RvoG	Sloped random volume over Ground
ST	Surface terrière
UAVSAR	Uninhabited Aerial Vehicle Synthetic Aperture Radar
UV	Ultraviolet
V	Volume
V _{aligote frais}	Volume saturé d'un aliquote frais d'un billon de bois
V _{frais}	Volume du billon de bois frais
WCM	Water cloud model
WS	Square window

Liste des unités et des symboles

%	Pourcentage
° ' "	Degré (°) minute (') seconde (")
σ	Erreur type résiduelle (Residual standard error)
ρ	Wood density
ρ	Wood infradensity
σ^0	Coefficient de rétrodiffusion
σ^0	Backscatter coefficient
ΔS	Pixel size in meters
C	Carbon
°C	Degré Celsius
cycles km ⁻¹	Cycle par kilomètre
cm	Centimètre
dB	Décibel
E	Est
g cm ⁻³	Gramme par centimètre cube
Gt	Gigatonne
ha	Hectare
kg	Kilogramme
km ²	Kilomètre carré
m	Mètre
m ² ha ⁻¹	Mètre carré par hectare
Mha	Millions d'hectares
Mha year ⁻¹	Millions d'hectares par année
Mg C ha ⁻¹	Mégagramme de carbone par hectare
mm	Millimètre
N	Nord
nm	Nanomètre
S	Sud
Stem ha ⁻¹	Tige par hectare
t	Tonne
tCO ₂ .y ⁻¹	Tonne de dioxyde de carbone par année
t ha ⁻¹	Tonne par hectare

Remerciements

Mes premiers remerciements s'adressent exclusivement à mon Directeur de recherche, Prof. Kalifa Goïta qui a bien voulu encadrer mes travaux de recherche doctorale à l'Université de Sherbrooke. Ses conseils et ses suggestions éclairés, intarissables et inlassables ont été un soutien motivateur, formidable et exceptionnel pour mener à terme la présente thèse. Ses connaissances, sa forte expérience professionnelle et ses valeurs humaines m'ont grandement encouragé à aller de l'avant pour bonifier la qualité de mon travail tout au long de la thèse.

Je remercie aussi profondément le Programme Canadien de Bourses de la Francophonie (PCBF) et le Conseil de Recherches en Sciences Naturelles et en Génie du Canada (CRSNG) pour leurs contributions financières au cours de mes travaux de recherche doctorale.

Mes remerciements sont également adressés aux différents membres du Jury pour leurs évaluations de ma thèse et apports supplémentaires significatifs à la bonification de ma thèse.

J'adresse ma gratitude aux personnes mentionnées ci-après qui ont concouru à la matérialisation de mes campagnes de mesures de terrain au Gabon. Il s'agit principalement de Andréana Paola Mekui Biyogo épouse De Wachter, Quentin Benjamin Meunier, Prof Alfred Ngomanda, Dr Aurélie Flore Kouumba Pambo, Simplice Nteme et Dr Aboubakar Ndjourougui Mambimba.

Des discussions enrichissantes, uniques et encourageantes ont été menées avec diverses personnalités notamment Prof Cheikh Mbow, Prof Goze Bertin Bénié et Prof Richard Fournier, Dr Lise Caron, Prof Guy Hector Adégbidi et Prof Lacina Coulibaly. Je leur témoigne ma reconnaissance.

Ma reconnaissance inoubliable est aussi formulée au corps professoral et au personnel de l'Université de Sherbrooke pour la haute qualité de leurs services professionnels et de leurs appuis ou orientations tout au long de mon cheminement académique.

Au laboratoire du département de géomatique de l'Université de Sherbrooke, j'ai rencontré au cours de mes études doctorales des condisciples de cultures et de nationalités variées, motivants et disponibles. Je leur témoigne ici ma gratitude renouvelée. Je pense particulièrement à Jawad Ziyad et Guy Armel Fotso Kamga pour leurs précieuses écoutes et leurs partages empathiques.

Des amis formidables ont régulièrement illuminé ma vie au Canada. Je les remercie pour tous les merveilleux moments passés ensemble. Ils ont été un berceau de partage, de réconfort et d'encouragements durant mes études doctorales. Il s'agit principalement d'Alexandre Lambert, Demba Tall, Edwige Nfoume Ella, Jean Claude Mabiala, Kien Trân, Mélanie Ross, Marc Tehi, Stecy Nathan Iyangui Alandji et Vicky Morin et son époux Jocelyn Francoeur.

Pour toutes les marques d'attention, d'affection et de motivations inconditionnelles durant mes études doctorales, je remercie ma famille particulièrement mes géniteurs, Samuel et Joséphine ainsi que mes sœurs et frères : Yolande, Dorian Samuel, Olga, Francis, Ginette et Judicaël Anaclet. Je témoigne ma haute reconnaissance à mes trois enfants : Issay Sarah Pierrice, Junior Ange Daniel et Esther Zoé. Ils ont toujours été par la pensée une source de motivation, de persévérance et de résilience abondante au cours de mes études doctorales.

Avant de clore la présente section, je témoigne chaleureusement ma gratitude à Danielle Géneviève pour nos divers partages d'épanouissements communs et pour avoir été longtemps à mes côtés au cours de mes études doctorales pendant les moments de joie et de vicissitude de la vie. J'adresse enfin mes remerciements chaleureux à la famille et aux connaissances (collègues, ami(e)s, etc.) de Danielle Géneviève pour les beaux moments passés ensemble durant mes études.

Avant-propos

Au cours des travaux de recherche doctorale de la présente thèse, deux articles ont été publiés dans les revues scientifiques *Forest* et *Remote Sensing*. Un troisième article a été soumis à la revue *GIScience & Remote Sensing*. Les commentaires formulés par les évaluateurs ont été pris en compte et le manuscrit a été resoumis au processus de révision. Cette thèse est ainsi présentée sous la forme d'articles publiés et soumis dans des journaux. Chacun de ces trois articles constituent un chapitre de la thèse.

CHAPITRE 1. Introduction générale

1.1 Rôles globaux de la forêt et de l'agriculture

Les forêts sont estimées à 31 % de la surface terrestre (*Food and Agriculture Organization* (FAO, 2021). Elles jouent un rôle mondialement connu de lutte contre les changements climatiques (IPCC, 2000) à travers le stockage de carbone (par la biomasse vivante de tous les biomes terrestres) et la séquestration de près de 30 % des émissions globales de dioxyde de carbone (CO₂) (FAO, 2016 ; Neumann *et al.*, 2016). Elles assurent aussi un rôle de fournisseur de services à l'humain dans plusieurs domaines, notamment la santé (pour ses plantes médicinales), l'habitat (pour son bois), l'alimentation, la culture, etc. (FAO, 2016). Par ailleurs, l'agriculture contribue à la production de la nourriture par le développement des plantations agro-industrielles et paysannes de subsistance (Laurance Sayer et Cassman, 2014). Cette nourriture alimente une population mondiale qui est estimée à 7,8 milliards de personnes en 2020 (*Department of Economic and Social Affairs-United Nations*, 2021). L'agriculture participe également, en moyenne, à près de 50 % du produit intérieur brut (PIB) des économies de la plupart des pays d'Afrique (Mrema *et al.*, 2008). La mise en œuvre des activités forestières et agricoles influence à la fois l'équilibre du climat et le développement durable des pays en voie de développement, plus particulièrement (FAO, 2016). En l'absence d'une définition forestière nationale au Gabon, dans cette étude, tout comme pour l'étude de Fichet *et al.*, (2014), la forêt est définie comme des terres de superficies minimales de 1 ha avec une couverture du territoire minimale de 30 % et des hauteurs d'arbres minimales de 5 m. Cette définition est basée sur les recommandations de l'Accord de Marrakech de la Conférence des Parties (COP) 7, qui fournit une gamme de valeurs à partir de laquelle les pays peuvent choisir leurs définitions de la forêt (Fichet *et al.*, 2014). Elle pourrait toutefois influencer la stratification de la zone d'étude.

1.2 Conséquences des changements des terres forestières et agricoles sur la biomasse

Malgré les fonctions vitales et les nombreux services rendus à l'espèce humaine, les forêts sont de plus en plus détruites, dégradées ou modifiées (Ozesmi et Bauer, 2002) pour acquérir des biens conduisant à la satisfaction des besoins socio-économiques. Parmi ces biens, on note entre autres la nourriture, les fibres, l'eau et l'habitat pour plus de sept milliards de personnes (Shooshtari et Gholamalifard, 2015). Ces changements mettent les forêts, à l'exemple de celles du Bassin du Congo, sous une forte pression surtout par l'intensification du développement des

plantations agro-industrielles (pour les biocarburants ou la consommation humaine à grande échelle), de l'extraction minière et du développement urbain (Megevand *et al.*, 2013).

Les changements mondiaux observés au niveau des terres forestières et agricoles sont clairement perceptibles depuis plus de trente ans dans la quantité mondiale de carbone stocké dans la biomasse de la forêt. En 2020, le stock de carbone de cette biomasse a ainsi principalement diminué en raison d'une conversion des terres à d'autres affectations et de la dégradation des forêts. Entre 1990 et 2020, cette diminution a été évaluée approximativement à 6,0 Gt sur un stock total initial de 662 Gt de carbone de la biomasse de forêt. En 2020, le stock de carbone de la biomasse vivante (aérienne et souterraine) a constitué le deuxième réservoir de carbone (295 Gt soit 44,5 %) après celui du carbone de la matière organique du sol (300 Gt soit 45,3 %). Ces deux réservoirs de carbone ont aussi été largement supérieurs au carbone dans le bois mort et la litière (68 Gt soit 10,2 %) (FAO, 2021). Il est également démontré que les forêts de l'Amérique du Sud, de l'Afrique de l'Ouest et Centrale piégent les plus fortes densités de carbone avec près de 120 t de carbone à l'hectare uniquement dans la biomasse vivante, contre une moyenne mondiale de stockage évaluée à 75 t de carbone à l'hectare (FAO, 2016). Malgré cette forte capacité de stockage, la quantité de carbone dans la biomasse forestière a considérablement baissé entre 1990 et 2020 en Amérique du Sud, en Afrique de l'Ouest et Centrale. Celle-ci a en revanche augmenté en Asie de l'Est, Centrale et occidentale, en Europe et en Amérique du Nord (FAO, 2021). La Figure 1.1 illustre ces différentes tendances de modification du stock de carbone dans la biomasse pour ces territoires. Au cours de la présente étude, la biomasse aérienne sèche totale de l'arbre sera évaluée. Celle-ci correspond à la quantité totale de matière organique aérienne présente dans les arbres (tige, branches, feuilles, souches et écorces). La BA est définie comme le stock total de matière organique sèche de bois estimé dans des conditions constantes (à savoir, le séchage des échantillons de bois au four jusqu'à ce qu'un poids constant soit atteint) (Neumann *et al.*, 2016). Cette BA est un réservoir important de stockage de carbone de la végétation et constitue aussi la partie la plus vulnérable aux activités anthropiques et aux catastrophes naturelles.

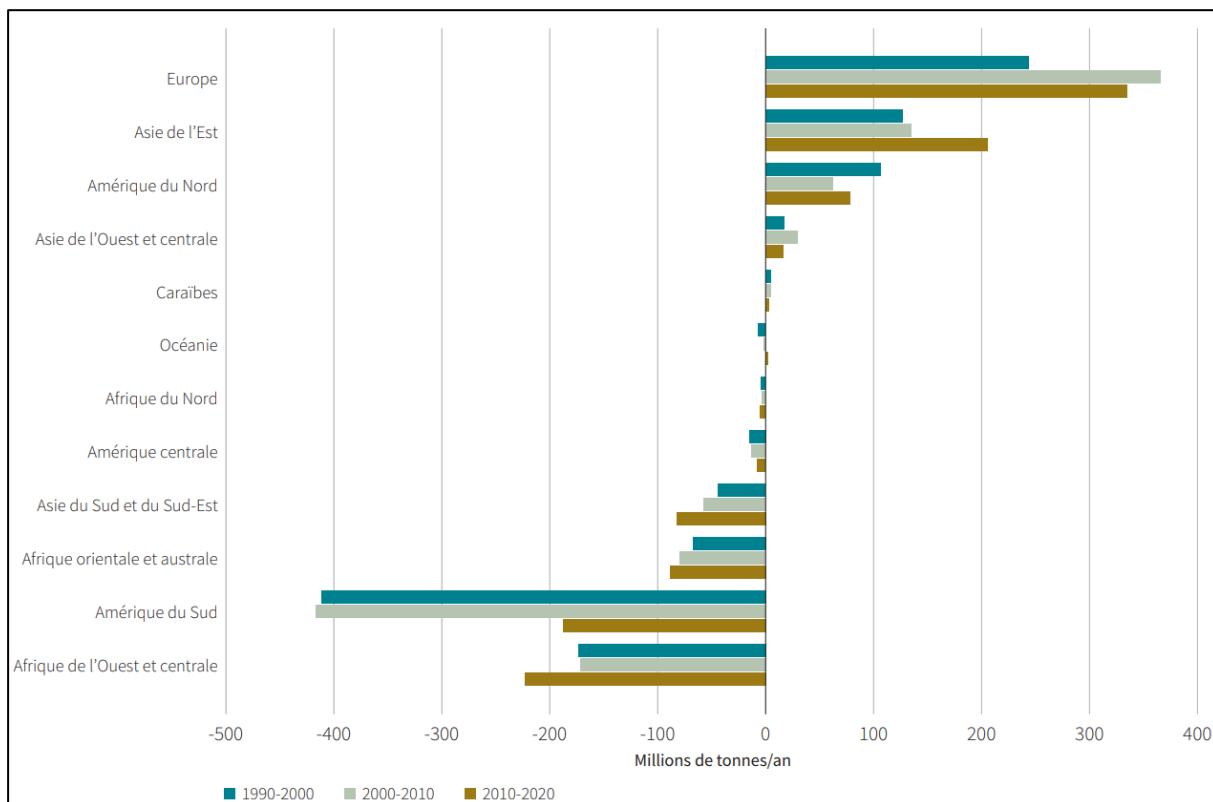


Figure 1.1. Changement dans le stock de carbone de la biomasse de la forêt selon les régions entre 1990-2020 (Tiré de FAO, 2021, p. 57)

Le programme REDD (*Reducing emissions from deforestation and forest degradation*) a été mis en place depuis 2008 pour faire face aux conséquences multiples des changements de la quantité de carbone séquestré dans la biomasse des arbres. L’Organisation des Nations Unies coordonne ce programme. Celui-ci vise à lutter contre le réchauffement climatique. Au fil du temps, ledit programme a été mué en REDD+ pour développer des approches de politiques et des systèmes d’évaluation de réduction des émissions liées à la dégradation et à la déforestation. Il contribue également à aider à la conservation, à l’accroissement des stocks existants de carbone forestier et à la gestion durable des forêts (Lund *et al.*, 2017).

1.3 Importance du choix thématique de la conversion des forêts en palmeraies

Au regard de ce qui précède, l’un des défis importants des pays détenteurs des forêts, à l’exemple de ceux du Bassin du Congo, est d’exploiter et de développer leur domaine agricole en perturbant faiblement l’équilibre écologique de la forêt. La prise en compte de ce défi et sa mise en œuvre permettraient éventuellement d’accentuer la tendance de ralentissement de la déforestation constatée par la FAO (2016). Pour relever ce défi, il est indispensable de réaliser des études pour connaître les quantités et les changements des biomasses forestières et agricoles sur de grandes superficies. Dans la présente étude, les forêts et les palmiers à huile des

plantations agro-industrielles ont été considérés. Ces deux peuplements ont été choisis parce qu'il existe, de manière répétitive, de nos jours dans les pays détenteurs des forêts tropicales, un remplacement des zones forestières par les plantations. Ce remplacement provoque des modifications temporelles de la BA des forêts (Morel *et al.*, 2012 ; Kho et Rudbeck-Jepsen, 2015).

1.4 Estimation de la biomasse

La BA des forêts et des palmeraies est régulièrement estimée dans le monde à l'aide des données de terrain et de télédétection. Au niveau de l'arbre ou du palmier, les BA de terrain sont obtenues par abattage, mesurage, séchage et calcul des biomasses des composantes (tiges et feuilles) des végétaux chlorophylliens (Khalid *et al.*, 1999 ; Ngomanda *et al.*, 2014 ; Aholoukpè *et al.*, 2018 ; Fayolle *et al.*, 2018). Sur de petites superficies, les BA sont évaluées à partir des données de terrain des paramètres structuraux des végétaux chlorophylliens (ex. hauteurs, diamètres, nombre de feuilles, longueur des feuilles, etc.) (Kotowska *et al.*, 2015 ; Da Silva *et al.*, 2015 ; Yuen *et al.*, 2016). Selon plusieurs études, l'approche d'estimation de la BA par compartiment produit des résultats améliorés par rapport à l'approche non compartimentée. Cela est principalement dû à l'apport complémentaire des différentes informations des attributs des végétaux (Morel *et al.*, 2012 ; Aholoukpè *et al.*, 2013 ; Kumar *et al.*, 2015 ; Asari *et al.*, 2017). Sur de vastes superficies, des études affirment que les estimations de BA sont meilleures avec la combinaison des données de télédétection (Morel *et al.*, 2012 ; Zhang *et al.*, 2016). Parmi ces données, on note par exemple les indices de végétation (Zhu et Liu, 2015 ; Galidaki *et al.*, 2017), l'indice de surface foliaire (Hardwick *et al.*, 2015), les indices de texture, le coefficient de rétrodiffusion des images radar (*Radio detection and ranging*), et les hauteurs dérivées des données LiDAR (*Light Detection And Ranging*) (Singh *et al.*, 2014a ; Kumar *et al.*, 2015 ; Vaglio-Laurin *et al.*, 2016 ; Ploton *et al.*, 2017). Dans plusieurs régions du monde, les chercheurs tentent de développer des méthodes d'estimation de la BA de la forêt à partir des mesures *in situ* et de données de télédétection. Par exemple, Silva *et al.* (2018) ont exploité des données LiDAR pour évaluer la structure et la BA de la forêt tropicale du parc national de la Lopé au Gabon.

Des méthodes statistiques sont systématiquement utilisées pour lier la BA aux paramètres structuraux des végétaux ou les données de télédétection. Pour accomplir cette tâche, les régressions linéaires multiples (RLM) sont fréquemment employées (Chong *et al.*, 2017). Elles ne considèrent toutefois pas la non-linéarité des données écologiques (Vaglio-Laurin *et al.*, 2016). Des études ont néanmoins montré que les RLM produisaient des résultats significatifs

lors de l'estimation de la BA des forêts et des palmeraies. Des approches par apprentissage machine (ex : k plus proches voisins, *support vector machine*, *random forest* et réseaux de neurones artificiels) servent aussi à évaluer la BA. Parmi ces approches, la régression multivariée par spline adaptative (MARS) est prise en compte (Vaglio-Laurin *et al.*, 2016). Celle-ci traite de la non-linéarité des variables (Piikki et Söderström, 2019). Des études basées sur MARS ont rapporté des résultats pertinents d'estimation de la BA (Pramila and Mahesh 2015 ; Park *et al.*, 2017 ; Li *et al.*, 2019). Ces résultats ont en effet montré que MARS produisait des fortes performances par rapport à d'autres méthodes statistiques (regression logistique, *random forest* et réseaux de neurones artificiels) pour divers paramètres. Des analyses sur l'évaluation de la BA des forêts et des plantations de palmiers à huile sont également réalisées à l'aide des données de télédétection. Par exemple, Morel *et al.*, (2012) ont montré que l'utilisation des données de télédétection contribue à déterminer les changements temporels de la BA dans les forêts et les plantations de palmiers à huile. Ces diverses analyses produisent exclusivement des informations de la biomasse sur des zones étudiées.

1.5 Problématique de l'étude

Le carbone issu de la biomasse forestière mondiale a baissé de près de 0,01 % entre 1990 et 2020, occasionnant ainsi une réduction de la superficie de la forêt (FAO, 2021). Dans le même temps, la demande de l'huile de palme dans le monde a augmenté et les superficies des plantations industrielles de ce végétal ont atteint les 25 millions d'hectares (Mha) (Lewis *et al.*, 2020). Dans le Bassin du Congo, les superficies des plantations industrielles augmentent et les remplacements de forêts en palmeraies existent et croissent avec de fortes ambitions d'ici 2035 (EarthSight, 2018; Tyukavina *et al.*, 2018). Au Gabon, près de 35 000 ha de forêt dense ont été convertis sur une période de six ans en des projets de plantations de palmiers à huile et d'hévéa (EarthSight, 2018). Dans ce pays, ces plantations contribuent à la croissance économique, mais elles mettent aussi en danger les forêts, la biodiversité et les ressources en carbone (Austin *et al.*, 2017). La Figure 1.2 illustre certains emplacements des projets des plantations de palmiers à huile et d'hévéa dans le Bassin du Congo.



Figure 1.2. Localisation de quelques projets de plantations des palmiers à huile et d'hévéa dans le Bassin du Congo (couleur rouge). (Tiré d'EarthSight, 2018, p. 2).

Au-delà de ce risque, l'estimation de la biomasse des forêts et des palmeraies demeure pour le moment très peu étudiée dans le Bassin du Congo (Mitchard *et al.*, 2012; Sannier *et al.*, 2014; Wade *et al.*, 2019). Cette situation est due en grande partie à l'absence de données *in situ* et de télédétection, elle-même motivée par plusieurs facteurs tels que le manque de ressources, le manque de budgets et la difficulté d'accès aux sites d'études sur le terrain. Au Gabon, ce manque de données est aussi clairement constaté (Mitchard *et al.*, 2012; Sannier *et al.*, 2014; Abourou *et al.*, 2018; Wade *et al.*, 2019). Cette irrégularité d'acquisition des données ne permet pas d'effectuer un suivi spatial périodique de la biomasse et de sa dynamique. La Figure 1.3 illustre les données d'inventaires forestiers des placettes scientifiques et des concessions forestières d'Afrique centrale. Dans le Bassin du Congo, la dynamique de la biomasse due aux remplacements des forêts par les palmeraies est aussi difficile à analyser à cause de ce manque régulier de données d'inventaire et de télédétection de haute précision (Brown et Gaston, 1995; Verbeeck *et al.*, 2011; Loubota Panzou *et al.*, 2016; Chong *et al.*, 2017; Ploton *et al.*, 2020; Kashongwe *et al.*, 2020 ; Shapiro *et al.*, 2021). À ce manque, s'ajoutent les incertitudes attachées à l'estimation de la biomasse (Ngomanda *et al.*, 2014 ; Ploton *et al.*, 2016 ; Loubota Panzou *et al.*, 2016; Shi et Liu, 2017). Ces incertitudes sont généralement dues principalement aux erreurs des mesures *in situ*, à la propagation des erreurs au cours de l'établissement des équations et aux bruits ou aux aptitudes des différents types de données de télédétection (Kumar *et al.*, 2015 ; Loubota Panzou *et al.*, 2016 ; Ploton *et al.*, 2016 ; Shi et Liu, 2017). Ces erreurs de mesures *in situ* peuvent être inhérentes à la qualité des données et du

modèle, à la taille des surfaces échantillonnées et à la représentativité des placettes de terrain (Carreira *et al.*, 2013 ; Weiskittel *et al.*, 2015 ; Shi et Liu, 2017). Ces incertitudes sont davantage réduites en utilisant les données LiDAR ou en combinant les données de télédétection (Chave *et al.*, 2014 ; Kumar *et al.*, 2015 ; Loubota Panzou *et al.*, 2016). L'ennuagement persistant dans les zones tropicales humides limite considérablement la disponibilité de certaines données de télédétection, notamment optiques, dans l'espace et le temps.

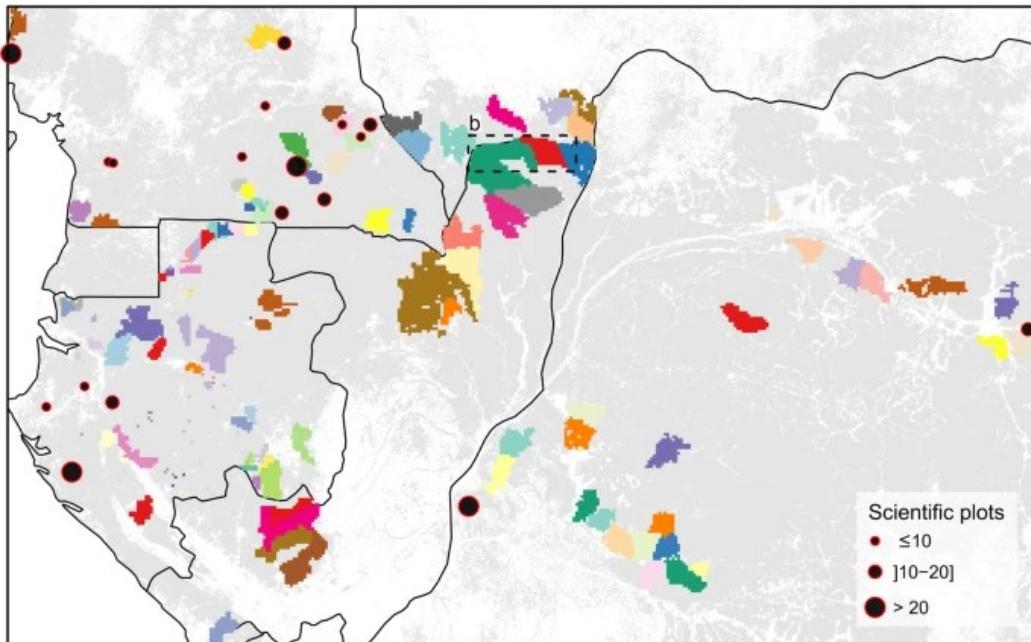


Figure 1.3. Photographie de la localisation spatiale des données d'inventaires forestiers des placettes scientifiques et des concessions forestières d'Afrique centrale utilisées par Ploton *et al.*, (2020) pour estimer la biomasse du Bassin du Congo. Les points noirs représentent l'emplacement des placettes scientifiques. La taille de ces points correspond au nombre de placettes par site d'échantillonnage. Les données forestières sont basées sur la répartition spatiale des forêts humides (gris clair) et les limites nationales (noir). Les données d'inventaire de gestion forestière sont colorées par concessions forestières (Tiré de Ploton *et al.*, 2020, p.4).

Malgré cette difficulté d'acquisition des données, la BA des forêts dans le Bassin du Congo a été estimée dans différentes études récentes à l'aide des mesures *in situ* comportant des incertitudes réduites (Chave *et al.*, 2014; Ploton *et al.*, 2016; Fayolle *et al.*, 2018). Dans l'une de ces études, la biomasse a été prédite à partir d'un ensemble de mesures *in situ* de différents types de végétations et de données bioclimatiques (précipitations, températures et déficit hydrique) des régions tropicales du monde (Chave *et al.*, 2014). Des modèles allométriques de biomasse ont aussi été développés à l'aide des mesures compilées existantes uniques et/ou non publiées d'inventaires forestiers (Ploton *et al.*, 2016; Fayolle *et al.*, 2018). Fayolle *et al.*, (2013) et Ngomanda *et al.*, (2014) proposent des modèles allométriques de loi puissance pour

estimer la biomasse à l'aide de données obtenues à partir de méthodes destructives ou d'inventaires forestiers sur des arbres à gros diamètres. Des études ont estimé la BA avec un nombre restreint d'échantillons (Ebuy *et al.*, 2011; Henry *et al.*, 2013) ou avec peu de gros diamètres d'arbres (Djomo *et al.*, 2010; Loubota Panzou *et al.*, 2016). Certains travaux intègrent des données multisources, comme celles provenant de bases de données en ligne d'accès libres de ForestPlots.NET (Lopez-Gonzalez *et al.*, 2011) ou du système d'observation des forêts du monde (Schepaschenko *et al.*, 2019).

L'estimation de la BA à partir des inventaires de terrain est la manière traditionnelle de procéder. La nouvelle tendance est l'exploitation des données d'observation de la Terre. De nombreux travaux ont été réalisés dans ce sens, même si beaucoup reste à faire pour améliorer la qualité des estimations. Ainsi, dans le Bassin du Congo, les observations de réflectance de MODIS (*Moderate Resolution Imaging Spectroradiometer*) sans nuage ont été liées aux mesures *in situ* des forêts avec un modèle d'arbres de régression pour produire la première carte de la BA de l'Afrique tropicale à une limite de résolution de 1 km (Baccini *et al.*, 2008). D'autres travaux ont porté sur des sites spécifiques de la région en proposant des approches basées sur des indices FOTO dérivés de Geoeye-1 et QuickBird-2 (Bastin *et al.*, 2014). Des approches basées sur les régressions linéaires multiples et les méthodes d'apprentissage machine non linéaires (*k plus proches voisins*, *support vector machine*, *random forest* et réseaux de neurones artificiels) ont également été évaluées (Tapamo *et al.*, 2014; Ploton *et al.*, 2017). À la différence de la plupart des travaux, Bouvet *et al.*, (2018) ont produit la première carte continentale de BA des savanes et des forêts africaines (incluant le Bassin du Congo) à une limite de résolution de 25 m en utilisant le coefficient de rétrodiffusion d'ALOS PALSAR en bande L. Les données LiDAR aéroportées et satellitaires ont été utilisées pour dériver les hauteurs des arbres et pour prédire la BA au Gabon (Mitchard *et al.*, 2012; Labriere *et al.*, 2018; Saatchi *et al.*, 2019). Nombre de travaux se sont penchés sur la combinaison de données de télédétection multisource. Ainsi, Kashongwe *et al.*, (2020) proposent une combinaison de données *Landsat-8 Operational Land Imager* (OLI) et LiDAR pour estimer les hauteurs et la BA dans une forêt tropicale de la République Démocratique du Congo en utilisant le *random forest*. Pour les mêmes fins, El Hajj *et al.*, (2019) combinent à la fois les données optiques, LiDAR et radar, ainsi que des données de précipitations. L'utilisation de ces données multisources créent des problèmes comme l'imprécision des données (manque de connaissance quantitative sur une mesure), l'incomplétude des données (manque d'information pour des sources de données), ou encore le conflit entre les sources de données (Bloch, 2003). Les études les plus récentes d'estimation de la BA au Gabon ont généralement utilisé les données de terrain

et/ou de télédétection de la campagne AfriSAR de la *United States National Aeronautics and Space Administration* (NASA) (Labriere *et al.*, 2018; Saatchi *et al.*, 2019 et El Hajj *et al.*, 2019). Cette imposante campagne expérimentale a été justement initiée pour pallier le manque de données scientifiques qui caractérise la région. La superficie forestière, le stock de carbone et les ressources de biodiversité protégées au Gabon ont également été quantifiés sur la base de l'évaluation des terres appropriées pour la culture du palmier à huile et pour des nouvelles cartes de la répartition des espèces prioritaires et de la biomasse forestière (Austin *et al.*, 2017).

En dépit des efforts déjà consentis par la communauté scientifique, beaucoup reste à faire pour estimer la biomasse des forêts tropicales du Bassin du Congo de manière précise. Les incertitudes restent encore très importantes sur la plupart des estimations rapportées, variant de 30 % à plus de 100 % (Gonçalves *et al.*, 2017 ; Vorster *et al.*, 2020). Ces incertitudes sont relatives à la vérité de l'information ou caractérisent la conformité de l'information estimée par rapport à la réalité (Bloch, 2003). L'évaluation d'approches à fort potentiel, comme MARS, avec une combinaison de données de télédétection multisource pourrait contribuer à améliorer les estimations de la BA tant pour les palmeraies que pour les forêts. Dans les deux cas, les connaissances restent encore très limitées dans le Bassin du Congo. Le besoin de développer de nouvelles approches motive cette étude et celui-ci reste donc très critique dans le contexte actuel des changements climatiques et de la propension vers le développement agro-industriel des plantations de palmiers. La prise en compte des différents besoins permettra d'estimer au moyen de la télédétection, la BA des palmeraies et de la forêt. Elle contribuera aussi à connaître si l'installation des plantations de palmiers sur des terres forestières favorise la compensation de la BA de la forêt dans cette région. Ainsi, la question de recherche principale formulée est la suivante : la combinaison de données de télédétection multisources dans une approche prenant en compte les non-linéarités permet-elle, d'une part, d'améliorer de manière significative l'estimation des BA des plantations des palmeraies et des forêts dans le Bassin du Congo, et d'autre part, de comprendre les éventuels déficits ou gains pouvant résulter de l'introduction des palmiers à la place des forêts ?

1.6 Objectifs

L'objectif principal de l'étude vise à utiliser la télédétection pour développer des méthodes d'estimation de la BA pour comprendre l'impact des plantations de palmiers à huile sur la dynamique de la biomasse des forêts dans le Bassin du Congo. Les trois (3) objectifs spécifiques sont les suivants :

1. développer des modèles d'évaluation des BA des palmiers à huile à l'aide des données de terrain ;
2. estimer les BA des forêts et des palmiers à huile des plantations agro-industrielles par l'utilisation de la télédétection ;
3. évaluer les changements des BA dus aux remplacements des forêts en plantations agro-industrielles des palmiers à huile.

1.7 Hypothèses

L'hypothèse principale de la présente étude est la suivante : l'utilisation de la télédétection permet d'estimer et de comprendre la dynamique de la BA des forêts et des palmeraies dans le Bassin du Congo. Ci-après, sont formulées les quatre (4) hypothèses spécifiques de l'étude :

- la BA des palmiers à huile est estimée de manière améliorée à l'aide de ses paramètres structuraux avec des équations allométriques locales et existantes ;
- l'utilisation de l'analyse de texture et de l'approche multivariée réduit les erreurs d'estimation de la BA des palmiers à huile ;
- l'emploi des données combinées de télédétection et de l'approche MARS améliore les estimations de la BA des forêts par rapport aux approches de prédiction de la BA existantes ;
- le remplacement des forêts matures, secondaires vieilles et jeunes-adultes en palmeraies occasionne des pertes de BA.

1.8. Structure de la thèse

La présente thèse s'articule autour de dix (10) chapitres. L'importance de la thématique de recherche est discutée au chapitre 1 portant sur l'introduction. Les défis des méthodes d'estimation de la BA des végétaux chlorophylliens et les problématiques de recherche sont aussi expliqués dans ce chapitre. Les objectifs, la question de recherche et les hypothèses y sont également présentés.

Le chapitre 2 porte sur le cadre théorique de l'étude. Il présente entre autres le contexte scientifique, les bases statistiques et les applications de la télédétection à l'estimation de la BA.

Le chapitre 3 décrit les sites, ainsi que les données (*in situ* et télédétection) utilisées.

La méthodologie globale de la thèse se retrouve dans le chapitre 4. Il est important de noter que les méthodologies spécifiques à l'obtention de chaque résultat sont détaillées dans les articles produits.

Le chapitre 5 correspond au premier article publié. Il présente la recherche effectuée pour développer les relations allométriques qui permettent d'estimer la BA des palmiers à huile dans une plantation mature du Bassin du Congo à partir des mesures acquises sur le terrain. L'article a été publié en 2020 dans la revue *Forest*, sous le titre « *Estimation of Aboveground oil palm biomass in a mature plantation in the Congo Basin* ».

Le chapitre 6 propose des modèles basés principalement sur l'approche MARS et les indices FOTO pour estimer la BA des palmiers à huile à partir d'images FORMOSAT-2 et PlanetScope. Ce chapitre a été publié dans la revue *Remote Sensing* en 2020. Il est intitulé « *Evaluation of FORMOSAT-2 and PlanetScope imagery for aboveground oil palm biomass estimation in a mature plantation in the Congo Basin* ».

Le chapitre 7 porte sur l'estimation des BA de la forêt tropicale à travers une série de modèles basés sur l'approche MARS et une combinaison de données multisources de télédétection, incluant les données optiques, LiDAR et radar polarimétrique-interférométrique. Le développement des modèles s'appuie sur des données *in situ* découlant de deux campagnes de terrain, dont l'une entreprise spécifiquement dans le cadre de la thèse. Les résultats obtenus dans ce chapitre ont fait l'objet d'un manuscrit, qui est actuellement en révision dans la revue *GIScience & Remote Sensing*, sous le titre « *Estimation of total dry aboveground biomass of forests in the Congo Basin using Optical, LiDAR and Radar Data* ».

Le chapitre 8 met en évidence l'analyse de la dynamique de la BA due aux remplacements des forêts par les palmeraies. Cette analyse est basée sur les valeurs de BA des cartes de forêts et des palmeraies produites à l'aide des données de télédétection aux chapitres 6 et 7 de la présente thèse. Celle-ci établit clairement les pertes et les gains de BA dus aux substitutions des forêts par les palmeraies. Les résultats de cette analyse permettent ensuite de concevoir une carte de BA de conversion ou non des forêts en palmeraies, utile aux décideurs pour optimiser la mise en œuvre des activités de l'affectation des terres et de la lutte contre les changements climatiques.

Le chapitre 9 porte sur la discussion générale de la recherche effectuée dans le cadre de la thèse. Il examine les forces et les faiblesses des approches proposées en lien avec la littérature existante.

Finalement, le chapitre 10 présente la conclusion générale et les contributions originales de la thèse. Il décrit également les perspectives en termes de nouvelles recherches qui pourraient améliorer davantage l'estimation des BA à la fois dans les plantations agro-industrielles et dans les forêts tropicales naturelles, et favoriser une meilleure compréhension de l'action de l'homme sur les forêts dans le contexte des changements climatiques.

CHAPITRE 2. Cadre théorique

2.1 Estimation de la biomasse de la végétation à partir des mesures *in situ*

2.1.1 Méthode destructive

La méthode destructive vise à estimer la biomasse au niveau de l'arbre particulièrement sur les parties des feuilles, du tronc et des racines (Picard *et al.*, 2012 ; Neumann *et al.*, 2016). La Figure 2.1 présente les compartiments des feuilles et du tronc d'un palmier à huile et d'un arbre pour les besoins de l'étude. La quantité de la biomasse (production primaire nette) est obtenue par la différence entre la quantité totale de matière organique produite au cours de la photosynthèse (production primaire brute) et la quantité de matière organique perdue pendant la respiration des végétaux chlorophylliens (Cornet, 1981). La méthode destructive est plus directe et plus précise pour estimer la BA des végétaux chlorophylliens à partir des mesures *in situ* (Brown *et al.*, 1989 ; Khalid *et al.*, 1999 ; Thenkabail *et al.*, 2004 ; Chave *et al.*, 2014 ; Lewis *et al.*, 2020). Néanmoins, elle est confrontée aussi aux erreurs de mesures des paramètres caractéristiques sur le terrain et en laboratoire (Picard *et al.*, 2012). Sur le terrain, le végétal chlorophyllien est abattu et billonné et les échantillons (ou aliquote) frais extraits de chacun de ses compartiments sont mesurés (ex. diamètres, hauteurs et masses) (Kumar *et al.*, 2015 ; Neumann *et al.*, 2016 ; Shi et Liu, 2017 ; Han et Park, 2020 ; Lewis *et al.*, 2020). La Figure 2.2 présente les étapes générales pour mettre en œuvre l'approche des mesures *in situ*.

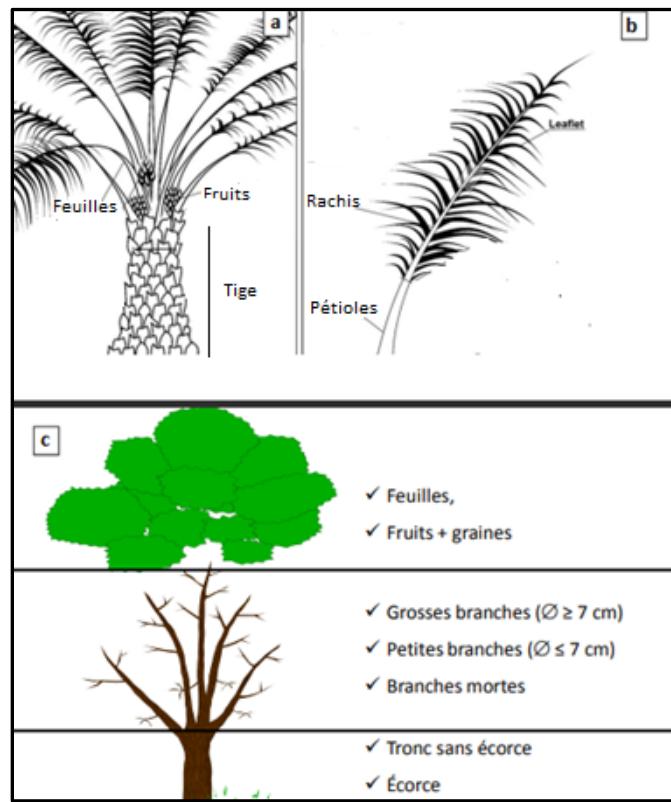


Figure 2.1. Compartiments des feuilles et du tronc d'un palmier à huile (a et b) et d'un arbre de forêt (Compilation d'après Picard *et al.*, 2012, p. 54 et Lewis *et al.*, 2020, p. 2)

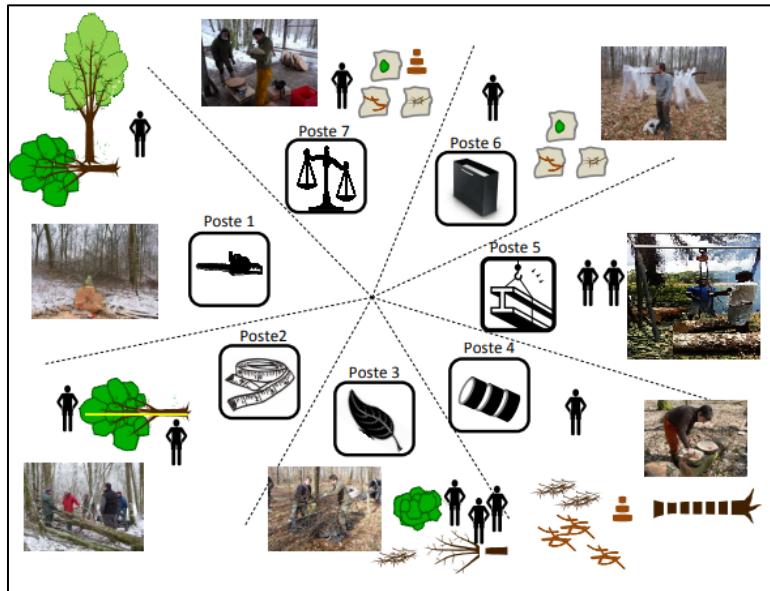


Figure 2.2. Organisation d'un chantier de biomasse avec 7 postes. Poste 1 : préparation du terrain et abattage des arbres; poste 2 : mesure sur arbres abattus : profils de tige, position des billons; poste 3 : effeuillage et ébranchage; poste 4 : billonnage et étiquetage des rondelles; poste 5 : pesée des billons et des fagots; poste 6 : échantillonnage des branches; poste 7 : zone de pesées des échantillons. (Adapté de Picard *et al.*, 2012, p. 56).

Dans la deuxième approche, les aliquotes frais sont séchés et pesés. La fraction de masse sèche par compartiment (fms), la masse de la biomasse sèche aérienne totale des compartiments du végétal (BA, en kg) et l'infra-densité ou la densité de bois (ρ , en g cm⁻³) sont ensuite calculées ou déterminées. Pour y parvenir, on calcule ainsi préalablement pour chaque échantillon prélevé dans le billon i , ce qui suit :

- le volume saturé d'un aliquote frais d'un billon de bois, i ($V_{\text{aliquote frais}, i}$ en cm⁻³). Ce volume est obtenu par pesée hydrostatique. Avec la pesée hydrostatique, l'échantillon de bois est immergé dans une cuve remplie d'eau. La masse du volume d'eau déplacée en g est égale au volume de l'échantillon en cm³ (Bauwens et Fayolle, 2014). Le volume du billon de bois frais peut aussi être calculé selon la formule du tronçon de cône (ou formule de Newton : $V_{\text{frais}, i} = L_i \times \pi / 3 \times (R_{1i}^2 + R_{1i} R_{2i} + R_{2i}^2)$ où : $V_{\text{frais}, i}$ est le volume frais du billon i . L_i est la longueur du billon i , et R_{1i} et R_{2i} sont les rayons du billon i à ses deux extrémités) (Picard *et al.*, 2012).
- la fraction de masse sèche par compartiment de l'arbre (fms)

$$fms = \frac{1}{n} \sum_{i=1}^n \frac{B_{\text{aliquote sec}, i}}{B_{\text{aliquote frais}, i}} \quad (2.1)$$

où fms est la fraction de masse sèche du compartiment d'un arbre. La variable n est le nombre d'aliquotes par compartiment de l'arbre. $B_{\text{aliquote sec}, i}$ est la biomasse sèche de l'aliquote du compartiment d'un arbre i . $B_{\text{aliquote frais}, i}$ est la biomasse fraîche de l'aliquote du compartiment d'un arbre i . Les compartiments de l'arbre de la forêt sont constitués de la tige, des feuilles, des branches et des fruits. Les palmiers à huile ont pour compartiment : la tige, les pétioles, les rachis, les folioles et les fruits.

La détermination de la fraction de masse sèche (équation 2.1) permet de calculer les biomasses sèches par compartiment, ainsi que la biomasse aérienne sèche totale de l'arbre.

- La biomasse sèche d'une portion d'un compartiment d'un arbre est :

$$B_{\text{portion sec}, i2} = B_{\text{portion frais}, i2} \times fms_{i2} \quad (2.2)$$

où $B_{\text{portion sec}, i2}$ est la biomasse sèche d'une portion d'un compartiment d'un arbre. $B_{\text{portion frais}, i2}$ est la biomasse fraîche d'une portion d'un compartiment d'un arbre.

- la biomasse sèche totale d'un compartiment d'un arbre est :

$$B_{\text{sèche compartiment}} = \sum_{i2=1}^m B_{\text{portion frais}, i2} \times fms_{i2} \quad (2.3)$$

où m est le nombre de portions d'un compartiment d'un arbre.

- la biomasse aérienne sèche totale des compartiments d'un arbre.

$$BA = \sum_{i3=1}^p B_{\text{sèche arbre}, i3} \quad (2.4)$$

où BA est biomasse aérienne sèche totale des compartiments d'un arbre. P est le nombre de compartiments d'un arbre.

Les volumes saturés et les masses sèches des aliquotes de bois des billons d'un arbre mesurés au laboratoire permettent d'évaluer l'infra-densité du bois d'un arbre spécifique.

- L'infra-densité de bois moyen (ρ , en g cm⁻³) est :

$$\rho = \frac{1}{z} \sum_{i=1}^z \frac{B_{aliquote\ sec,i}}{V_{aliquote\ frais,i}} \quad (2.5)$$

où ρ est l'infra-densité de bois moyen. $B_{aliquote\ sec,i}$ est la biomasse sèche de l'aliquote de bois du billon du tronc d'un arbre. $V_{aliquote\ frais,i}$ est le volume saturé de l'aliquote frais d'un billon de bois du tronc d'un arbre, et z est le nombre de billons du tronc d'un arbre.

2.1.2 Équations allométriques de biomasse

Il existe au niveau d'une population une relation statistique entre les différentes mensurations d'un individu. Les proportions entre ces mensurations respectent une règle identique pour tous les arbres vivants dans les mêmes conditions (Picard *et al.*, 2012). Ces relations découlent du principe de base de l'allométrie qui consiste à prédire une mensuration d'un arbre en fonction d'une autre mensuration qui respecte une règle identique pour tous les arbres vivants dans les mêmes conditions (Picard *et al.*, 2012). Une définition plus restrictive de l'allométrie établit une relation de proportionnalité entre les accroissements relatifs des mensurations. Avec cette restriction, une équation allométrique correspond à l'équation de puissance, qui prend en compte l'auto-similarité lors de la croissance des individus (White et Gould, 1965; Gould, 1971; Picard *et al.*, 2012). Les équations allométriques de loi puissance sont ainsi usuellement les plus employées pour estimer la BA à l'aide des paramètres structurels physiques des végétaux obtenus avec la méthode destructive. Elles prennent la forme ci-après (Gould, 1966 ; Brown *et al.*, 1989 ; Da Silva *et al.*, 2015) :

$$y = aX^b \quad (2.6)$$

où y est la variable dépendante (biomasse sèche), X est le produit des variables indépendantes (ex : DHP, diamètre à hauteur de poitrine mesuré à 1,3 m au-dessus du sol) et a et b représentent respectivement la proportionnalité entre les grandeurs cumulées et le coefficient de l'allométrie. La forme log -transformée de l'équation est utilisée pour linéariser l'expression, tout en homogénéisant la variance, ce qui augmente la validité des tests statistiques utilisés (Brown *et al.*, 1989; Onyekwelu *et al.*, 2004; Chave *et al.*, 2005). L'équation peut être réécrite comme :

$$\ln(y) = \ln(a) + b\ln(X) \quad (2.7)$$

Les variables indépendantes sont constituées des mesures *in situ* d'inventaires forestiers non destructifs ou semi-destructifs (hauteur de la tige (H_T), hauteur totale (H_{TOT}), DHP, densité du bois (ρ), nombre de feuilles (N_F), etc.) (Kumar *et al.*, 2015 ; Loubota Panzou *et al.*, 2016 ; Shi et Liu, 2017 ; Lewis *et al.*, 2020). Il existe plusieurs écrits sur les méthodes classiques d'estimation de la BA, ainsi que sur les biais et erreurs associés. Le lecteur pourrait consulter entre autres Cole et Ewel, 2006; Picard *et al.*, 2012 ; Carreira *et al.*, 2013 ; Goodman *et al.*, 2013; Ngomanda *et al.*, 2014 ; Kumar *et al.*, 2015 ; Da Silva *et al.*, 2015 ; Weiskittel *et al.*, 2015 ; Shi et Liu, 2017 ou Yang *et al.*, 2017.

2.2 Estimation de la biomasse des peuplements par télédétection

L'estimation de la biomasse sèche aérienne totale des peuplements par télédétection est une méthode non destructive. Cette dernière vise à prédire la BA au niveau du peuplement ou sur de vastes territoires des végétaux chlorophylliens (ex. forêts ou palmeraies) sans pourtant les abattre (Lewis *et al.*, 2020). Nous distinguons trois approches : optique, LiDAR et radar. Ces trois approches peuvent être combinées pour améliorer les estimations des paramètres étudiés (Chave *et al.*, 2014 ; Kumar *et al.*, 2015 ; Loubota Panzou *et al.*, 2016). Plusieurs approches statistiques (ex. régression, k plus proches voisins, *support vector machine*, *random forest* et réseaux de neurones artificiels) sont utilisées pour lier la BA aux variables explicatives de télédétection (Tapamo *et al.*, 2014 ; Kumar *et al.*, 2015 ; Vaglio-Laurin *et al.*, 2016 ; Loubota Panzou *et al.*, 2016 ; Chong *et al.*, 2017 ; Li *et al.*, 2019 ; Li *et al.*, 2020 ; Li *et al.*, 2021).

2.2.1 Estimation de la biomasse à partir des données optiques

Le domaine optique utile pour l'étude de la végétation couvre les parties visible et infrarouge du spectre électromagnétique. Comme le montre la Figure 2.3, la réflectance a un creux d'absorption dans le spectre rouge (650 nm), alors que l'infrarouge (750 à 1550 nm) est caractérisé par une forte réflexion. L'intensité de l'activité chlorophyllienne explique les caractéristiques des signatures (Willstätter et Stoll, 1918 ; Jacquemoud *et al.*, 2009 ; Galidaki *et al.*, 2017). Ces particularités ont été utilisées pour développer une multitude d'indices de végétation au cours des quatre dernières décennies. Pour un survol de ces indices, consulter Kumar *et al.*, (2015) et Galidaki *et al.*, (2017).

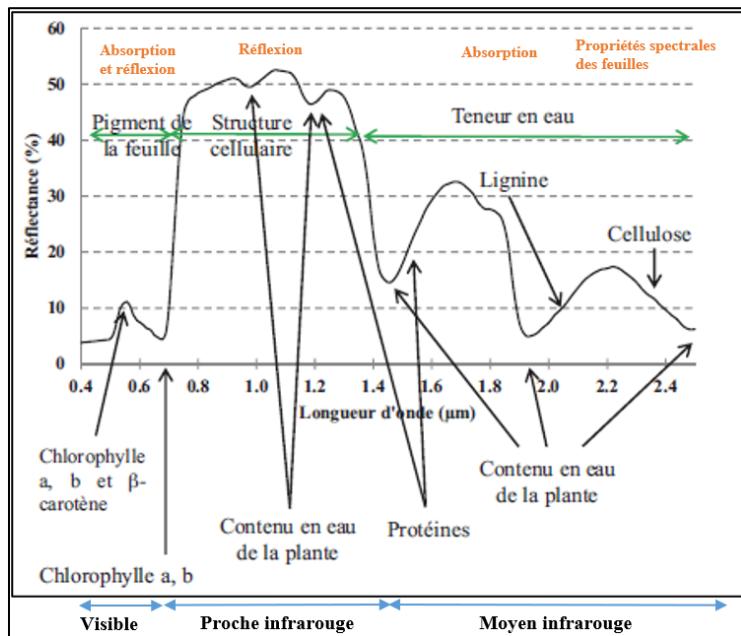


Figure 2.3. Réflectances des constituants d'une feuille verte (Adapté de Briottet, 2016, p. 34)

Les BA des végétaux chlorophylliens ont régulièrement été estimées avec des méthodes statistiques à l'aide de trois principales approches des données de télédétection optique à résolutions spatiales fine (< 5 m), moyenne (10-100 m) et grossière (> 100 m). L'approche de résolution spatiale fine fournit plus de détails sur l'objet (ex : couronne d'arbre) contenu dans l'image satellitaire. Elle offre ainsi la possibilité d'identifier des couronnes individuelles. L'approche de résolution spatiale moyenne présente moins de détails par rapport à la résolution spatiale fine. Elle peut englober plusieurs couronnes d'arbres ou d'autres caractéristiques dans un seul pixel. L'approche de résolution spatiale grossière est moins précise par rapport aux autres approches. Elle est utile pour l'estimation de la BA au niveau régional ou continental. Plusieurs facteurs exogènes (stockage, temps de traitement important et coût) limitent l'utilisation des images satellitaires de haute résolution spatiale pour l'estimation de la biomasse sur de vastes zones géographiques. D'autres facteurs d'ordre spectral (ombres, variabilité spectrale et faible séparabilité spectrale entre les cimes des arbres) liés directement à ces images concourent également à leurs limitations pour l'évaluation de la biomasse (Kumar *et al.*, 2015). Malgré ces limites, ces images caractérisent mieux les classes de végétation ou la BA à partir des informations contextuelles, des indices de texture, des statistiques des bandes spectrales (Kumar *et al.*, 2015). Les BA des forêts tropicales (Lu et Batistella, 2005) ont par exemple été mieux estimées à l'aide des images de texture que les bandes spectrales originales de résolution spatiale fine. L'estimation de la BA peut être améliorée à travers la combinaison de données satellitaires multisources (optiques, radar, ou LiDAR), associées ou non à des données auxiliaires (climat, topographie, carte de végétation, température) (Baccini *et al.*, 2004; Saatchi

et al., 2007; Baccini *et al.*, 2008; Blackard *et al.*, 2008; Kumar *et al.*, 2015; Galidaki *et al.*, 2017).

Globalement, les valeurs de réflectance de la plante intègrent les effets perturbateurs liés à l'acquisition des données de télédétection, des conditions météorologique (ex : couverture nuageuse fréquente sur les tropiques) et environnementale (ex : l'humidité du sol, la phénologie de la végétation, la vigueur de croissance) (Villard *et al.*, 2016 ; Catry *et al.*, 2018). Au Gabon, aucune image des séries Landsat et SPOT-Take5 n'est par exemple exploitable dans plusieurs régions (Villard *et al.*, 2016). Les données optiques ont tendance à saturer dans les biomasses élevées. De plus, elles sont peu sensibles à la structure verticale de la canopée. Néanmoins, elles sont appropriées pour décrire la structure horizontale de la végétation (ex : type de végétation et couvert végétal). Ainsi, malgré des limitations évidentes, elles peuvent contribuer à l'estimation de la BA (Kumar *et al.*, 2015). Dans ce sens, l'utilisation des indices de texture (GLCM ou FOTO) s'avère souvent plus efficace que celle d'autres variables de télédétection optique (Kumar *et al.*, 2015 ; Chen et Wang, 2020 ; Li *et al.*, 2021). Ces indices montrent la disposition relative des niveaux de gris, des motifs spatiaux et des structures horizontales dans l'image (Haralick *et al.*, 1979). Les indices FOTO résistent mieux à la saturation à des hautes BA avoisinant les 500 Mg ha⁻¹ et plus (Bastin *et al.*, 2014 ; Tapamo *et al.*, 2014 ; Ploton *et al.*, 2017). Ainsi, ces indices paraissent mieux indiqués lorsqu'il s'agit des forêts tropicales denses (Villard *et al.*, 2016 ; Ploton *et al.*, 2017).

2.2.1.1. Indices FOTO

Les scores de l'analyse en composantes principales (ACP) des spectres radiaux (spectres-r) de la transformée de Fourier discrète rapide à deux dimensions (FFT 2D) constituent les indices FOTO. Ces derniers contribuent à caractériser la distribution des tailles de la couronne de la canopée et à estimer la BA des forêts. Cinq (5) étapes sont indispensables pour développer des approches d'estimation de la BA basées sur les indices FOTO. La première étape consiste à masquer sur l'image satellitaire optique à haute résolution spatiale les zones non forestières, c'est-à-dire dépourvues de BA. La deuxième étape porte sur la sélection des tailles de fenêtre pour le calcul des indices à partir de la bande spectrale choisie. L'étape 3 consiste à calculer les spectres-r pour chacune des tailles de fenêtre considérées en appliquant la FFT 2D. Pour cela, il est nécessaire de convertir la radiance spectrale du domaine spatial au domaine fréquentiel. Cette conversion est effectuée par le calcul des périodogrammes (I_{pq}) pour chaque paire de fréquences spatiales (ou nombres d'onde) (p, q) à partir des coefficients de Fourier (a_{pq} et b_{pq}), tels que (Couteron *et al.*, 2006; Proisy *et al.*, 2007) :

$$I_{pq} = WS^{-2}(a_{pq^2} + b_{pq^2}) \quad (2.8)$$

où WS est la taille de la fenêtre considérée pour appliquer la FFT 2D. Le périodogramme informe sur la variance de l'image, selon les contributions relatives des types de texture à diverses échelles spatiales. La seconde phase vise à simplifier les périodogrammes dans le contexte de l'analyse de la texture. Cette simplification s'appuie sur le calcul de leurs valeurs moyennes dans toutes les directions éventuelles de mouvement θ pour générer un spectre radial moyen $I_{(r)}$. Ce spectre est appelé « spectre-r » :

$$I_{(r)} = (k\sigma^2)^{-1} \sum_{\theta} I_{r\theta} \quad (2.9)$$

où k correspond au nombre de valeurs du périodogramme à fréquence spatiale r et σ^2 est la variance à l'intérieur de la bande spectrale de l'image satellitaire.

Les spectres-r permettent de caractériser les grains grossiers et les grains fins de la texture. Cette propriété est particulièrement importante pour la discrimination des classes de forêt, et par ricochet l'estimation de la BA (Mugglestone et Renshaw, 1998; Couteron *et al.*, 2006; Proisy *et al.*, 2007; Guo et Rees, 2019). La quatrième étape dans les approches basées sur les indices FOTO consiste à faire l'ordination texturale par taille de fenêtre et à exécuter l'ACP sur les valeurs normalisées des spectres-r. Les scores des trois premières composantes principales (CP) de l'ACP obtenus expliquent en général l'essentiel de la variance des données. Ces scores correspondent aux indices FOTO. Les types de grains de texture sont habituellement interprétés à partir des scores des CP 1 et 2 sur un plan orthogonal. Pour des fins de visualisation, les valeurs des scores, c'est-à-dire les indices FOTO peuvent être cartographiées sous forme d'images de texture rouge-vert-bleu, avec une résolution spatiale identique à la taille de la fenêtre (WS). La dernière étape du processus permet de développer des approches statistiques d'estimation de la BA en utilisant les indices FOTO comme des variables explicatives. Ces approches peuvent être des régressions ou des méthodes d'apprentissage machine (k plus proches voisins, *support vector machine*, *random forest* et réseaux de neurones artificiels, etc.).

La Figure 2.4 présente le schéma des étapes d'exécution de la méthode FOTO avec une taille de fenêtre sur une image satellitaire. Dans diverses études, les indices FOTO, utiles à la prédiction de la BA, ont été extraits sur les bandes spectrales proche infrarouge (Proisy *et al.*, 2007), panchromatique (Ploton *et al.*, 2012; Ploton *et al.*, 2017) ou le composé couleur (infrarouge, rouge et vert) (Singh *et al.*, 2014a). La méthode FOTO requiert généralement des images de très haute résolution spatiale. Cette résolution est dégradée par la suite avec le choix des fenêtres. Selon les études antérieures, il est plutôt recommandé d'utiliser la bande proche

infrarouge pour mettre en œuvre l'approche FOTO pour l'estimation de la BA. Cela s'explique par la grande sensibilité de cette partie du spectre au couvert végétal (Proisy *et al.*, 2007). Il est aussi conseillé de réduire les opérations de transformation des données des bandes spectrales (ex. la correction radiométrique) pour limiter les pertes d'informations (Proisy *et al.*, 2007).

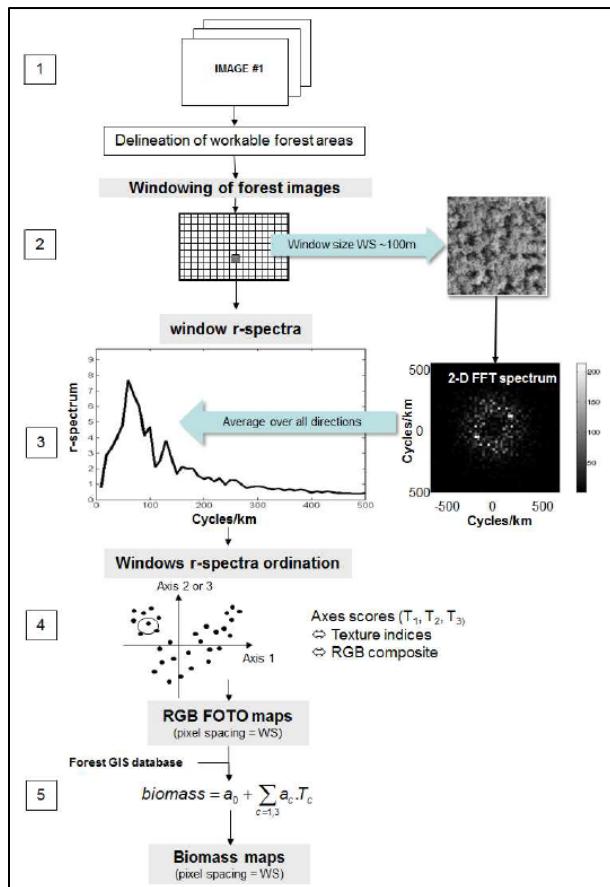


Figure 2.4. Schéma des étapes de mise en œuvre de la méthode FOTO avec une taille de fenêtre sur une image satellitaire (Tiré de Proisy *et al.*, 2012, p. 62)

2.2.1.2 Indices de texture de la matrice de co-occurrence de niveau de gris

Les indices de texture de la matrice de co-occurrence de niveau de gris (GLCM) permettent de caractériser les niveaux de gris de la texture de la canopée et d'estimer la BA des forêts (Haralick *et al.*, 1979 ; Kumar *et al.*, 2015 ; Hlatshwayo *et al.*, 2019). Les indices de texture GLCM correspondent aux mesures de premier ordre (ou d'occurrence) et de deuxième ordre (ou de co-occurrence). Les mesures de premier ordre (ex. la moyenne, l'écart-type, la variance) ne considèrent pas la relation entre pixels voisins mais quantifient plutôt les valeurs de chaque pixel en un emplacement donné. Les mesures de second ordre (ex. entropie, contraste, corrélation) traduisent par ailleurs les relations spatiales entre des groupes de deux pixels voisins dans une direction donnée (Gallardo-Cruz *et al.*, 2012; Singh *et al.*, 2014b). Le Tableau 2.1 présente les différentes équations des indices de texture GLCM souvent utilisés pour estimer

la BA (Coulibaly et Gwyn, 2005; Coulibaly et Goïta, 2006; Gallardo-Cruz *et al.*, 2012; Singh, Malhi, et Bhagwat, 2014b; Kelsey et Neff, 2014; Moya *et al.*, 2019; Pandit, Tsuyuki, et Dube, 2020). Les indices peuvent être extraits de bandes individuelles ou combinées (Singh *et al.*, 2014b; Gallardo-Cruz *et al.*, 2012; Hlatshwayo *et al.*, 2020). La combinaison de bandes fournit une grande quantité d'informations qui contribuent davantage à réduire les effets de divers facteurs influençant la saturation, comme la topographie, les types de forêt, les structures de peuplement forestier, les résolutions spatiales des images, etc. (Zhao *et al.*, 2016). Pour estimer la BA, les indices sont souvent combinés entre eux (Singh *et al.*, 2014b; Kelsey et Neff, 2014; Hlatshwayo *et al.*, 2020) ou avec d'autres données de télédétection et des informations auxiliaires (Kumar *et al.*, 2015; El Hajj *et al.*, 2019).

Tableau 2.1. Description des indices de texture GLCM usuellement utilisés pour estimer la biomasse des végétaux chlorophylliens. $P(i, j, d, \theta)$ est la probabilité de passer du pixel de niveau de gris i au pixel de niveau de gris j qui sont situés à une distance d les uns des autres dans une orientation θ . Les valeurs μ_x et σ_x sont respectivement la moyenne et l'écart type des lignes de la matrice de cooccurrence, tandis que μ_y et σ_y définissent les mêmes statistiques pour les colonnes. L correspond au niveau de quantification maximal des niveaux de gris (Compilation d'après Coulibaly et Gwyn, 2005, p. 443; Coulibaly et Goïta, 2006, p. 4574; Singh, Malhi, et Bhagwat, 2014b, p. 083695-7 ; Moya *et al.*, 2019, p. 18 ; Pandit, Tsuyuki et Dube, 2020, p. 1837).

Indice de texture GLCM	Signification	Formule
Moyenne	La moyenne mesure la moyenne de la distribution des niveaux de gris des éléments de base ou des motifs à partir desquels la texture est formée	$\text{Moyenne} = \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} iP(i, j, d, \theta)$
Écart-type	L'écart type caractérise la dispersion des niveaux de gris des éléments ou motifs de base à partir desquels la texture est formée	$\begin{aligned} \text{Écart - type} \\ = \sqrt{\sum_{i=0}^{L-1} \sum_{j=0}^{L-1} [P(i, j, d, \theta)(i - \text{Moyenne})]} \end{aligned}$
Homogénéité	L'homogénéité quantifie le niveau d'uniformité de la texture.	$\text{Homogénéité} = \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} P(i, j, d, \theta)/1 + (i - j)^2$
Entropie	L'entropie mesure le degré d'organisation ou de désordre de la texture.	$\text{Entropie} = \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} P(i, j, d, \theta) \ln [P(i, j, d, \theta)]$
Corrélation	Mesure la dépendance linéaire des niveaux de gris dans une image	$\text{Corrélation} = \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} [(i - \mu_x)(j - \mu_y)P(i, j, d, \theta)]/\sigma_x\sigma_y$
Contraste	Calcule le niveau de variation locale des niveaux de gris au sein d'une fenêtre	$\text{Contraste} = \sum_{i=0}^{L-1} \sum_{j=1}^{L-1} (i - j)^2 P(i, j, d, \theta)$

2.2.2 Estimation de la biomasse à partir des données LiDAR

La télédétection optique active du LiDAR permet l'étude de la végétation dans les mêmes bandes spectrales (visible et IR) que la télédétection optique passive (Figure 2.3). Les longueurs d'onde des domaines du proche ultraviolet (UV, 200-390 nm), de l'optique (visible (390-780 nm) et du proche infrarouge (IR, 780 à 3000 nm)) sont utilisées dans la télédétection optique active pour l'étude de la végétation (Chazette *et al.*, 2016). Des études pionnières ont attesté le LiDAR comme source de données entrantes pour les modèles de hauteur de la canopée sur différentes échelles de la végétation (arbre, parcelle, zone étudiée) (Hyyppä et Hallikainen, 1996 ; Lu *et al.*, 2012 ; Michez *et al.*, 2016). Les données LiDAR ont usuellement été synthétisées en sous-produits de nuages de points LiDAR (Figure 2.5). Ces sous-produits sont constitués des modèles numériques de terrain (MNT), des modèles numériques de surface (MNS) et des modèles numériques de hauteur (MNH) ou canopée (MNC). Les détails pour le calcul des différents modèles sont disponibles dans Michez *et al.*, (2016). La Figure 2.6 illustre les différentes échelles d'estimation des hauteurs du couvert de la végétation.

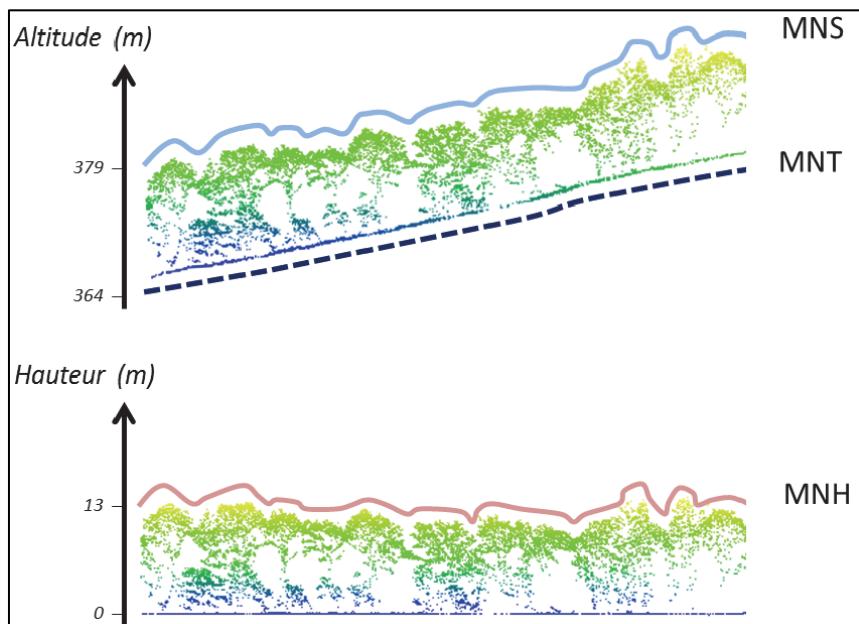


Figure 2.5. Sous-produits d'un nuage de points LiDAR aérien à retour discret en zone forestière : cas du modèle numérique de terrain (MNT), du modèle numérique de surface (MNS) et du modèle numérique de hauteur (MNH). Le MNH est issu de la soustraction du MNS et du MNT (Tiré de Michez *et al.*, 2016, p. 328)

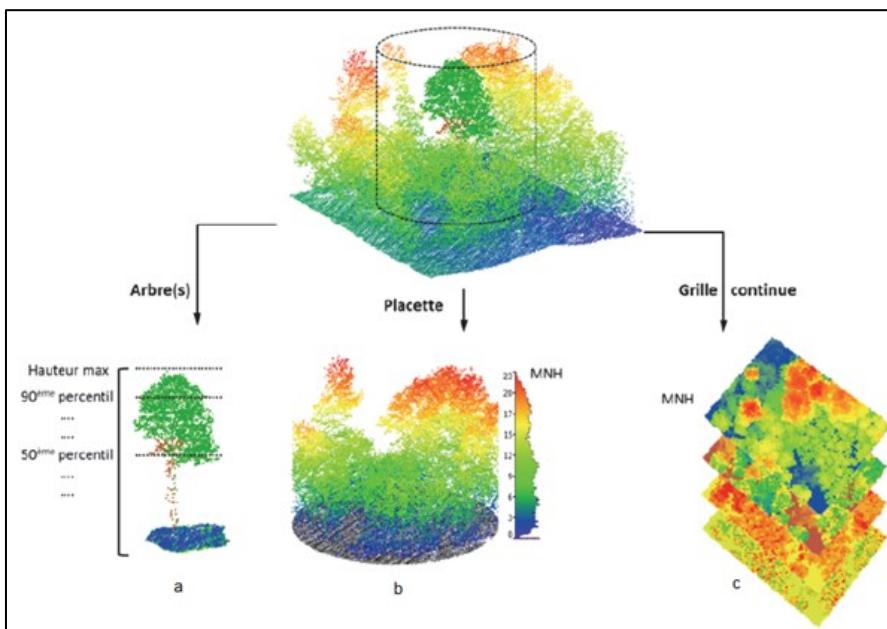


Figure 2.6. Extraction des variables obtenues à partir d'un nuage de points LiDAR selon trois échelles : arbre (a), placette (b) ou production de données raster (c). Ces variables sont principalement des paramètres statistiques calculés sur la base de la distribution en hauteur des points : hauteur maximale, percentile de la hauteur (90^e, 50^e) (Adapté de Michez *et al.*, 2016, p. 329).

La BA peut être estimée avec les approches axées sur la parcelle de forêt ou sur les arbres individuels (ou cime d'arbre) à l'aide des données LiDAR. L'approche de la parcelle de forêt consiste à dériver régulièrement les mesures des hauteurs de la canopée, du nombre de retours LiDAR et des ratios de retours à partir des données LiDAR présentes sur la superficie de la parcelle pour estimer la BA à l'échelle de la zone d'étude. Ces hauteurs sont calculées en fonction du premier, du dernier ou de tous les retours LiDAR (Gleason et Im, 2012 ; Kumar *et al.*, 2015 ; Coops *et al.*, 2021). Elles peuvent aussi être déterminées à l'aide des grilles du modèle de hauteur de la canopée au niveau de la zone d'étude. Compte tenu du lien bien connu entre la hauteur et la biomasse, le LiDAR offre un excellent potentiel pour l'estimation de la biomasse. Cependant, dans les forêts denses et complexes, les premiers retours du LiDAR, notamment à retour discret, sont susceptibles de ne pas pénétrer en profondeur la canopée. Cela limiterait la description précise des caractéristiques des attributs de la forêt comme la hauteur de la canopée. L'approche basée par arbre identifie les cimes des arbres individuels et extrait les informations sur ces arbres à partir du nuage de points LiDAR (ex. la hauteur des arbres). Celles-ci peuvent ensuite être liées à la biomasse et à d'autres variables de la structure de la canopée en utilisant les approches statistiques (Gleason et Im, 2012; Kumar *et al.*, 2015; Coops *et al.*, 2021). Cette approche peut être efficace dans certains types de peuplement homogène où les cimes sont bien dégagées et faciles à délimiter. Cela n'est pas le cas souvent dans les forêts denses et complexes, comme les forêts tropicales humides.

En général, les mesures structurelles de la forêt dérivées à partir des données LiDAR estiment avec précision les attributs des forêts (ex : hauteur de la canopée et BA) dans les forêts à BA élevée. Ce qui est difficile avec les données de télédétection optique passive (Kumar *et al.*, 2015). Les systèmes LiDAR ont la capacité de dériver de manière plus précise les attributs de des forêts à la fois horizontalement et verticalement, contrairement aux données de télédétection optique passive qui fournissent davantage des mesures des distributions horizontales (Vazirabad et Karslioglu, 2011; Gopalakrishnan *et al.*, 2015; Kumar *et al.*, 2015). L'exploitation des formes d'onde complètes dérivées des LiDAR améliore grandement les précisions des résultats (Vazirabad et Karslioglu, 2011 ; Coops *et al.*, 2021). La problématique majeure de l'utilisation du LiDAR réside dans les coûts, même s'il y a une diminution marquée au fil du temps. Cela provient du fait que les acquisitions LiDAR se font essentiellement à partir des plateformes aéroportées, qui couvrent de petites zones à la fois. Les LiDAR satellitaires (*Ice, Cloud and Land Elevation Satellite* (ICESat), ICESat-2/ATLAS) ont été mis en orbite surtout pour le suivi des calottes glaciaires dans les régions polaires. Néanmoins, des études ont été faites sur l'estimation de la BA aux échelles régionales et continentales, compte tenu des résolutions grossières des données (Vazirabad et Karslioglu, 2011; Coops *et al.*, 2021). Il existe également un LiDAR à haute résolution à bord de la Station spatiale internationale, dénommé GEDI (*Global Ecosystem Dynamics Investigation*), dont une des missions est de permettre une meilleure caractérisation des forêts, notamment tropicales (Coops *et al.*, 2021).

D'une manière générale, les systèmes LiDAR ont contribué à produire des incertitudes relativement faibles pour l'estimation de la BA des forêts dans le monde. Par exemple, de faibles erreurs (%RMSE < 20 %) ont été observées lors de l'estimation des BA de la forêt de Tahe dans la province du Heilongjiang en Chine à l'aide des hauteurs dérivées des données LiDAR ICESat GLAS (*Geoscience Laser Altimeter System*) (Chi *et al.*, 2015). Sun *et al.*, (2011) ont évalué la BA des forêts d'Howland (Maine, USA) avec des erreurs négligeables (%RMSE = 19,5 %) en utilisant des mesures de hauteurs dérivées du LiDAR aéroporté du capteur d'imagerie laser de la végétation (LVIS). Dans les forêts tropicales denses de la péninsule du Yucatan au Mexique, Urbazaev *et al.*, (2018) ont estimé la BA avec des erreurs relativement faible (%RMSE comprise entre 20 et 40%) à l'aide des métriques dérivées de données LiDAR aéroporté à retour discret. Les données combinées de LiDAR, radar ou optique participent également à la réduction des erreurs d'estimation de la BA de l'ordre de 12 à 38 %, comme rapporté dans (Montesano *et al.*, 2013).

2.2.3 Estimation de la biomasse à partir des données PolInSAR

Les longueurs d'onde du domaine des micro-ondes (X-2,4-3,75 cm, C-3,75-7,5 cm, L-15-30 cm et P-30-100 cm) sont utilisées dans la télédétection active radar pour l'étude de la végétation. La bande X a une interaction avec les feuilles et la surface de la canopée. La bande C pénètre et traverse les feuilles puis les petites branches la dispersent, tandis que la bande L pénètre plus à travers les feuilles par rapport à la C et est propagée par le tronc et les branches principales. Au-delà des trois bandes, il existe également la bande P. Celle-ci a la plus grande capacité de pénétration de la canopée, pouvant atteindre le sol et les racines principales des arbres. Les bandes L et P offrent les meilleurs potentiels pour l'estimation des attributs biophysiques des arbres et de la BA (Ghasemi *et al.*, 2011; Sinha *et al.*, 2015 ; Yadav *et al.*, 2020; Cartus et Santuro, 2019; Waqar *et al.*, 2020; Shi *et al.*, 2021).

Dans la télédétection active, le radar à synthèse d'ouverture (SAR) est la technique généralement utilisée pour émettre et recevoir le signal micro-onde sur les cibles terrestres. L'un des gros avantages du radar, c'est cette capacité d'acquérir des données en continu dans diverses conditions météorologiques sur de vastes territoires même couverts de nuage (Xiao *et al.*, 2019). Cette technologie devient donc particulièrement utile dans les régions tropicales humides où la couverture nuageuse est quasi permanente. SAR est un système radar cohérent à vue latérale pour générer des images à haute résolution (Yadav *et al.*, 2021). Le principe est basé sur la mesure de la rétrodiffusion dans la longueur d'onde, la polarisation et la gamme d'angles d'incidence considérée. Le coefficient de rétrodiffusion résultant désigne la mesure normalisée du signal radar retourné par une cible distribuée. Ainsi, les coefficients de rétrodiffusion issus des images SAR en polarisation horizontale (H), verticale (V) ou croisée (VH) varient en fonction des caractéristiques des cibles terrestres (humidité, structure, rugosité, etc.) et des géométries d'acquisition (angle d'incidence). Ces coefficients peuvent s'avérer très intéressants dans la caractérisation des couvertures végétales, incluant l'estimation de BA (Sinha *et al.*, 2015). L'évolution des technologies a permis le développement de méthodes d'acquisition de données radar, plus sophistiquées, combinant les techniques SAR polarimétriques (PolSAR) et interférométriques (InSAR), connues sous l'appellation PolInSAR (Sinha *et al.*, 2015 ; Shi *et al.*, 2021; Yadav *et al.*, 2021). Les coefficients de rétrodiffusion issus des données PolSAR permettent de différencier les diffuseurs alors que InSAR établit la relation entre la cohérence interférométrique et la distribution verticale des diffuseurs (Yadav *et al.*, 2021). Ce faisant, avec les données PolInSAR, il devient possible de disposer en même temps des coefficients de rétrodiffusion polarimétriques, mais également de l'information sur la

hauteur des cibles. Ceci est particulièrement d'une grande importance pour les couvertures forestières, car il permet d'obtenir une des variables les plus critiques dans l'estimation de la BA, qui est la hauteur des arbres, avec des informations additionnelles sur les différents mécanismes de diffusions (surface, volume) à travers les coefficients de rétrodiffusion.

L'estimation des paramètres à l'aide des données PolInSAR repose sur la prise en compte de la cohérence interférométrique. Cette cohérence γ exprime la similitude de deux images radar observées à l'aide d'une géométrie identique (Brigot *et al.*, 2019). Celle-ci est mesurée en termes de décorrélation à plusieurs dimensions, incluant celle due au système (γ^{syst}), à la géométrie ($\gamma^{\text{géo}}$), au temps (γ^{temp}) et au volume (γ^{vol}). La décorrélation est décomposée avec un modèle multiplicatif. Dans le contexte polarimétrique, elle est généralisée pour des états de polarisation p et q en émission et réception (Papathanassiou et Cloude, 2001; Garestier, 2006; Villard *et al.*, 2016 ; Ferro-Famil et Pottier, 2016) :

$$y_{pq} = y^{\text{syst}} \cdot y^{\text{géo}} \cdot Y^{\text{temp}} \cdot Y^{\text{vol}} \quad (2.10)$$

La littérature présente les détails sur les processus d'estimation du coefficient de rétrodiffusion (Agrawal *et al.*, 2019) et de la hauteur des arbres (Kumar *et al.*, 2020) à l'aide des données PolInSAR. Différents modèles d'inversion ont été développés dans ce sens (Schlund et Davidson, 2018; Agrawal *et al.*, 2019; Sun *et al.*, 2019). Pour les canopées forestières, les modèles utilisés peuvent se regrouper en trois approches, incluant les modèles de base, les modèles optimisés (ou de traitement de l'information) et les modèles de réduction des problèmes de décorrélation.

Les modèles de base n'intègrent pas les contributions de la diffusion au sol et de la décorrélation temporelle. Ces modèles s'appliquent mieux sur des sols plats. À titre d'exemple, on peut citer le modèle *Random volume over ground* ou RvG (Treuhhaft *et al.*, 1996; Cloude et Papathanassiou, 1998) et le *water cloud model* (WCM) (Attema et Ulaby, 1978; Agrawal *et al.*, 2019). En considérant le modèle RvG, le comportement de la diffusion de la forêt est en général modélisé comme une couche d'épaisseur de hauteur végétale contenant un volume avec des particules orientées au hasard sur un diffuseur au sol (Lu *et al.*, 2013). Ce modèle décrit le profil de rétrodiffusion verticale de la forêt ou la couche de volume avec une fonction exponentielle (Treuhhaft *et al.*, 1996; Schlund et Davidson, 2018; Sun *et al.*, 2019). WCM est un modèle de diffusion, qui considère la canopée comme un « nuage d'eau » contenant des gouttelettes d'eau identiques réparties de manière aléatoire dans la canopée de la forêt. Avec ce modèle, la couche de végétation est supposée être comme une collection de particules sphériques identiques, uniformément réparties dans toute la couche de volume. Ce modèle

définit le coefficient de rétrodiffusion en fonction de trois paramètres cibles : la teneur en humidité volumétrique du sol, la teneur en eau volumétrique de la végétation et la hauteur de la plante (Attema et Ulaby, 1978; Agrawal *et al.*, 2019; Park *et al.*, 2019). Les modèles optimisés réduisent les problèmes de contribution de la diffusion du sol pour améliorer les estimations de la hauteur de la forêt dérivées des données PolInSAR. À titre d'exemple, le modèle *sloped random volume over Ground* (S-RvoG) est une variante du modèle RvoG dans laquelle la pente est intégrée comme information additionnelle (Lu *et al.*, 2013; Sun *et al.*, 2019). Ce modèle sépare les contributions du sol et de la canopée pour améliorer les estimations de la hauteur de la forêt à partir des données PolInSAR. Les erreurs d'estimation rapportées sont nettement inférieures à celles du modèle RvoG (environ 12 % contre 41 %) d'après Sun *et al.*, (2019). Dans la même optique, WCM a été transformé en *extended* WCM (EWCM) pour prendre en compte la diffusion depuis le sol et améliorer la précision de l'estimation de la BA (Agrawal *et al.*, 2019). Ces auteurs rapportent une précision de l'ordre de 72 % pour la BA estimée en appliquant EWCM sur des données PolInSAR (Agrawal *et al.*, 2019).

La troisième approche porte en général sur les modèles relativement complexes, qui visent à réduire les problèmes de décorrélation temporelle dans les données PolInSAR. En effet, les modèles de diffusion de base comme le RvoG ne prennent pas en compte les changements dynamiques de la cible entre deux acquisitions d'images. Ces changements, dus par exemple à l'effet du vent, peuvent affecter la localisation et les propriétés des diffuseurs effectifs de la cible, et réduire en général la corrélation entre les images acquises. Cela se traduit par la suite par des erreurs ou des biais dans l'estimation des paramètres, notamment de la hauteur des forêts. Pour réduire ces effets, les modèles proposés associent les modèles de base à des approches prenant en compte la décorrélation temporelle. Dans le cas de l'étude des forêts, le RvoG est associé à une approche de décorrélation temporelle du volume (*Random Volume over Ground with Volume Temporal Decorrelation model* (RvoG + VTD), Shi *et al.*, 2021). D'autres combinaisons existent, notamment en considérant la décorrélation temporelle comme fonction du mouvement physique des diffuseurs (Shi *et al.*, 2021).

Selon différentes études recensées pour diverses forêts (particulièrement tropicales), les erreurs (%RMSE) d'estimation de la BA à l'aide d'approches utilisant des variables dérivées des données PolInSAR (hauteur de la canopée ou rétrodiffusion) varient entre 9,4 % et 24,33 % (Schlund et Davidson, 2018; Liao *et al.*, 2019; Yadav *et al.*, 2021; Mukhopadhyay *et al.*, 2021). Les meilleurs résultats sont obtenus en combinant la hauteur inversée à partir du modèle RvoG à d'autres variables de télédétection. Par exemple, Yadav *et al.*, (2021) rapportent un %RMSE

de l'ordre de 14 % sur l'estimation de la BA de forêts tropicales en Inde, en combinant la hauteur provenant de l'inversion du modèle RvoG à la cohérence interférométrique, au coefficient de rétrodiffusion, ainsi qu'à des indices de texture GLCM. Bien évidemment, plusieurs facteurs (ex. le type de variable dérivée des données PolInSAR, le type de modèle d'inversion, le choix de combinaisons des variables, etc.) peuvent affecter les résultats des estimations.

Malgré leur très grand potentiel pour l'estimation de la BA, il n'existe pas encore une grande disponibilité des données PolInSAR. Celles-ci sont actuellement acquises sur des zones relativement petites (Cartus et Santoro, 2019 ; Xiao *et al.*, 2019). Pour surmonter cette limite, les espoirs reposent désormais sur la mise en œuvre des missions spatiales utilisant la bande P (*European Space Agency, ESA*) BIOMASS Earth Explorer and Tandem-L. D'ailleurs, des études expérimentales démontrent que la combinaison des bandes P et L contribue à l'amélioration des estimations de la BA (Schlund et Davidson, 2018; Shi *et al.*, 2021).

2.2.4 Estimation de la biomasse avec l'approche MARS

Différentes approches mathématiques sont souvent utilisées pour estimer les BA des végétaux chlorophylliens à partir des données de télédétection (Kumar *et al.*, 2015). Ces approches comprennent entre autres des réseaux de neurones artificiels, les méthodes random forest, *support vector machine*, ou k plus proche voisin, etc. Ces diverses méthodes d'apprentissage machine participent à réduire les problèmes (d'incertitudes, d'imprécisions, d'incomplétude des données et de conflit entre les sources de données) liés à la fusion des données. Elles sont utilisées avec divers types de données (télédétection ou autres) plus ou moins complexes. Selon plusieurs études, certaines de ces méthodes (ex : *random forest* et réseaux de neurones artificiels) ont souvent montré de faibles performances par rapport à MARS dans l'estimation de plusieurs paramètres (Pramila and Mahesh 2015 ; Park *et al.*, 2017 ; Li *et al.*, 2019). Dans ce contexte ici, nous présentons en particulier l'approche MARS, puisqu'elle sera utilisée plus tard dans nos travaux de modélisation. La technique MARS, non paramétrique (Vaglio-Laurin *et al.*, 2016), modélise les interactions et la non-linéarité des données de grande dimension ou multidimensionnelles (Friedman, 1991 ; Piikki *et al.*, 2019). MARS fonctionne mieux avec des variables écologiques composées de données non-linéaires (García Nieto *et al.*, 2012 ; García Nieto *et al.*, 2019), en établissant des relations entre les variables dépendantes et explicatives. Pour y parvenir, l'espace des prédicteurs est divisé en plusieurs nœuds pour ajuster une fonction spline entre ces nœuds. MARS recherche tous les nœuds ou les emplacements des points de

jonction possibles univariés et les interactions entre toutes les variables. La Figure 2.7 présente un modèle linéaire ordinaire et des noeuds / splines linéaires du modèle non linéaire développé avec MARS. L'algorithme MARS obtient par la suite les fonctions de base et les combine pour déterminer le modèle (Friedman, 1991 ; Oduro *et al.*, 2015). Ce modèle comporte une constante, et une fonction de base ou fonction charnière (sans interactions des variables explicatives). Dépendant de la complexité de la relation, des termes d'interactions, composés de produits de fonctions charnières, peuvent s'avérer nécessaires. Le modèle MARS est ainsi composé d'un ensemble de fonctions charnières constituées des variables indépendantes. La forme mathématique générale de MARS est une somme de fonctions de base, déclinée ci-dessous (López-Serrano *et al.*, 2016) :

$$f(x) = \beta_0 + \sum_{m=1}^M \beta_m K_m(x) \quad (2.11)$$

où β_0 est la constante du modèle, $K_m(x)$ est l'une des fonctions de base, β_m est l'un des coefficients constants de la fonction de base et M est le nombre de fonctions de base dans le modèle. Chaque fonction de base $K_m(x)$ consiste en une fonction charnière de la forme $\max(0, x-k)$ ou $\max(0, k-x)$, où k est une valeur constante. Cette formulation prend en compte les effets individuels des variables indépendantes plus ceux résultant des interactions entre deux ou plusieurs prédicteurs (x) (Zhang et Goh, 2016). Plus de détails sont disponibles dans Friedman (1991) ou Oduro *et al.*, (2015) sur la façon dont les fonctions sont établies par itérations successives, incluant l'identification automatique des variables indépendantes les plus pertinentes et les interactions les plus significatives entre elles.

A la suite de la détermination du modèle et de son amélioration par itération, la deuxième étape est l'élagage. C'est une procédure d'élimination des fonctions de base ayant les plus faibles contributions au modèle (Zhang et Goh, 2016). L'élagage repose sur le critère de validation croisée généralisée (GCV). Le modèle optimal est celui qui présente le GCV le plus bas. GCV est calculé à l'aide de l'expression mathématique suivante (López-Serrano *et al.*, 2016) :

$$GCV(M) = \frac{\sum_{i=1}^n (y_i - f_M(x_i))^2}{n(1 - \frac{P_M}{n})^2} \quad (2.12)$$

où y_i sont les valeurs observées de la variable indépendante, n est le nombre d'observations, $f_M(x_i)$ est le modèle MARS avec les fonctions de bases M , x sont les valeurs observées des prédicteurs inclus dans le modèle MARS et P_M est le nombre de paramètres du modèle MARS.

La figure 2.8 illustre le processus de production des modèles MARS.

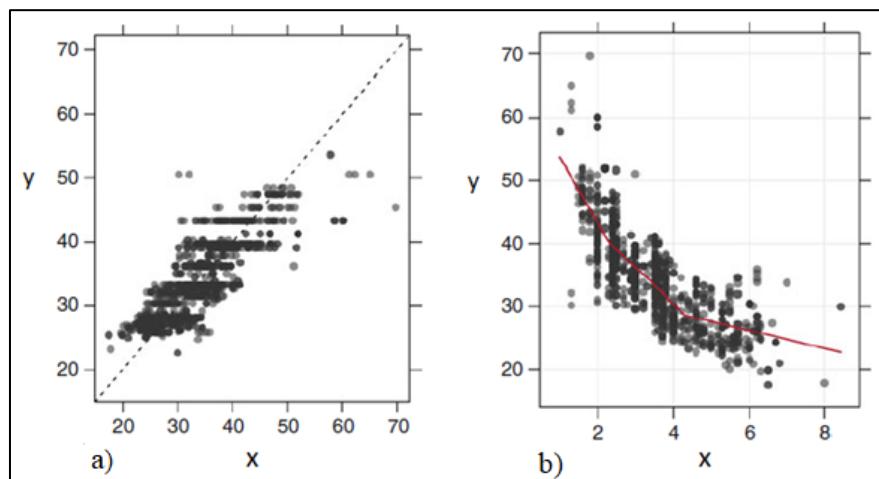


Figure 2.7. Illustration d'un modèle linéaire ordinaire des observés de terrain (a) et du modèle non linéaire issus de MARS à l'aide des données identiques (b). Les valeurs élevées de y du modèle linéaire (Figure 2.7a) montrent que les relations entre y et x pourraient être non linéaires. Ces valeurs s'écartent de la ligne de régression alors que les valeurs faibles se concentrent autour de la ligne de régression. En observant les valeurs y du modèle MARS, la Figure 2.7b révèle des relations non-linéaires entre y et x. Trois formes de plis ou nœuds (2,3 ; 3,5 et 4,3) sont constatés dans les valeurs y prédictes pour représenter la non-linéarité. Ces nœuds délimitent trois intervalles où diverses relations linéaires sont identifiées (Zhang et Goh, 2013). (Tiré de Kuhn et Johnson, 2013, p. 23).

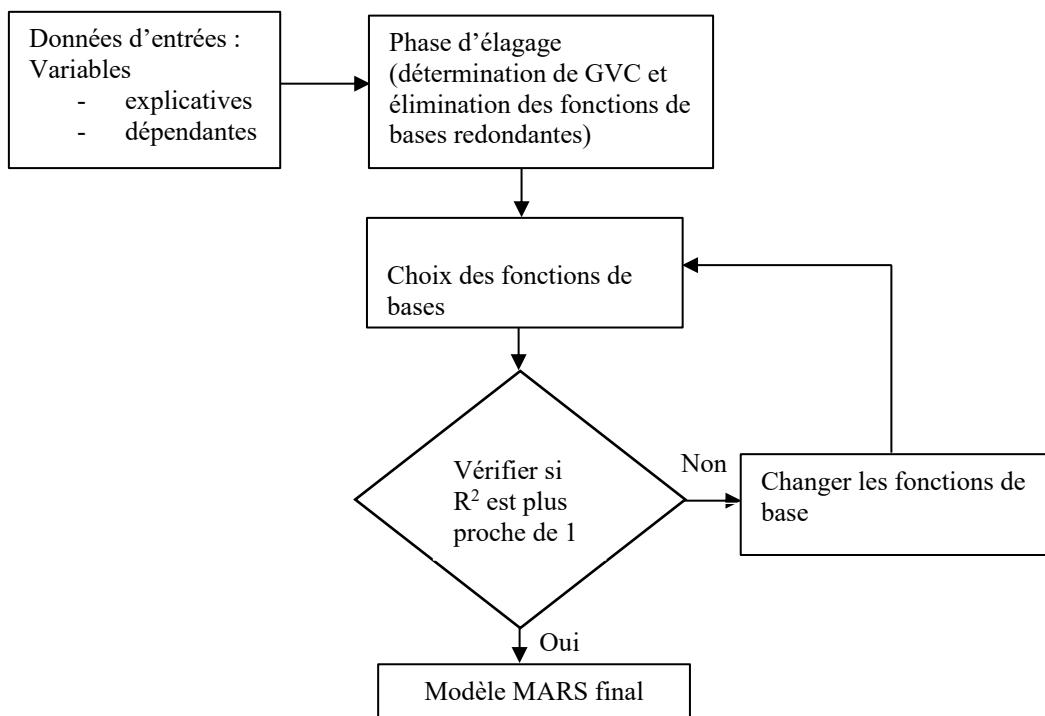


Figure 2.8. Schéma de fonctionnement de MARS (Adapté d'Oduro *et al.*, 2015, p. 5)

L'approche MARS a plusieurs mérites comme méthode d'apprentissage machine. Cette approche a l'avantage de construire des modèles avec des fonctions de base capables de prédire avec précision la variable cible. Chaque fonction de base contribue à améliorer la précision de la variable cible. Seule, chacune des fonctions de base qui apporte une contribution individuelle

significative au modèle est retenue par MARS. Cet apport participe à identifier les variables pertinentes d'entrée, à les transformer et à établir les interactions pour renforcer la robustesse du modèle. MARS peut aussi intégrer aux modèles additifs (fonctions de base sans interaction) les fonctions de base avec interactions plus ou moins complexes. Cette association des deux types de fonction de base permet au modèle de saisir la diversité des informations fournies par les variables explicatives et de les imbriquer dans le modèle. Les modèles MARS sont également capables de ne pas sous-estimer ou surestimer la variable cible. Cela permet aux modèles de fournir des approximations précises de la variable cible. Les modèles MARS ont en outre le privilége d'être simples, faciles à interpréter et uniques sur la base des données complexes et de grande dimension. Cela contribue beaucoup à leur utilisation et leur identification. L'un des inconvénients de MARS est le développement de fonctions MARS avec une absence d'effet d'interactions entre les variables. Cela se produit généralement à cause de la petite taille de l'échantillon ou du manque d'autres variables utiles permettant de mieux décrire les interactions (Friedman, 1991; Li *et al.*, 2009; Li *et al.*, 2019). En tenant compte des différents avantages, l'approche MARS pourrait s'avérer efficace pour l'estimation de la BA, en particulier dans les milieux forestiers complexes, comme dans les forêts tropicales (Vaglio Laurin *et al.*, 2016; López-Serrano *et al.*, 2016; Zhang *et al.*, 2020).

CHAPITRE 3. Sites et données de l'étude

3.1 Sites de l'étude

Deux sites sont considérés dans la présente étude pour atteindre les objectifs de l'étude : 1) site de la plantation des palmiers à huile et 2) site des forêts. Ces deux sites sont localisés au Gabon, pays d'Afrique centrale, couvert des forêts du Bassin du Congo. Le territoire de ce pays est reparti du 2^e degré de latitude nord au 4^e degré de latitude sud et du 9^e au 15^e degré de longitude ouest. Le premier site d'étude a une superficie de 25 ha et est localisé entre les longitudes 10°24'27" E et 10°24'57" E, et les latitudes 0°30'6" S et 0°30'16" S (Figure 3.1). Ce site correspond à un bloc de la plantation agro-industrielle des palmiers à huile de la société Olam Palm Gabon (OPG). Les palmiers du bloc étaient matures (35 ans) et ont été plantés dans des zones sèches et inondées (Figure 3.1). Ce site est considéré pour sa disponibilité en données indispensable à l'estimation et l'analyse de la dynamique des BA des palmiers à huile. Le deuxième site a une superficie de 8092 ha. Celui-ci est compris entre les longitudes 9°18'42,29" E et 9°25'53,10" E puis les latitudes 0°35'19,72" N et 0°32'1,58" N (Figure 3.2). Ce site inclut partiellement une zone de conservation, l'Arboretum Raponda Walker (ARW), administré par l'Agence Nationale des Parcs Nationaux (ANPN). Il contient principalement des forêts matures, secondaires et des zones des forêts inondables incluant les mangroves (Goïta *et al.*, 2017). Il est facilement accessible et situé au Nord de Libreville à 25 km du Cap Estérias. Il regorge de basses altitudes atteignant 41 m. Dans ce site d'étude, il existe quelques vallées en allant vers la côte dans la zone Nord-Ouest de l'ARW. Les zones Est, Sud et Nord-Est du site sont davantage caractérisées par les plaines basses et marécageuses avec des plateaux sableux. Ce site est utilisé pour ses données utiles à l'atteinte des objectifs 2 et 3 de la présente étude.

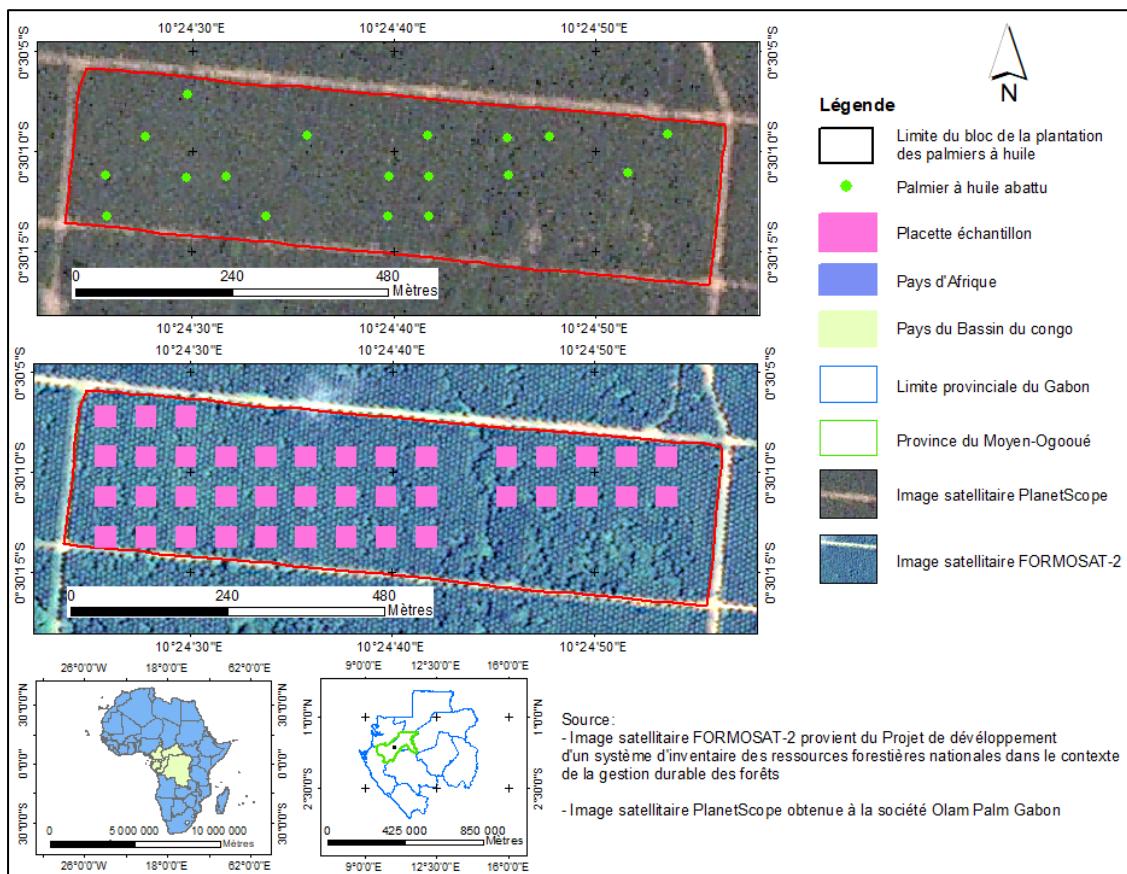


Figure 3.1. Zone d'étude des palmiers à huile

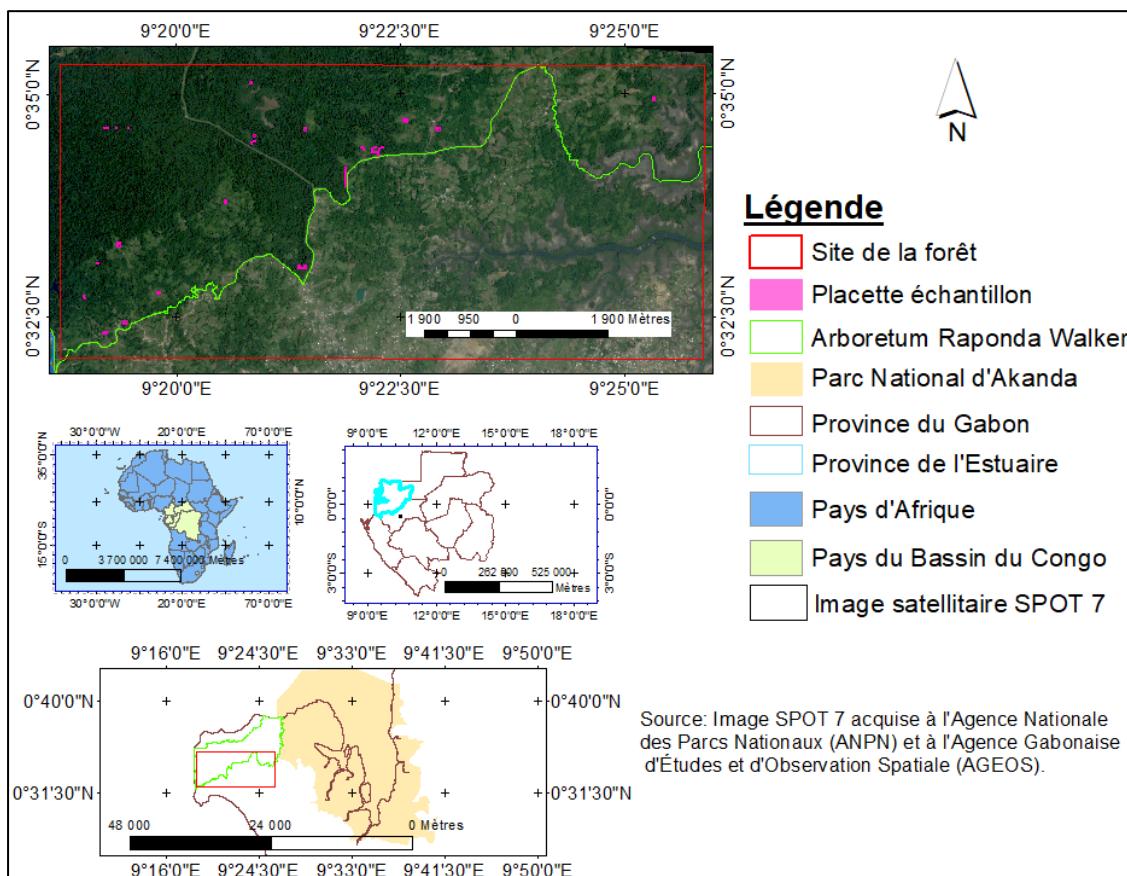


Figure 3.2. Zone d'étude des forêts

3.2 Données collectées

3.2.1 Données *in situ*

Les données *in situ* ont été catégorisées en 3 groupes : 1) Les données *in situ* des palmiers à huile abattus ; 2) les données *in situ* des palmiers à huile sur pied ; et 3) les données *in situ* des arbres sur pied de la forêt.

3.2.1.1 Données *in situ* des palmiers à huile abattus

Les données *in situ* des palmiers à huile abattus ont été acquises sur le terrain et au laboratoire. Au cours de la présente étude, nous avons abattu 18 palmiers à huile afin de mesurer leurs attributs. Sur le terrain, les attributs relevés sont les DHP, les hauteurs totales (H_{TOT} , en m) ou de la tige (H_T , en m), le nombre de feuilles (N_F) et les biomasses fraîches des différents compartiments d'un palmier à huile (tige, pétioles, fruits, rachis et folioles). Des échantillons frais ont aussi été prélevés sur chaque compartiment d'un palmier à huile et ont ensuite été pesés sur le terrain. Au niveau du laboratoire, plusieurs paramètres ont été déterminés. Il s'agit par exemple de la biomasse d'un échantillon séché (B_{ES} , en g), la fraction de masse sèche (fms), la BA, l'infra-densité du bois de la tige de palmier à huile. Dans la présente étude, les paramètres structurels des palmiers (DHP, H_{TOT} , H_T , N_F et ρ) ont été liés aux biomasses aériennes fraîches totales (B_{AF}) ou BA pour développer des modèles de biomasse de terrain avec les équations allométriques (section 2.1.2). Le Tableau 3.1 résume les méthodes ou outils utilisés, ainsi que les caractéristiques des mesures prises sur le terrain.

3.2.1.2 Données *in situ* des palmiers à huile sur pied

Des mesures *in situ* ont également été effectuées sur les palmiers à huile sur pied. Elles concernent notamment les paramètres structuraux (DHP, H_{TOT} et H_T), le nombre de palmiers à huile (N_P), la densité des palmiers à huile du bloc de la plantation (D, en tige par hectare) et la surface terrière (ST , en $m^2 ha^{-1}$). Les différentes mesures ont été prises dans 40 placettes échantillons. Celles-ci ont été échantillonnées sur une base systématique. Les placettes avaient une dimension de 30,8 m × 30,8 m (voir Tableau 3.1).

3.2.1.3 Données *in situ* des arbres sur pied de la forêt

Les données *in situ* des arbres sur pied de la forêt de la présente étude ont d'abord été collectées dans la base de données de la campagne AfriSAR de 2016 organisée par la NASA en collaboration avec l'AGEOS et l'Agence Européenne Spatiale (ESA). Les données de cette

campagne sont accessibles au public depuis 2018 via le site Web de la NASA ORNL DAAC (Fatoyinbo *et al.*, 2018). Dans la présente étude, 14 placettes échantillons de 1 ha de cette campagne ont été considérées. Une grille de résolution spatiale de 30,8 m × 30,8 m a été superposée sur la zone correspondant à l'emplacement de ces 14 placettes échantillons. En considérant cette grille, 45 placettes échantillons de 30,8 m × 30,8 m ont été sélectionnées aléatoirement. Les données de la campagne AfriSAR ont été extraites dans les 45 placettes échantillons. Celles-ci ont été constituées des BA estimées avec l'équation de Chave *et al.*, (2014), des DHP mesurés, des hauteurs maximales modélisées des arbres (H_M , en m) et du nombre total d'arbres (Na) (Fatoyinbo *et al.*, 2018).

Pour compléter les données de la campagne AfriSAR, nous avons mis en place dans le cadre de cette étude 26 placettes échantillons supplémentaires d'une dimension de 30,8 m × 30,8 m chacune. Ces placettes ont été positionnées aléatoirement sur le terrain en forêt tropicale. Ainsi, 75 placettes échantillons ont été utilisées au total sur la forêt dans le cadre de cette recherche. Les variables forestières usuelles ont été mesurées dans chaque placette (DHP, hauteur, nombre d'arbres). Le nom botanique scientifique de chaque arbre inventorié a aussi été identifié, en plus de son espèce, son genre et sa famille. La densité de bois de chaque arbre a enfin été recensée dans une base de données existante (Tableau 3.1). Ces différentes données collectées ont permis de développer les modèles de BA par télédétection (section 2.2).

Tableau 3.1. Caractéristiques des données *in situ* de la thèse

Paramètre	Mode d'acquisition	Description	Méthode ou outil utilisé pour acquérir les valeurs du paramètre
Données <i>in situ</i> des palmiers à huile abattus			
Terrain			
Diamètre à hauteur de poitrine (DHP mesuré à 1,3 m au-dessus du sol, en cm)		Paramètre structural du palmier à huile (PSPH)	Ruban diamétrique
Hauteur de la tige (H_T , en m)			
Hauteur totale (H_{TOT} , en m)			
Nombre de feuilles (N_F)			Comptage manuelle
Biomasse fraîche de la portion d'un compartiment d'un palmier à huile (tige, folioles, pétioles, rachis et fruits) (B_{FP} , en kg)			B_{FP} = Masse fraîche de la portion d'un compartiment d'un palmier à huile pesée sur le terrain
Biomasse fraîche totale d'un compartiment d'un palmier à huile (B_{FT} , en kg)		Attribut du palmier à huile (APH)	B_{FT} = somme des B_{FP} de toutes les portions d'un compartiment d'un palmier à huile
Biomasse aérienne fraîche totale (BA_F , en kg)			BA_F = somme des B_{FT} de tous les compartiments d'un palmier à huile
Biomasse d'un échantillon frais d'un compartiment d'un palmier à huile (BE_F , en g)			BE_F = Masse d'un échantillon frais d'un compartiment d'un palmier à huile pesée sur le terrain
Laboratoire			
Biomasse d'un échantillon séché d'un compartiment	Mesure de laboratoire	APH	B_{ES} = Masse d'un échantillon séché d'un compartiment d'un palmier à huile pesée au laboratoire

d'un palmier à huile (B_{ES} , en g)			
Fraction de masse sèche de chaque compartiment échantillonné d'un palmier à huile (fms)			fms équivaut à la moyenne des fms des échantillons prélevés sur le même compartiment d'un palmier à huile (cf. équation 2.1 section 2.1.1)
Biomasse sèche d'une portion d'un compartiment d'un palmier à huile (B_p , en kg)			$B_p = \text{multiplication de } B_{FP} \text{ par sa (fms) correspondante (cf. équation 2.2 section 2.1.1)}$
Biomasse sèche totale de chaque compartiment d'un palmier à huile (B_C , en kg)			$B_C = \text{somme de tous les } B_p \text{ d'un même compartiment d'un palmier à huile (fms) correspondante (cf. équation 2.3 section 2.1.1)}$
La biomasse aérienne sèche totale (BA, en kg)			$BA = \text{somme de toutes les } B_C \text{ (cf. équation 2.4 ; section 2.1.1)}$
Volume saturé d'un aliquote frais d'un billon de bois ($V_{\text{aliquote frais}}$, en cm^{-3})			$V_{\text{aliquote frais}}$ a été déterminé par la pesée hydrostatique suivant le protocole de Bauwens et Fayolle (2014) (cf. section 2.1.1)
Infra-densité (ρ , en g cm^{-3})			ρ correspond à la moyenne des ρ des échantillons de bois prélevés sur des billons de la tige d'un palmier à huile (cf. équation 2.5 section 2.1.1)

Données *in situ* des palmiers à huile sur pied

DHP	Mesure de terrain	PSPH	Ruban diamétrique
H _T			Vertex IV associé à un transpondeur 3
Nombre de palmiers à huile (N_p)		APH	Comptage manuelle dans la placette échantillon de 30,8 m × 30,8 m
Densité des palmiers à huile du bloc de la plantation (D, en tige par hectare)			D = Rapport du nombre total de palmiers à huile (N_p) sur la surface de chaque placette échantillon (en ha)
Surface terrière (ST, en $\text{m}^2 \text{ha}^{-1}$)			ST = Surface de la coupe transversale d'une tige de palmier mesurée à 1,3 m au-dessus du sol ($(\pi \times DHP^2) / 4$). ST globale ou moyenne = somme de toutes les surfaces terrières des palmiers à huile intégrés dans chacune des placettes échantillons

Données *in situ* des arbres sur pied de la forêt

Diamètre à hauteur de poitrine (mesuré à 1,3 m au-dessus du sol, en cm) (DHP)	Mesure de terrain	Paramètre structural de l'arbre de la forêt	Mesure des DHP ≥ 10 cm avec un ruban diamétrique
Hauteur maximale modélisée de l'arbre (H _M , en m)	Mesure estimée		H _M dérivée avec l'équation locale de Labriere <i>et al.</i> , (2018) établissant la relation entre DHP et la hauteur totale de l'arbre : $H_M = (53,679 \times DHP) / (34,022 + DHP)$
Nombre total d'arbres (Na)	Mesure de terrain	Attribut de l'arbre de la forêt (AAF)	Comptage manuel
Densité du bois (ρ , en g cm^{-3})	Mesure existante		Recension de ρ de chaque arbre dans la base de données du Centre international pour la recherche en agroforesterie (ICRAF) (http://db.worldagroforestry.org/)
BA, H _M , DHP et Na	Mesure existante		Extraction des données de l'étude de la base de données de la campagne AfriSAR de 2016 du site d'étude de la forêt (ancienne forêt classée de Mondah) (https://doi.org/10.3334/ORNLDAAAC/1580)

9.4.3 Données de télédétection

Les données de télédétection de l'étude sont constituées des données optiques (indices de texture), LiDAR et PolInSAR. Toutes ces données ont été extraites à partir des placettes échantillons de 30,8 m × 30,8 m. Plusieurs logiciels ont été utilisés dans les traitements et l'analyse des données, incluant Geomatica, Statistica, Excel, Matlab, etc. Les détails apparaissent les trois articles constitutifs de la thèse.

3.2.2.1 Données optiques

Les variables d'intérêt ont été extraites des images satellitaires optiques couvrant les sites des palmiers à huile (Figure 3.1) et de la forêt (Figure 3.2). Pour l'étude de la biomasse des palmiers à huile, deux types d'images ont été utilisés pour extraire les indices FOTO. Il s'agit de FORMOSAT-2 et PlanetScope. FORMOSAT-2 a été obtenue auprès du projet de développement d'un système d'inventaire des ressources forestières nationales contribuant à la gestion durable des forêts (DSIRFN). PlanetScope a été fournie par la société Olam Palm Gabon. Une image SPOT 7 a été utilisée sur le site de la forêt pour extraire les indices de texture GLCM, et les indices FOTO (section 2.2.1.1). Cette image a été fournie par l'ANPN et l'AGEOS. Les indices de texture extraits ont été utilisés dans la thèse pour développer des modèles de BA de la forêt ou des palmeraies. Les codes utilisés pour produire les indices FOTO sont mis en évidence à l'annexe 3, et sont disponibles sur le site internet github (<https://github.com/nagyist/khufkens.foto-toolbox>). Ces codes ont été exécutés dans Matlab R2016a (MathWorks, Natick, MA, USA). Le Tableau 3.2 apporte des détails supplémentaires sur les caractéristiques des indices de texture considérés.

3.2.2.2 Données LiDAR

Les données LiDAR aéroporté à forme d'onde complète ont été considérées dans la présente étude (section 2.2.2). Ces données ont été acquises au cours de la campagne AfriSAR de 2016. Les mesures LiDAR ont été effectuées avec le capteur *Land, Vegetation, and Ice Sensor* (LVIS). Elles sont accessibles gratuitement depuis 2018 sur le site Web de National Snow & Ice Data Center (NSIDC) (Blair et Hofton, 2018). Au cours de la présente étude, les hauteurs médianes (RH50) de la canopée des données LiDAR ont été utilisées pour développer les modèles de BA des forêts. Le Tableau 3.2 donne plus de détails sur le RH50.

3.2.2.3 Données PolInSAR

Les données PolInSAR (section 2.2.3) en bande L polarisation H-V ont été utilisées dans la présente étude. Elles proviennent également de la campagne AfriSAR de 2016 de la NASA, et ont été acquises avec le *Uninhabited Aerial Vehicle Synthetic Aperture Radar* (UAVSAR). Elles sont disponibles sur le site Web de la NASA ORNL DAAC (Lavalle *et al.*, 2018). Dans la présente étude, les hauteurs au sommet de la canopée (H_R) et le coefficient de rétrodiffusion (σ^0) des données PolInSAR ont été utilisés pour développer des modèles de BA des forêts. Des détails sur les caractéristiques de σ^0 et H_R sont mentionnés dans le Tableau 3.2.

Tableau 3.2. Caractéristiques des données de télédétection de la thèse

Paramètre	Description	Méthode d'acquisition	Support et/ou bande spectrale (BS) d'acquisition des données	Année d'acquisition des données	Site d'étude	Source d'obtention des données
Indice de texture						
Indice FOTO	Caractérise la variation du grain de texture grossière et fine avec présence d'ouverture ou de fermeture de la canopée	Application de FFT 2D + ACP (cf. section 2.2.1.1)	BS proche infrarouge (PIR) FORMOSAT-2	2011	Palmier à huile	PDSIRFNGDF
			BS PIR de PlanetScope	2017		OPG
Indice FOTO			BS PIR de SPOT-7	2015	Forêt	ANPN et AGEOS
Indice de texture statistique GLCM	Explique la variation tonale de la texture	Calcul des indices de texture GLCM d'Haralick <i>et al</i> (1979) (cf. section 2.2.1.2)	Bandes spectrales rouge de SPOT-7			
Données LiDAR						
Hauteur dérivée du modèle numérique de hauteur de la canopée (MNHC) des données LiDAR aéroporté à forme d'onde complète	Correspond à la hauteur médiane de la canopée (RH50, en m)	Soustraction entre modèles numériques de surface (MNS) et de terrain (MNT) (cf. section 2.2.2)	LVIS	2016	Forêt	AfriSAR (https://doi.org/10.5067/AOPM UXVUYNH)
Données PolInSAR						
Hauteur dérivée à partir des données PolInSAR en bande L polarisation HV	Décrit la hauteur au sommet de la canopée (H _R , en m)	Utilisation du modèle d'inversion RvoG (cf. section 2.2.3)	UAVSAR	2016	Forêt	AfriSAR (https://doi.org/10.3334/ORNL DAAC/1601)
Coefficient de rétrodiffusion (σ^0 , en dB) dérivé à partir des données PolInSAR bande L polarisation HV	Sensible aux caractéristiques physiques du couvert végétal (branche et tronc) et du sol			2016	Forêt	

CHAPITRE 4. Méthodologie globale

Des explications succinctes sont fournies pour montrer comment les méthodologies utilisées répondent aux différents objectifs des travaux de recherche de la présente thèse. Une description plus détaillée des méthodologies est mise en évidence dans les chapitres 5, 6, 7 et 8. La Figure 4.1 illustre l'organigramme méthodologique global de la présente étude.

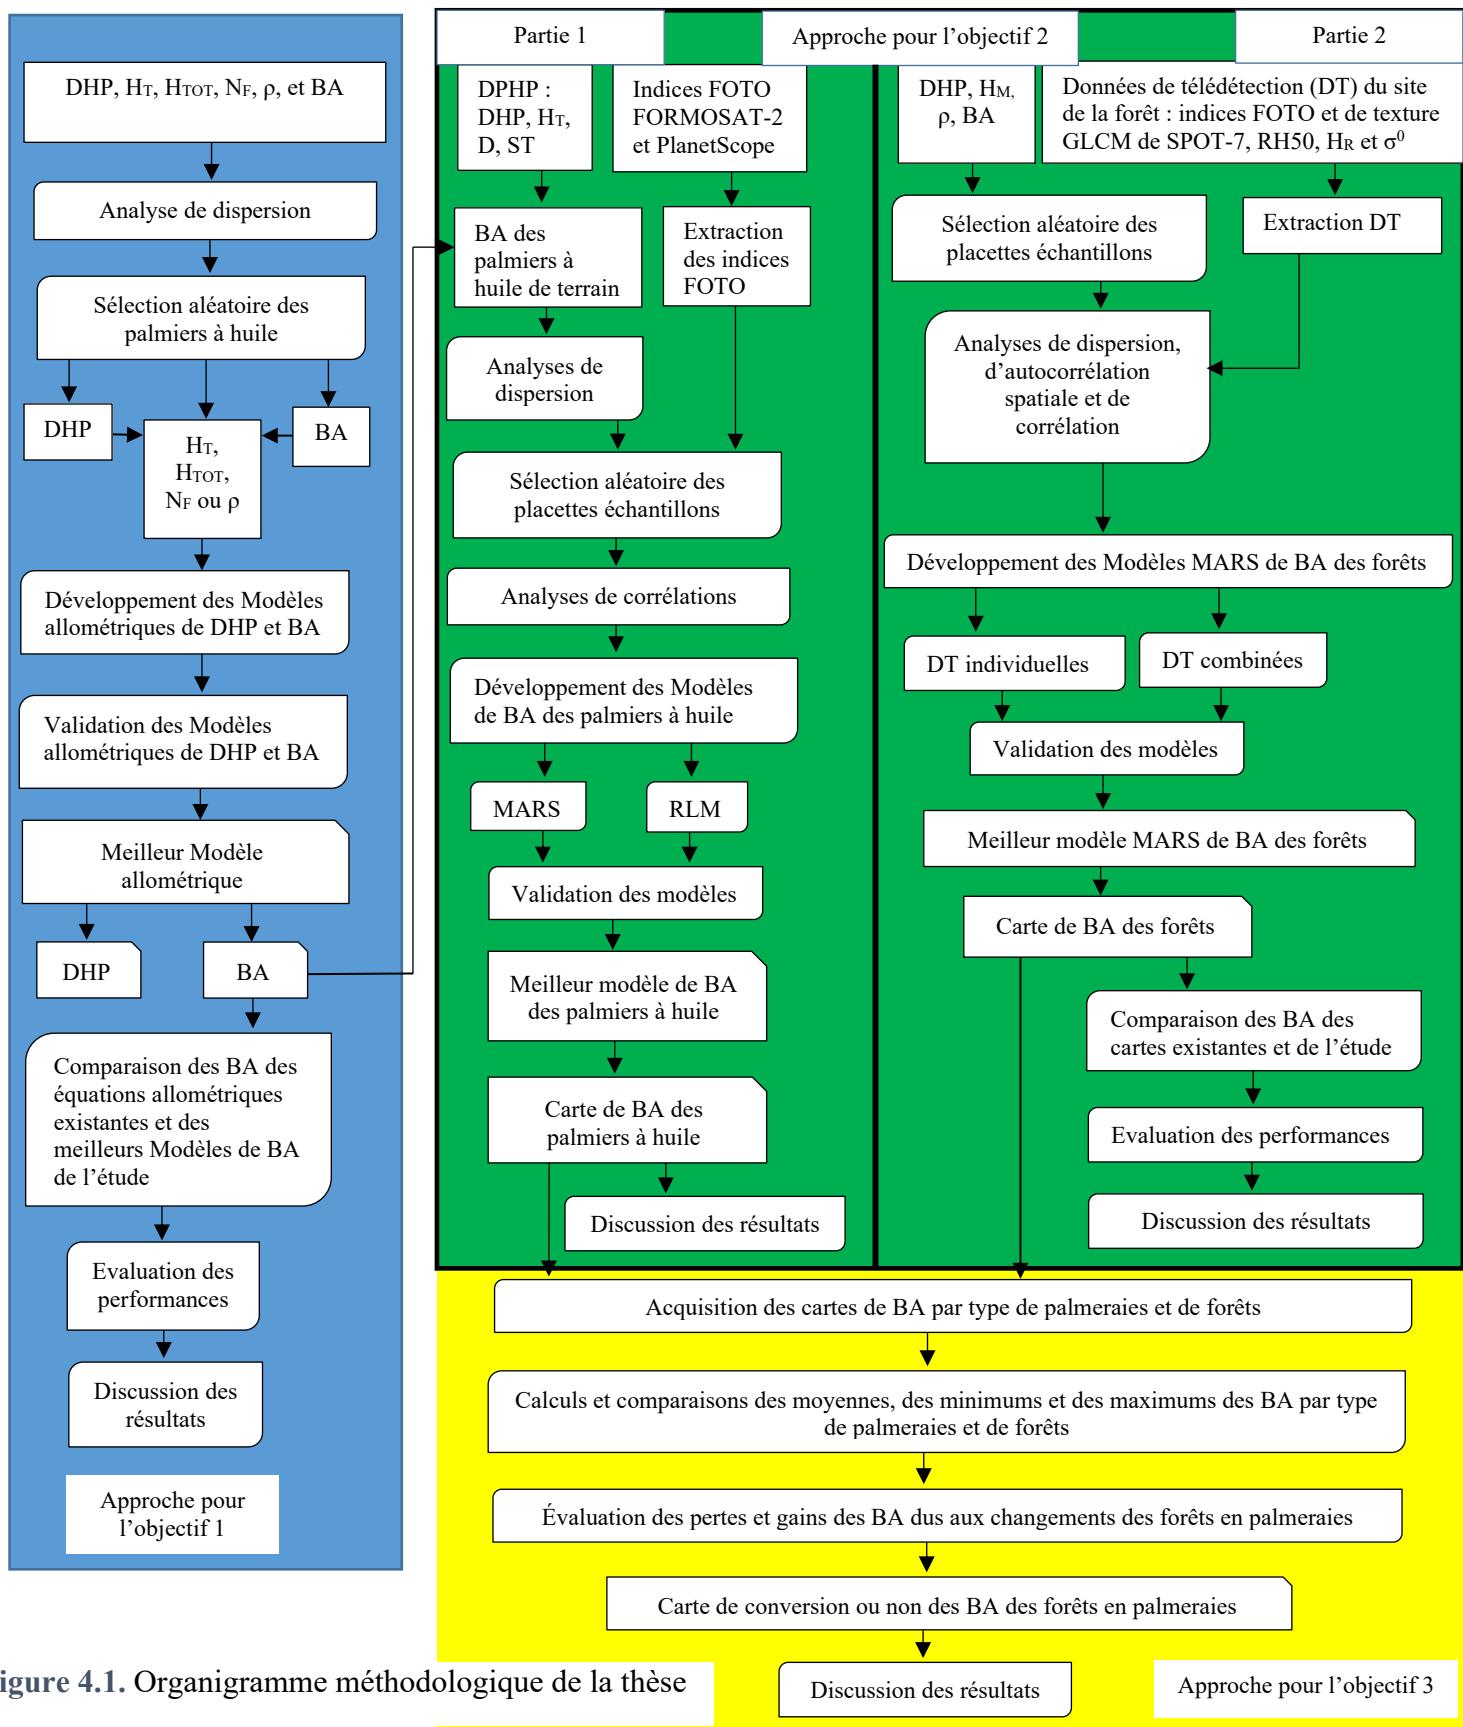


Figure 4.1. Organigramme méthodologique de la thèse

Discussion des résultats

Approche pour l'objectif 3

Comme illustré par la Figure 4.1, la méthodologie générale de l'étude s'articule autour d'approches spécifiques visant à : i) déterminer les biomasses des palmiers à huile sur le terrain (objectif 1), ii) estimer les biomasses par télédétection pour les palmiers et les forêts tropicales (objectif 2), et iii) évaluer les pertes et gains éventuels provenant de la conversion des forêts en plantations de palmiers (objectif 3). Ces différentes approches sont résumées ci-dessous. Les détails se retrouvent dans les manuscrits d'articles présentés dans les chapitres 5, 6, 7 et 8.

4.1. Approche pour l'objectif 1

Avec l'approche de l'objectif 1, des modèles allométriques locaux de BA ont été développés à partir des paramètres structuraux des palmiers à huile. Un diagramme de dispersion des BA et des paramètres structuraux (DHP, H_T , H_{TOT} , ρ et N_F) des palmiers à huile de terrain a initialement été établi pour examiner la distribution des données. Les renseignements sur les mesures des paramètres structuraux et les calculs de BA ont été vérifiés. Les données jugées aberrantes ont été exclues si possible. Avant le développement des modèles de palmiers à huile, 60 % de l'ensemble des palmiers à huile de l'étude (c'est-à-dire 11 palmiers à huile) ont été sélectionnés aléatoirement pour l'entraînement des modèles allométriques locaux de BA. Le reste des 40 % des palmiers à huile (soit 7 palmiers à huile) ont été utilisés pour la validation des modèles. Cette sélection aléatoire a donné une chance égale à chaque palmier à huile d'intégrer les données d'entraînement ou de validation. Les équations allométriques locales de loi puissance des paramètres structuraux (H_T , H_{TOT} , ρ et N_F) ont été développées en fonction de la variable explicative DHP. Les forces de ces relations ont été vérifiées (section 2.1.2). Les modèles allométriques locaux de loi puissance de BA de l'étude ont aussi été construits en liant de manière individuelle ou combinée les BA aux paramètres structuraux des palmiers à huile (DHP, H_T , H_{TOT} , ρ et N_F) (section 2.1.2). Les explications sur le développement des équations allométriques de loi puissance de BA sont indiquées à la section 2.1.2. Ces équations allométriques locales ont été évaluées avec des critères statistiques usuels : R^2 , P-value, l'erreur type résiduelle (σ), le critère d'information d'Akaike (AIC), l'erreur relative (ER), l'erreur relative en pourcentage (%ER), RMSE et son pourcentage (%RMSE ou RMSE relative) (Ngomanda *et al.*, 2014 ; Hansen *et al.*, 2015 ; Da Silva *et al.*, 2015). Selon les recommandations de Kuyah *et al.*, (2012), les modèles ont été sélectionnés en se basant sur la RMSE au détriment de R^2 et l'AIC. Les mêmes critères statistiques utilisés (à l'exception de l'erreur type résiduelle) pour évaluer les modèles développés, ont été considérés pour la validation des modèles. Cette validation a permis d'identifier les meilleurs modèles de DHP et de BA de l'étude. Après cette validation, les équations allométriques existantes de BA de divers

auteurs (Khalid *et al.*, 1999 ; Thenkabail *et al.*, 2004 ; Hughes *et al.*, 1999 ; Saldarriaga *et al.*, 1988 ; Goodman *et al.*, 2013 ; Da Silva *et al.*, 2015 ; Cole et Ewel, 2006) ont été comparées aux meilleures équations locales de BA de l'étude. Cette comparaison a été effectuée à l'aide des BA et des paramètres structuraux des 7 palmiers à huile utilisés pour valider les modèles allométriques locaux de BA. Les BA des équations existantes ont d'abord été estimées à partir des paramètres structuraux des palmiers à huile de terrain. Les erreurs (ER, %ER, RMSE et %RMSE) d'estimation de la BA des équations existantes ont ensuite été calculées par rapport aux BA des 7 palmiers à huile de terrain. Par la suite, les erreurs des BA des équations existantes et de l'étude ont été comparées. Les performances des modèles de l'étude ont été évaluées et une discussion des résultats a été réalisée. L'article de Migolet *et al.*, (2020) décrit de manière exhaustive la méthode d'estimation de la BA des palmiers à huile de terrain.

4.2. Approche pour l'objectif 2

L'approche de l'objectif 2 est constituée de 2 parties. Dans la première partie, les modèles MARS et RLM de BA des palmiers à huile matures ont été développés à l'aide des indices FOTO FORMOSAT-2 et PlanetScope. Pour y parvenir, 40 placettes échantillons ont d'abord été établies sur le site des palmiers à huile sur la base d'un échantillonnage systématique. Des diagrammes de dispersion ont été réalisées entre les BA et les paramètres structuraux des palmiers à huile sur pied (DHP, H_T, D et ST) (section 3.2.1.2) de ces placettes échantillons pour vérifier les valeurs aberrantes et les exclure si possible. À la suite de cette analyse, les indices FOTO des bandes spectrales proches infrarouges de FORMOSAT-2 et PlanetScope (section 3.2.2.1) ont été extraits dans toutes les placettes échantillons de l'étude. Après cette extraction, 75 % des 40 placettes échantillons (soit 30 placettes) ont aléatoirement été sélectionnées pour développer les modèles de BA. Avant le développement des modèles, des analyses de corrélation ont été effectuées entre les paramètres structuraux et les indices FOTO des placettes échantillons d'entraînement. Des modèles de BA ont également été établis avec MARS (section 2.2.4) et RLM à partir des indices FOTO de FORMOSAT-2 et de PlanetScope. L'expression mathématique de RLM utilisée au cours de la présente étude est la suivante :

$$BA = a_0 + \sum_{C=1}^3 a_C \cdot IF_C \quad (4.1)$$

où a_0 et a_C représentent respectivement la constante et les coefficients de RLM. IF correspondent aux indices FOTO déterminés à l'aide des scores pour les trois premiers axes de l'ACP des spectres-r de la transformé de Fourier discrète de Fourier. Les différents modèles construits ont été évalués avec divers paramètres statistiques : R², P-value, RMSE et %RMSE. Dix (10) placettes échantillons sélectionnées aléatoirement ont été utilisées pour valider les

modèles de BA. Les mêmes paramètres statistiques utilisés pour évaluer les modèles établis ont été considérés pour la validation des modèles. Après cette validation, la carte de la BA a été réalisée avec le meilleur modèle de l'étude. Une discussion a enfin été menée sur les résultats. Migolet et Goïta (2020) apportent des détails sur la méthodologie utilisée pour matérialiser la première partie de l'approche de l'objectif 2 de l'étude.

Dans la deuxième partie de l'approche de l'objectif 2, le modèle MARS de BA de la forêt a été développé à l'aide des données de télédétection optique (section 3.2.2.1), LiDAR (section 3.2.2.2) et PolInSAR (section 3.2.2.3) (Tableau 3.2). Les données *in situ* (DHP, H_M, ρ et BA) des arbres sur pied du site de la forêt (section 3.2.1.3 ; Tableau 3.1) ont d'abord été mesurées dans 75 placettes échantillons de terrain sélectionnées aléatoirement. Les valeurs moyennes des données optiques, LiDAR et PolInSAR ont ensuite été extraites des 75 placettes échantillons de terrain de résolution spatiale de 30,8 m × 30,8 m. Après ces extractions, les placettes d'entraînement et de validation des BA des cartes ont également été aléatoirement sélectionnées. Globalement, 60 % des 75 placettes échantillons (c'est-à-dire 45 placettes) ont aléatoirement été sélectionnées pour développer les modèles de BA. Le reste des 30 placettes échantillons a servi à la validation des modèles établis et à la comparaison des BA des cartes existantes et du meilleur modèle de l'étude. Avant de développer les modèles de BA de l'étude, des analyses de dispersion, d'autocorrélation et de corrélation ont été effectuées sur les données *in situ* et de télédétection de l'étude. A la suite de ces analyses, les modèles de BA ont été établies avec MARS (section 2.2.4) en reliant les BA de terrain et les variables de télédétection des placettes échantillons d'entraînement. Ces modèles ont été évalués avec les paramètres statistiques suivants : R², P-value, RMSE et %RMSE. Suivant l'analyse d'autocorrélation, 17 placettes échantillons ont été utilisées pour valider les modèles MARS de BA avec les mêmes paramètres de performances considérés pour entraîner les modèles développés. La carte de BA a été réalisée avec le meilleur modèle MARS de BA de l'étude à la résolution spatiale de 30,8 m × 30,8 m. Par la suite, les cartes existantes de BA récentes de la zone d'étude de divers auteurs (Bouvet *et al.*, 2018; Labrière *et al.*, 2018; Saatchi *et al.*, 2019; El Hajj *et al.*, 2019) ont été rééchantillonées à la même résolution spatiale de la carte de BA de l'étude (30,8 m × 30,8 m). Les BA des cartes existantes ont ensuite été comparées aux BA de la carte de l'étude. Les BA de chacune de ces cartes ont été évaluées avec R², P-value, RMSE, %RMSE, ER et %ER. Une discussion des résultats a enfin été effectuée. Migolet *et al.*, (en révision dans la revue *GIScience and Remote Sensing*) explicitent davantage la méthodologie utilisée proposée.

4.3 Approche pour l'objectif 3

L'approche de l'objectif 3 évalue la dynamique de la biomasse due aux remplacements des forêts par les palmiers à huile d'une plantation agro-industrielle mature. Cette évaluation a reposé sur les cartes de BA des palmeraies et des forêts produites avec les méthodologies mises en œuvre pour atteindre les objectifs 1 (section 4.1) et 2 (section 4.2) de la thèse. La carte de BA de la forêt a été rééchantillonnée à la même résolution spatiale que la carte de BA des forêts ($30,8 \text{ m} \times 30,8 \text{ m}$). Des valeurs moyennes, minimales et maximales des BA ont ensuite été déterminées par type de palmiers à huile de la plantation et des forêts à partir de chacune des cartes de BA. Les valeurs des BA des forêts ont par la suite été comparées aux valeurs des BA des palmiers à huile de la plantation. Cette comparaison a permis de déterminer les pertes et les gains des BA des forêts dus aux remplacements des palmeraies. Pour déterminer ces pertes et gains, le taux de diminution ou d'augmentation de la biomasse par conversion des occupations des terres a été calculé par le rapport de la différence des BA des végétaux à installer (ex. palmiers de la plantation) ou à extraire (ex. forêt) sur la BA du végétal à extraire (ex. forêt). Le résultat de ce rapport a été multiplié par 100. Le taux de gain de BA dû à la conversion des forêts en palmeraies atteint 100 % lorsque les BA du végétal à installer (ex. palmiers de la plantation) sont $> 0 \text{ t ha}^{-1}$ et les BA du végétal à extraire (ex. forêt) équivalent à 0 t ha^{-1} (Ramdani et Masateru, 2013; Kho et Rudbeck-Jepsen, 2015). Une carte de conversion des BA des forêts en palmeraies a enfin été réalisée à la résolution spatiale de $30,8 \text{ m} \times 30,8 \text{ m}$. Les valeurs des intervalles des pertes et de gains des BA obtenues au cours de cette analyse ont été considérées pour produire la carte de BA de conversion ou de non-conversion des forêts en palmeraies. Une discussion des résultats a enfin été menée.

CHAPITRE 5. Estimation of Aboveground oil palm biomass in a mature plantation in the Congo Basin (Article 1)

5.1 Présentation de l’Article

Cette recherche visait à déterminer la biomasse aérienne des palmiers à huile dans le Bassin du Congo à partir de mesures effectuées sur le terrain dans le cadre de la thèse. Elle a donné lieu à un article scientifique original. Cet article traite de l'estimation de la BA des palmiers à huile dans une plantation mature dans le Bassin du Congo. Son originalité provient de l'inexistence des modèles d'estimation de la BA de terrain dans le Bassin du Congo et de l'expertise développée au cours des travaux de recherche de la présente thèse de doctorat. L'article était également original par la production en 2017 des données inédites des masses fraîches des compartiments (tiges, rachis, pétioles, fruits et folioles) et des paramètres structuraux (DHP, H_T , H_{TOT} et N_F) de 18 palmiers à huile matures de terrain de la plantation d'Olam Palm Gabon à Makouké au Gabon dans le Bassin du Congo. Cette originalité a aussi été marquée par la détermination des masses sèches totales de chaque compartiment et de tous les compartiments des palmiers à huile. L'originalité de cet article a aussi été mise en évidence par les estimations de la fraction de masse sèche par compartiment (excepté les feuilles) et l'infra-densité (ρ) des tiges de des palmiers. La répartition des proportions des biomasses des compartiments a aussi été une première et une réussite pour les palmiers à huile dans le Bassin de Congo.

La similarité entre les proportions des biomasses des tiges et des feuilles de cet article et celles de la littérature (Cole et Ewel, 2006; Da Silva *et al.* 2015) témoigne de la fiabilité de nos estimations. Des relations entre les variables explicatives individuelles de BA (ρ , H_{TOT} , H_T et N_F) et DHP ont été fortes et significatives (R^2 compris entre 0,54 et 0,81). Les équations allométriques locales de loi puissance de ces variables explicatives (ρ , H_{TOT} , H_T et N_F) ont été établies en fonction de DHP. Celles-ci avaient des faibles erreurs de validation (erreur quadratique moyenne relative (%RMSE) < 10 %). Les équations allométriques locales de loi puissance de BA de terrain ont aussi été développées avec de faibles erreurs de validation (%RMSE < 12 %). Les BA des équations existantes ont été estimées et par la suite comparées à celles de l'étude. Certaines équations existantes ont été applicables dans le Bassin du Congo mais leurs erreurs (%RMSE entre 9,3 et 24 %) ont été plus élevées à celles de la meilleure équation de l'étude (%RMSE = 5,1 %). Au-delà des résultats encourageants obtenus avec les modèles allométriques locaux de BA développés, les erreurs de mesures de terrain et le nombre de placettes échantillons de l'étude restent des limites pour l'estimation de la BA. Il est alors recommandé d'augmenter le nombre de palmiers à huile échantillons et de tenir compte des

différents stades de croissance de ce végétal pour établir des modèles dans les études futures. Ce travail a fait l'objet d'une vulgarisation scientifique par la Bande Dessinée (BD). Il a été présenté sous forme de BD au festival de la bande dessinée "Art BD Sherbrooke 2020" à Sherbrooke au Canada. Les résultats des modèles locaux de BA développés et la comparaison des équations existantes des BA des palmiers à huile ont été publiés dans le journal *Forest* :

Migolet, P., Goïta, K., Ngomanda, A. et Mekui Biyogo, A. P. (2020) *Estimation of Aboveground Oil Palm Biomass in a Mature Plantation in the Congo Basin. Forests*, vol. 11, n°5, p. 544.

Le manuscrit de l'article est présenté dans les pages qui suivent.

Estimation of Aboveground oil palm biomass in a mature plantation in the Congo Basin

by Pierre Migolet, Kalifa Goïta, Alfred Ngomanda and Andréana Paola Mekui Biyogo

Forest

Volume 11, No 5, 544, 12 may 2020

Estimation of Aboveground oil palm biomass in a mature plantation in the Congo Basin

Pierre Migolet ^{1*}, Kalifa Goïta ¹, Alfred Ngomanda ² and Andréana Paola Mekui Biyogo ³

¹Centre D'Applications et de Recherches en Télédétection (CARTEL), Département de Géomatique Appliquée, Université de Sherbrooke, Québec, Canada

²Commissariat Général du Centre National de la Recherche Scientifique et Technologique (CENAREST), Libreville, Gabon

³Independent Geomatics Consultant, Former Employee of Olam Palm Gabon, Rebecq, Belgique

*Author to whom correspondence should be addressed.

Abstract

Agro-industrial oil palm plantations are becoming increasingly established in the Congo Basin (West Equatorial Africa) for mainly economic reasons. Knowledge of oil palm capacity to sequester carbon requires biomass estimates. This study implemented local and regional methods for estimating palm biomass in a mature plantation, using destructive sampling. Eighteen 35-year-old oil palms with breast height diameters (DBH) between 48 and 58 cm were felled and sectioned in a plantation located in Makouké, central Gabon. Field and laboratory measurements determined the biomasses of different tree compartments (fruits, leaflets, petioles, rachises, stems). Fruits and leaflets contributed an average of 6% to total aboveground palm biomass, which petioles accounted for 8%, rachises for 13% and the stem, 73%. The best allometric equation for estimating stem biomass was obtained with a composite variable, formulated as $DBH^2 \times$ stem height, weighted by tissue infra-density. For leaf biomass (fruits + leaflets + petioles + rachises), the equation was of a similar form, but included the leaf number instead of infra-density. The allometric model combining the stem and leaf biomass yielded the best estimates of the total aboveground oil palm biomass (coefficient of determination (r^2) = 0.972, $p < 0.0001$, relative root mean square error (%RMSE) = 5%). Yet, the model was difficult to implement in practice, given the limited availability of variables such as the leaf number. The total aboveground biomass could be estimated with comparable results using $DBH^2 \times$ stem height, weighted by the infra-density ($r^2 = 0.961$, $p < 0.0001$, relative RMSE (%RMSE) = 5.7%). A simpler model excluding infra-density did not severely compromise results ($r^2 = 0.939$, $p < 0.0003$, %RMSE = 8.2%). We also examined existing allometric models, established elsewhere in the world, for estimating aboveground oil palm biomass in our study area. These models exhibited performances inferior to the best local allometric equations that were developed.

Keywords: agro-industrial plantations; oil palms; aboveground biomass; allometric equations; Congo Basin; Gabon

Résumé

Les plantations agro-industrielles de palmiers à huile sont de plus en plus implantées dans le Bassin du Congo (Afrique équatoriale occidentale) pour des raisons essentiellement économiques. La connaissance de la capacité du palmier à huile à séquestrer le carbone nécessite des estimations de la biomasse. Cette étude a mis en œuvre des méthodes locales et régionales d'estimation de la biomasse de palmiers dans une plantation mature, en utilisant un échantillonnage destructif. Dix-huit palmiers à huile âgés de 35 ans avec un diamètre à hauteur de poitrine (DHP) compris entre 48 et 58 cm ont été abattus et sectionnés dans une plantation située à Makouké, au centre du Gabon. Des mesures sur le terrain et en laboratoire ont déterminé les biomasses des différents compartiments d'arbres (fruits, folioles, pétioles, rachis, tiges). Les fruits et les folioles ont contribué en moyenne à 6 % à la biomasse aérienne totale des palmiers, dont les pétioles représentaient 8 %, les rachis 13 % et la tige 73 %. La meilleure équation allométrique pour estimer la biomasse de la tige a été obtenue avec une variable composite, formulée comme $DHP^2 \times$ hauteur de la tige, pondérée par l'infra-densité. Pour la biomasse foliaire (fruits + folioles + pétioles + rachis), l'équation était de forme similaire, mais incluait le nombre de feuilles au lieu de l'infra-densité. Le modèle allométrique combinant la biomasse des tiges et des feuilles a donné les meilleures estimations de la biomasse aérienne totale du palmier à huile (coefficients de détermination (r^2) = 0,972, $p < 0,0001$, erreur quadratique moyenne relative (%RMSE) = 5 %). Toutefois, le modèle était difficile à mettre en œuvre dans la pratique, étant donné la disponibilité limitée de variables telles que le nombre de feuilles. La biomasse aérienne totale pourrait être estimée avec des résultats comparables en utilisant $DHP^2 \times$ hauteur de la tige, pondérée par l'infra-densité ($r^2 = 0,961, p < 0,0001$, RMSE relative (% RMSE) = 5,7 %). Un modèle plus simple excluant l'infra-densité n'a pas gravement compromis les résultats ($r^2 = 0,939, p < 0,0003$, % RMSE = 8,2 %). Nous avons également examiné des modèles allométriques existants, établis ailleurs dans le monde, pour estimer la biomasse aérienne du palmier à huile dans notre zone d'étude. Ces modèles ont présenté des performances inférieures aux meilleures équations allométriques locales développées.

Mots-clés : plantations agro-industrielles ; palmiers à huile ; biomasse aérienne ; équations allométriques ; Bassin du Congo ; Gabon

5.2 Introduction

The world is becoming increasingly concerned with changes that are occurring in ecosystems and in the climate. These changes are manifested in and exacerbated by forest conversion into agricultural land. This process is a major driver of global deforestation. Results of the Global Forest Resources Assessment [1] have indicated that the total forest area has declined by about 3%, from a worldwide estimate of 4128 Mha in 1990 to 3999 Mha in 2015 [2]. These losses are responsible for increasing greenhouse gas (GHG) emissions and incurring substantial changes in the amounts of carbon I that are stored in forested ecosystems [3]. Indeed, a global loss of forest biomass carbon in the order of 11.1 gigatons has been reported over 25 years (from 1990 to 2015); this represents a 3.8% decrease in storage from an initial 296 Gt estimate of the total forest C [1]. The intensification of forest- and agriculture-related economic activities largely explains this change. For example, tropical forested areas are being converted into oil palm plantations to meet economic (biofuel, palm oil), social (food, household products, cosmetics, soap), cultural (traditional medicines and other care products) or scientific needs [4,5,6]. An increase in these needs has led to the development and expansion of agro-industrial oil palm plantations in tropical Asia, Oceania, Africa and Amazonia [7,8,9].

Several species of oil palms have been naturalized throughout the world. Currently, the Afrotropical species *Elaeis guineensis* Jacq. (African oil palm) is the palm most extensively cultivated for oil production. The Neotropical *Elaeis oleifera* (Kunth) Cortés (American oil palms), which also produce oil, have been rarely exploited commercially. Hybridization with *E. oleifera* has increased the disease resistance of *E. guineensis*, while improving its biochemical and physiological characteristics [10,11].

These latter species, together with palms within the genera *Euterpe* and *Astrocaryum*, have not been extensively domesticated given that they tend to occur as solitary individuals or small groups within intact tropical forest and in seral stages leading to mature stand canopy closure. Nonetheless, these species are cultivated as food crops (including açai berry and hearts of palm); the small quantities of oil extracted from their edible fruits are used in salads or as ingredients in soaps and cosmetics [12].

Resulting land use changes have exerted effects especially on the capacity of ecosystems to sequester and store carbon in the plants of which they are composed. In the case of oil palms, this capacity may increase or decrease, depending upon the ecosystems that they frequently replace [9,13,14]. In mature forests, oil palms generally cause a loss in the quantity of carbon that is stored, whereas they favor an increase in storage in fallow land and savannah areas [6,14,15]. As a result, this variation in storage can have repercussions for the climatic and environmental equilibria in the affected tropical regions [1]. An important challenge is the

ability to exploit and develop agricultural areas, such as agro-industrial plantations, without compromising or damaging the ecological integrity of the broader continuous forest (e.g., [5]). Such actions would help to accentuate the trend towards decelerating deforestation rates that has been noted by the Food and Agriculture Organization (FAO) [1]. Indeed, the loss of tropical forest area declined by 42% to 5.5 Mha year⁻¹ during the period 2010–2015, from the estimated 9.5 Mha year⁻¹ during the 1990s [2].

To improve attempts in land use redevelopment, it is important to have a better understanding of forest and agricultural biomass stocks, together with their respective spatial and temporal dynamics. The current study developed allometric models to estimate the total aboveground biomass of oil palms in a particular region, namely the Congo Basin. We aimed at determining which components of the total aboveground biomass were most effective and efficient in constructing these allometric equations. Total aboveground biomass is the total dry mass of aboveground organic material that is present in different plant compartments, including the stem, branches, leaves, stumps and bark [16]. The total biomass represents an important carbon storage reservoir within the plant and also constitutes the part that is most vulnerable to human activities and natural perturbations, regardless of whether these effects are acute or chronic.

A number of studies have been conducted to gather data on the total dry aboveground biomass of oil palms in targeted tropical areas of Africa, Amazonia and Asia [4,17,18,19]. The resulting allometric equations rely upon characteristic attributes of oil palms (and palms, in general), such as diameter, height, wood infra-density (stem dry mass vs. fresh volume), dry mass fraction and the number of leaves or age to estimate the biomass at different stages of tree development (young, mid-mature, mature). These attributes are frequently used as simple [4,20] or as composite [21,22,23] explanatory variables. In Benin, Thenkabail et al. [20] estimated the aboveground biomass of young oil palm trees (1- to 5-years-old) using stem height. In another study conducted in Benin, Aholoukpè et al. [24] proposed a simple equation for estimating the biomass of oil palm fronds using the dry mass of the rachis, i.e., the axis of the compound leaf. Khalid et al. [4] predicted the biomass for mid-mature (23-years-old) Malaysian oil palm plantations by considering the total height as the explanatory variable. Saldarriaga et al. [18] developed equations in which the squared value of the DBH (diameter at breast height, measured at 1.3 m), together with the stem height, were used to estimate the plant biomass. In this case, the plants were relatively young, with DBHs ranging between 1 and 10 cm. The same variable combination expressed as DBH² × stem height was used by Hughes et al. [25] in southern Mexico to estimate biomass for wild palms (*Astrocaryum mexicanum* Liebm. Ex Mart.) with DBHs < 10 cm. Cole and Ewel [26] also considered the same variable combination

for four economically valuable forest species, but also included the leaf count in the estimation of the aboveground biomass in açaí palm (*Euterpe oleracea* Mart.) plantations (DBH < 20 cm) in the Atlantic Lowlands of Costa Rica. Goodman et al. [27] studied the allometric relationships of nine species in the Arecaceae, including *Attalea phalerata* Mart. Ex Sprung, which is a source of vegetable oil [28]. These authors substituted the dry-matter fraction for the leaf count in palm plantations covering all the stages of development (DBH between 4 and 50 cm) in Amazonian Peru, while Da Silva et al. [22] considered the stem infra-density in the case of young (DBH 3–13 cm) forest açaí or *açaí-solitário* (*Euterpe precatoria* Mart.) in Amazonian Brazil.

All of these studies have provided various explanatory variables for estimating the aboveground biomass of palms worldwide, including those that produce oil. The performances of these different variables have yet to be compared in the same study. Furthermore, the allometric equations of these studies have not been compared with local allometric models for estimating the aboveground biomass of oil palms that were established in the Congo Basin (West Equatorial Africa). The oil palms that were used in these studies were consistently young, with a few cases of semi-mature and mature individuals. However, there is little research on mature individuals (>30-years-old).

Research estimating oil palm biomass is relatively sparse for the Congo Basin. Considering the gradual but relentless establishment of oil palm plantations, it is crucial that estimation methods be developed and comparative analyses be conducted relative to other tropical regions. Thus, the current study sought (1) to evaluate the attributes that were most relevant for characterizing the aboveground biomass of oil palm plantations in the Congo Basin, and (2) to develop the necessary allometric equations and compare their results with those that have been obtained from other tropical areas. This study was based upon field measurements that were acquired through destructive sampling in agro-industrial oil palm plantations operated by the Société Olam Palm Gabon.

5.3 Materials and Methods

5.3.1 Study Area

The oil palms were sampled in a plantation operated by the Société Olam Palm Gabon, which is located in the Makouké district, Moyen Ogooué Province, central Gabon. The region is characterized by a hot and humid equatorial climate, with two rainy seasons and two dry seasons. The plantation adjoins the Ogooué River, which is the largest river in Gabon. The temperatures in the area range from 27 °C to 38 °C and precipitation reaches 1800 to 2000 mm annually. The plantation is located on a ferrallitic Cambisol-dominant soil. Established in 1981,

it is the oldest plantation of oil palm in Gabon. It currently covers 5700 ha, with an average density of 134 oil palm trees per hectare. Mature oil palms represent an area of about 1500 ha. The plantation is divided into blocks. One of these blocks was the study area, located between longitudes $10^{\circ}24'27''$ E and $10^{\circ}24'57''$ E, and latitudes $0^{\circ}30'06''$ S and $0^{\circ}30'16''$ S (**Figure 5.1**). The block considered covered an area of 25 ha ($1000\text{ m} \times 250\text{ m}$). The palm trees inside the block were mature and were planted in both dry and flooded areas (**Figure 5.1**).

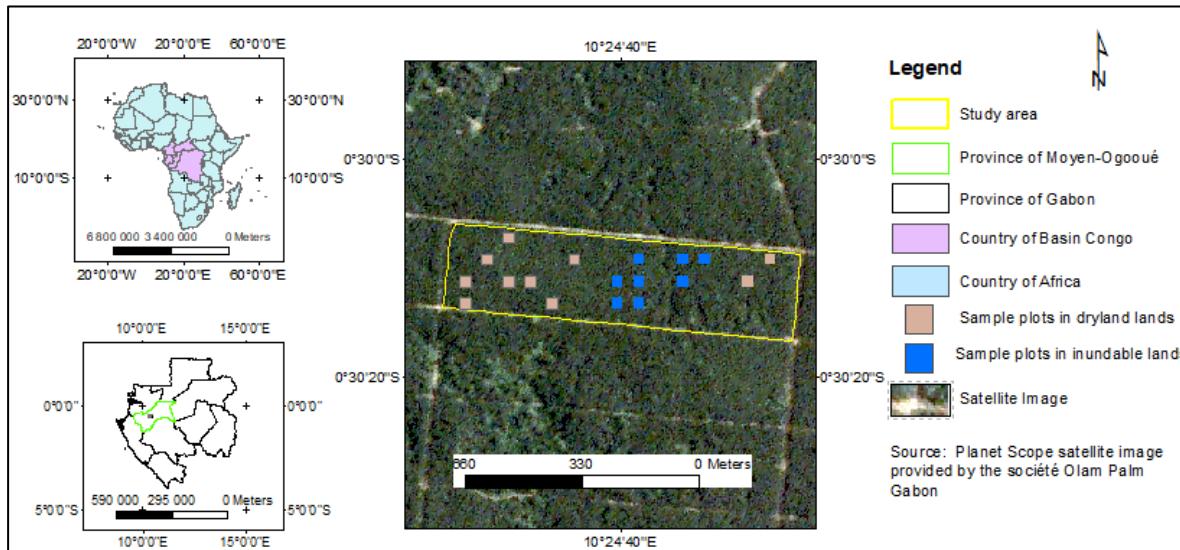


Figure 5.1 Study area.

In 2019, the plantation obtained “Roundtable on Sustainable Palm Oil” (RSPO) certification for its efforts to protect the environment and encourage sustainable development by complying with global standards for sustainable palm oil. The RSPO certification committed Olam Palm Gabon to respecting several principles and criteria for managing the plantation, including among others (1) reducing deforestation, (2) encouraging the responsible use of agro-chemical products in the production system and (3) avoiding conflicts between local communities and plantation owners. The implementation of all these actions contributed to the sustainable exploitation of oil palm trees. The company’s commitment to not convert primary forests, areas of high conservation value, peatlands as well as land belonging to local communities into plantations, considerably limits deforestation.

Although located in the heart of the tropical forest in the Congo Basin, the area where the studied plantation was positioned cannot be considered as fully representative of the conditions prevailing throughout the whole basin, which is a very large region. Nevertheless, it reflected certain similar natural aspects, notably in terms of tropical forest, biodiversity, climate, soil type and hydrography.

5.3.2 Data Collection

5.3.2.1 Field Data Measurement

The sampling was conducted in a 35-year old plantation. In this area, eighteen oil palms were felled during the rainy season in October 2017 to obtain information on their aboveground biomass. Each felled palm tree was randomly selected within a 30.8 m × 30.8 m sample plot across the plantation block. The sample plots were randomly located in the study block. Eight of them were located in flood prone areas, while ten were on drylands ([Figure 5.1](#)). The individuals were healthy and not deformed by disease. The DBH of each selected palm, together with its stem height (H_T) and total height (H_{TOT}), were recorded using a standard measuring tape (DBH in cm and heights in m). The stem height was measured from the stump to the first branch, while the total height was taken from the stump to the top of the crown. The total number of leaves (N_F) on each palm was also counted. Following these measurements, the palm stem was sectioned into logs at fixed 0.5 m increments. The diameters and heights of the palm trees in the flood prone and neighboring areas were smaller (less than 52 cm for DBH and less than 16.4 m for H_{TOT}) than those located on the dryland (more than or equal to 52 cm for DBH and 15.1 m for H_{TOT}). The basic statistics of the measurements that were taken in the field are summarized in [Table 5.1](#).

Table 5.1. Summary of the field measurements for 18 felled oil palms: DBH, H_T , H_{TOT} and N_F are respectively the diameter at breast height (cm, measured 1.3 m above the ground surface), the stem height (m), the total height (m) and the leaf number per tree

Parameter	Minimum	Maximum	Mean	*SE	%SE
DBH	48.8	57.9	53.1	0.71	1.34
H_T	6.65	10.0	8.46	0.22	2.60
H_{TOT}	14.5	18.2	15.97	0.22	1.38
N_F	27	39	33.27	0.92	2.77

*SE is the standard error for each parameter and %SE is its percentage.

Once the measurements were taken and the stem was sectioned, each oil palm was separated into different components, namely the stem elements and the leaves, which included the petioles, rachis, leaflets and the fruits. The fresh mass of each component was immediately recorded using a one-ton scale. Subsamples were then taken from each component. Stem samples were taken from the first three cut logs, starting with the stump from the middle, and then from the crownward end of the stem. Samples were taken from the butt or bottom end of each log, in the form of a right angled triangle that varied in thickness from 2.7 to 4.8 cm, and from 12 to 48 cm for the lengths of the sides forming the right angle of the triangle. The same samples represented one-quarter of the large end of the stem section. Following weighing, all

samples were inserted into numbered freezer bags for laboratory determinations. A summary of all the data on oil palms is presented in [**Table 5.A1**](#).

5.3.2.2 Laboratory Measurements

Subsamples that were taken from the components of the 18 individuals palms (stems, petioles, rachis, leaflets and fruit) were dried under ambient air conditions and then placed in drying oven (or steamer) at 105 °C (except for the leaflets, 65 °C) to obtain wet-to-dry conversion factors. Six oil palms were selected to obtain dried fruit masses, but not all of the individuals bore fruit. The individual components were dried to constant mass (3 consecutive days) [27,29,30] and weighed on a 5 kg balance. Thus, the dry mass fraction (DMF) of each sample per component (stems, petioles, rachis, fruit and leaflets) was calculated as the ratio of the dry mass that was recorded in the laboratory to the corresponding fresh mass that was obtained in the field for each oil palm. A mean DMF value was determined for each component. [**Table 5.2**](#) summarizes the means that were obtained for each component and for the whole palm tree.

Table 5. 2. Summary of the infra-density, dry mass fractions and the average total dry mass of the palm components for 18 individuals that were felled in Makouké, central Gabon

Components	Minimum	Maximum	Mean	SE	% SE
Descriptive statistical parameters for dry mass fractions (DMF)					
Stem	0.253	0.347	0.301	0.006	2.020
Petiole	0.134	0.245	0.194	0.007	3.805
Fruit	0.156	0.221	0.190	0.009	5.059
Rachis	0.233	0.335	0.277	0.006	2.386
Leaflet	0.198	0.386	0.322	0.010	3.215
Whole oil palm	0.281	0.290	0.285	6.10 ⁻⁴	0.220
Descriptive statistical parameters for infra-density (g cm⁻³)					
Stem	0.25	0.3279	0.2930	0.0048	1.639
Descriptive statistical parameters for total dry mass of oil palm compartments (kg)					
Stem	199.19	419.46	302.77	13.66	4.51
Petiole	20.89	46.31	33.28	1.64	4.92
Fruit	14	82.5	58.57	10.54	17,99
Rachis	29.38	83.16	56.50	3.31	5.86
Leaflet	13.29	29.57	21.42	1.03	4.83
Leaf (petioles, fruit, rachis + leaflets)	77.15	148.79	114.93	5.19	4.52
Stem + Leaf	288.72	556.41	417.69	17.78	4.26

Finally, the fresh masses that were obtained in the field for each component of an oil palm were multiplied by the corresponding average DMF to obtain their respective dry masses. From these corrected values, it was then possible to determine the total dry mass of an individual oil palm. The dry mass: total fresh mass ratios of the palms allowed us to estimate the DMF for each of the 18 palms. The total dry masses of the different compartments of the 18 oil palms are presented in [Table 5.2](#). In the laboratory, the infra-density (ρ) of the oil palm stem tissue was determined according to the protocol of Rondeux [31], and Bauwens and Fayolle [32]. The mean infra-density of the oil palm stems is also presented in [Table 5.2](#).

5.3.3 Establishment and Validation Allometric Models

The data analyses were performed using the XLSTAT software (<https://www.xlstat.com/fr/>). Scatterplots were created to better understand the distributions of the data. Consequently, outliers were identified and checks were performed to detect the possible sources of error. Only data that were correctly identified and reported were retained for the purposes of this study. Using data from the 18 oil palm trees, two classes of DBH (48–54 cm and 54–58 cm) were established to determine the proportions of biomass. The DBH class of 48–54 cm had 11 oil palms and that of 54–58 cm had 7 oil palms.

The basic expression that was employed in this research for creating the allometric equations took the following form [33]:

$$y = aX^b \quad (5.1)$$

where y is the dependent variable (dry aboveground biomass), X is the product of one or more independent variables (e.g., DBH) and a and b are empirically estimated scaling factors. Typically, the log_e-transformed form of the equation is used to linearize the expression, while at the same time homogenizing the variance, which increases the validity of statistical tests that are being used [34,35,36]. The equation can be rewritten as

$$\ln(y) = \ln(a) + b\ln(X) \quad (5.2)$$

The independent variables that were considered here are DBH, H_T, H_{TOT}, ρ and N_F. To obtain unbiased estimations with log-transformed models, the bias caused by the conversion of $\ln(y)$ to the original non-transformed scale y , should be corrected. The correction factor (CF) was used to make this correction [26,27,30], such as $CF = \exp(\text{root mean square error (RMSE}^2/2)$, where RMSE is the mean square error of the regression equation. The original untransformed scale of y could be obtained by $y = (CF \times a)X^b$ [30]. To develop the equations, 60% of the oil palms were randomly selected and used (i.e., 11 of 18 palms). The remaining 40% (7 oil palms) were set aside for the independent validation of the results. Both the data for development and validation were randomly located over drylands and flood prone areas.

The performance of the established models was evaluated using different metrics. These included the coefficient of determination (r^2), the residual standard error (σ), the Akaike information criterion (AIC), the relative error (ER), the relative percentage error (%ER), and the root mean square error (RMSE) and its percentage (%RMSE). Similar metrics have been used in previous studies [30,37,38]. The expressions for calculating ER and RMSE are as follows:

$$ER = \frac{\sum_{i=1}^n[(\bar{y}_i - y_i)/y_i]}{n} \quad (5.3)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n(y_i - \bar{y}_i)^2}{n}} \quad (5.4)$$

where n is the number of observations, y_i is the observed value for palm I , and \bar{y}_i is its predicted value. The relative RMSE (%RMSE) was calculated as a percentage by dividing the RMSE by the observed mean [38]. The relative percent error (%ER) was obtained by multiplying ER by 100. The interpretation of the metrics differed when attempting to characterize the best performance. The higher the r^2 , the more robust the equation was considered. In contrast, the lower the AIC value, the better the model fit. In all cases, the errors (ER, %ER, σ , RMSE, %RMSE) should be as small as possible. However, Kuyah et al. [39] and Yang et al. [30] have recommended giving more weight to the bias and RMSE rather than to an adjusted r^2 or AIC in deciding the final optimal model [30].

The field data that were obtained from seven randomly selected sample plots were used to validate the equations that we had developed. The same metrics were considered in the validation, except for the standard residual error. Error distributions were established to better understand the predictive performance of the models.

5.3.4 Comparisons with Existing Biomass Allometric Models

Previous studies by different authors have established allometric equations for estimating the dry aboveground biomass of oil palms in several tropical regions of the world, i.e., Africa, Amazonia and Asia–Oceania. [Table 5.3](#) summarizes the previously published equations, which were considered here for comparison. The work covered at least four different oil palm species. Depending on the study, the equations were available for the total above-ground biomass or for specific compartments (such as stem or leaves). The data from the seven validation sample were used to verify the applicability of each model to our study area and to compare their performance with the equations developed in this research. Our aim was to determine whether an existing biomass model for oil palm which was developed elsewhere could be used in the

Congo Basin. The evaluations were made by quantifying the errors (ER, %ER, RMSE and %RMSE) for each model relative to the data that were used.

Table 5.3. Existing biomass models that were considered. B = total aboveground biomass (kg); B_F = total aboveground fresh biomass of an oil palm (kg); B_{Stem} = stem biomass (kg); N_F = number of leaves; B_{FSR} = leaf biomass without rachis (kg); B_{Rachis} = rachis biomass (kg); DBH = diameter at breast height (in cm, measured 1.3 m above ground surface); H_{Tcm} = stem height of a palm (cm); CF = correction factor; n = number of palms that were sampled. R^2 = coefficient of determination. The other variables have been previously defined in the text.

Source	Geographic region	Palm species	Existing biomass model (kg tree ⁻¹)	CF	r^2	n
Khalid et al. [4]	Malaysia	<i>Elaeis guineensis</i>	$B_F = 725 + 197 \times H_{TOT}$	0.96	7	
Thenkabail et al. [20]	Benin	<i>Elaeis guineensis</i>	$B_F = 1.5729 \times H_{Tcm} - 8.2835$	0.97	7	
Hughes et al. [25]	Mexico	<i>Astrocaryum mexicanum</i>	$B = 0.3747 \times H_{Tcm} + 3.6334$	0.98	7	
Saldarriaga et al. [18]	Colombia & Venezuela	Common	$B = \exp(3.6272 + 0.5768 \times \ln(DBH^2 H_T)) \times CF / 10^6$	1.02	0.73	15
Goodman et al. [27]	Amazonia (Peru)	Common	$B = \exp(-6.3789 - 0.877 \times \ln(1/DBH^2) + 2.151 \times \ln(H_T))$	0.89	19	
Da Silva et al. [22]	Brazil	<i>Euterpe precatoria</i>	$B = 0.0950 \times (DMF \times DBH^2 H_T)$ $B_{Stem} = \exp(0.1212 + 0.90 \times \ln(DBH^2 H_{Tp}))$ $B_{Leaf} = \exp(0.0065 + 0.69 \times \ln(DBH^2 H_{Tp}))$	0.99	106	
Cole and Ewel [26]	Tropical zone (Costa Rica)	<i>Euterpe oleraceaee</i>	$B_{Stem} = 0.0314 \times (DBH^2 H_T)^{0.917} \times CF$ $B_{FSR} = 0.0237 \times (DBH^2 H_T N_F)^{0.512} \times CF$ $B_{Rachis} = 0.0458 \times (DBH^2 H_T N_F)^{0.388} \times CF$	1.04 1.036 1.036	0.95 0.94 0.90	156 182 187

¹ Da Silva [22] used adjusted values of the coefficient of determination (R_{adj}^2) rather than r^2 .

5.4 Results

5.4.1 Distribution of biomass proportions

Average proportions are shown in [Figure 5.2](#) for the aboveground oil palm biomass per compartment as a function of the DBH class. The aboveground biomass of the 18 oil palms that were sampled was concentrated mainly in the stems (72.51%). Leaf biomass (including petioles, rachises, fruits and leaflets) represented on average 27.50% of the total aboveground biomass. Average biomass proportions of rachises (13.53%) were much higher than those of petioles (7.95%) and fruits and leaflets (6.02%). The difference between the biomass proportions in each compartment by diameter class (48–54 cm vs. 54–58 cm) was analyzed by simple linear regression. Proportions did not significantly differ between the DBH classes ($r^2 = 0.999, p < 0.0001$).

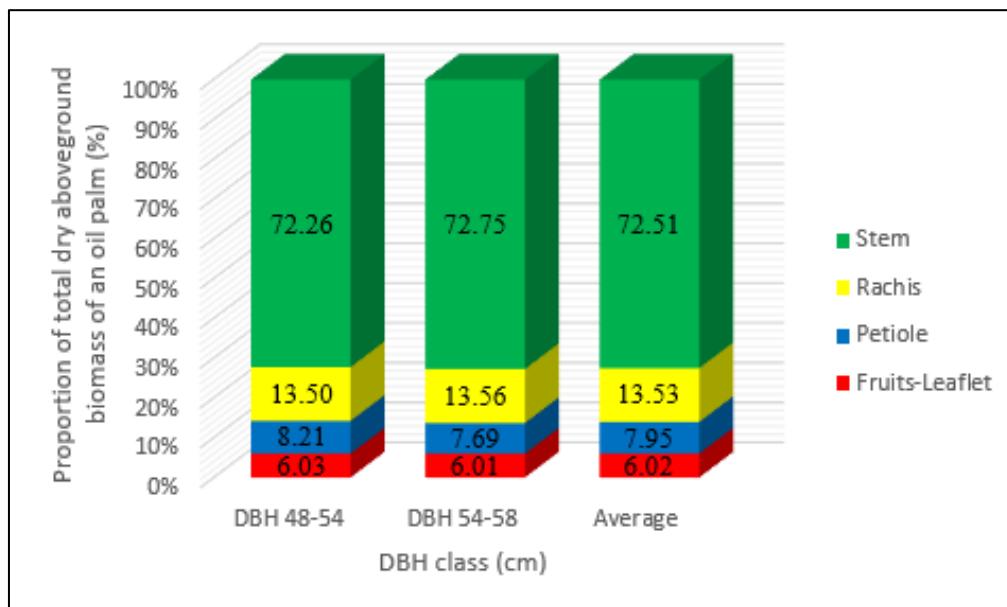


Figure 5.2. Mean proportions of the aboveground biomass for the 18 oil palms, Makouké, central Gabon.

5.4.2 Relationships between variables

Before creating the biomass equations, we first examined the interrelationships between the variables under consideration. Clearly, the question was whether variation in ρ , H_{TOT} , H_T and N_F could be explained by the diameter (DBH). As shown in [Table 5.4](#) and [Figure 5.3](#), the respective allometric relationships were significant ($p < 0.05$) between the dependent variables ρ , H_{TOT} , H_T and N_F , vs. the independent variable DBH, with a moderate to strong r^2 (0.538 to 0.806). The %RMSE was $< 3\%$ ([Table 5.4](#)). On the one hand, the strongest relationship was obtained between the stem height and the DBH ($r^2 = 0.806$; $p = 0.0001$). On the other hand, the weakest relationship (albeit, statistically significant) with the DBH was obtained with the total tree height ($r^2 = 0.538$; $p = 0.010$).

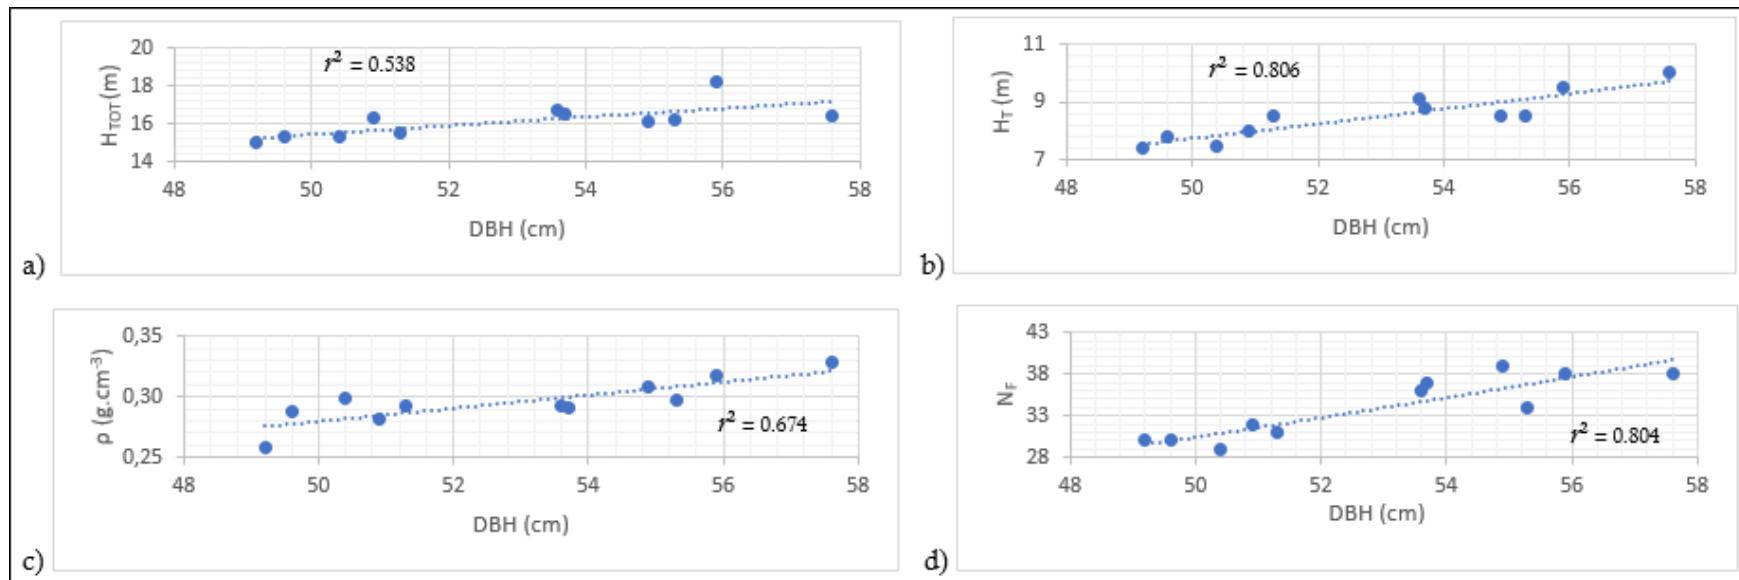


Figure 5.3. Allometric relationships between the variables and the DBH of the 11 oil palms used in this study to develop local biomass models: (a) relationship between total height vs. DBH; (b) relationship between stem height vs. DBH; (c) relationship between infra-density vs. DBH; and (d) relationship between number of leaves vs. DBH.

Table 5.4. Criteria for evaluating the allometric relationships between the DBH and the dependent variables using data from 11 oil palms in Makouké, central Gabon. Values of the coefficients a and b of the models are given; σ is the residual standard error (in kg); p is the p-value of the model. CF is the correction factor for the log-transformed equation. Residual standard errors (σ, in kg), Akaike Information Criterion (AIC), relative error (ER), relative percentage error (%ER), root-mean-square error (RMSE, in kg) and its percentage (%RMSE) are shown for each equation.

Model	a	b	r ²	σ	AIC	CF	P	ER	%ER	RMSE	%RMSE
Model 1: ln(ρ) = a + b×ln(DBH)	-5.057	0.967	0.674	0.037	-73.343	1.0006	0.002	75*10 ⁻⁵	0.075	0.034	2.793
Model 2: ln(N _F) = a + b×ln(DBH)	-3.892	1.868	0.804	0.051	-63.390	1.0011	0.0001	17.5*10 ⁻⁵	0.017	0.046	1.327
Model 3: ln(H _T) = a + b×ln(DBH)	-4.342	1.608	0.806	0.044	-66.843	1.0008	0.0001	34.6*10 ⁻⁵	0.034	0.039	1.869
Model 4: ln(H _{TOT}) = a + b×ln(DBH)	-0.179	0.746	0.538	0.038	-69.769	1.0006	0.010	15.4*10 ⁻⁵	0.015	0.034	1.258

5.4.3 Allometric Biomass models that were developed

Allometric models of the aboveground oil palm biomass were developed for the different compartments, i.e., stem, leaves and the total aerial biomass. Several equations were tested to determine which were the best models; we referred to these as the local models. All the established local allometric models for estimating the aboveground biomass provided low errors overall (**Table 5.5**: %RMSE < 4%; σ < 1 kg for mean biomass = 417.7 kg; $r^2 \geq 0.564$, $p < 0.05$; %ER < 1.3%). Model 6, which was based upon DBH, yielded the highest $r^2 = 0.959$ ($p < 0.0001$) and the lowest errors (%RMSE = 0.54%, %ER = 0.003%) compared to all the other local models (7 and 8) using individual explanatory variables (ρ , H_T and H_{TOT}) (**Table 5.5**).

The local models that were constructed from stem heights (%RMSE < 1.12; $r^2 > 0.8$; $p \leq 0.0001$; AIC < -55.4) were more efficient than those designed using the total heights (%RMSE < 1.8; $r^2 > 0.5$; $p \leq 0.008$; AIC < -45.4). The allometric models of the aboveground biomass using composite variables (DBH²H_T or DBH²H_T ρ) performed in a manner that was relatively similar to those solely based upon DBH (**Table 5.5**).

The allometric relationships between stem and leaf biomass with DBH, as an independent variable (Model 12), were significant with r^2 values of 0.930 and 0.679, respectively. The errors associated with these relationships were relatively small (%RMSE = 0.76%; RMSE = 0.04 kg for stems, %RMSE = 0.10%; RMSE = 2.19 kg for leaves) (**Table 5.5**). All of the allometric models estimating stem and leaf biomasses (13 and 14), with the exception of Model 15, exhibited evaluation performances that were close to those of Model 12 (**Table 5.5**). Errors for Model 15 in predicting stem and leaf biomass were lower (RMSE < 0.094 kg; %RMSE < 1.96%) than those for Models 12, 13 and 14 (RMSE < 0.14 kg; %RMSE < 3.28%). In summary, according to the results that we obtained, the total aboveground biomass of oil palm was best correlated with the DBH compared to the stem or leaf biomass (**Figure 5.4**).

Table 5. 5. Local allometric biomass models that were developed in this study. B is the total dry aboveground oil palm biomass. B_{stem} , B_{leaf} , B_{FSR} and B_{Rachis} are respectively stem, leaf (including petioles, rachis and leaflets), rachis-free leaf and rachis biomasses. P is the *p*-value of the model. Residual standard error (σ , in kg), the correction factor (CF), the ER and the RMSE are shown for each equation.

Model	a	b	r^2	σ	AIC	P	CF	ER	%ER	RMSE	%RMSE	
Allometric equations using infra-density (q) or DBH as the predictor												
Model 5: $\ln(B) = a + b\ln(q)$	8.755	2.223	0.685	0.099	-48.985	0.002	1.0041	22.1×10^{-5}	0.022	0.089	1.488	
Model 6: $\ln(B) = a + b\ln(DBH)$	-6.256	3.100	0.959	0.035	-71.480	< 0.0001	1,0005	2.8×10^{-5}	0.002	0.032	0.535	
Allometric equations using height as the predictor												
Model 7: $\ln(B) = a + b\ln(H_T)$	2.616	1.604	0.824	0.074	-55.383	0.0001	1.0022	12.3×10^{-5}	0.012	0.067	1.112	
Model 8: $\ln(B) = a + b\ln(H_{TOT})$	-0.443	2.333	0.562	0.117	-45.350	0.008	1.0056	30.4×10^{-5}	0.030	0.106	1.755	
Allometric equations using DBH and height as composite predictors												
Model 9: $\ln(B) = a + b\ln(DBH^2H_T)$	-2.335	0.832	0.942	0.042	-67.606	< 0.0001	1.0007	4×10^{-5}	0.004	0.038	0.638	
Allometric equations using DBH, height and infra-density as composite predictors												
Model 10: $\ln(B) = b\ln(DBH^2H_T q)$	0.683	0.999	0.0439	-68.560	0.0001	1.0008	-2.1×10^{-5}	-0.002	0.040	0.669		
Model 11: $\ln(B) = a + b\ln(DBH^2H_T q)$	0.277	0.651	0.938	0.043	-66.938	< 0.0001	1.0008	4.3×10^{-5}	0.004	0.039	0.658	
Allometric equations using DBH, H_T , q or N_F as composite variables to estimate aboveground biomass from its components (stems, rachises, leaves with/without rachises)												
Model 12	$\ln(B_{\text{stem}}) = a + b\ln(DBH)$	-6.776	3.147	0.930	0.048	-64,933	< 0.0001	1.0010	5.6×10^{-5}	0.005	0.043	0.762
	$\ln(B_{\text{leaf}}) = a + b\ln(DBH)$	-7.188	3.014	0.679	0.115	-45,605	0.002	1.0055	51.4×10^{-5}	0.051	0.104	2.197
	$\ln(B_{\text{stem}}) = a + b\ln(DBH^2H_T)$	-2.831	0.848	0.921	0.051	-63,594	< 0.0001	1.0010	6.4×10^{-5}	0.006	0.046	0.810
Model 13	$\ln(B_{\text{FSR}}) = a + b\ln(DBH^2H_T N_F)$	-3.124	0.530	0.564	0.146	-40,430	0.008	1.0088	115.1×10^{-5}	0.115	0.132	3.257
	$\ln(B_{\text{Rachis}}) = a + b\ln(DBH^2H_T N_F)$	-4.041	0.597	0.702	0.122	-44,332	0.001	1.0062	74.9×10^{-5}	0.074	0.111	2.724
Model 14	$\ln(B_{\text{stem}}) = b\ln(DBH^2H_T q)$		0.645	0.999	0.037	-71.844	< 0.0001	1.0006	11×10^{-5}	0.011	0.034	0.610
Model 14	$\ln(B_{\text{leaf}}) = b\ln(DBH^2H_T N_F)$		0.351	0.999	0.103	-46.406	< 0.0001	1.0061	109.6×10^{-5}	0.109	0.110	2.320
Model 15	$\ln(B_{\text{stem}}) = a + b\ln(DBH^2H_T q)$	-0.295	0.678	0.958	0.037	-70.429	< 0.0001	1.0006	3.4×10^{-5}	0.003	0.033	0.594
	$\ln(B_{\text{leaf}}) = a + b\ln(DBH^2H_T N_F)$	-2.852	0.561	0.747	0.103	-48.205	0.001	1.0043	40.4×10^{-5}	0.040	0.093	1.952

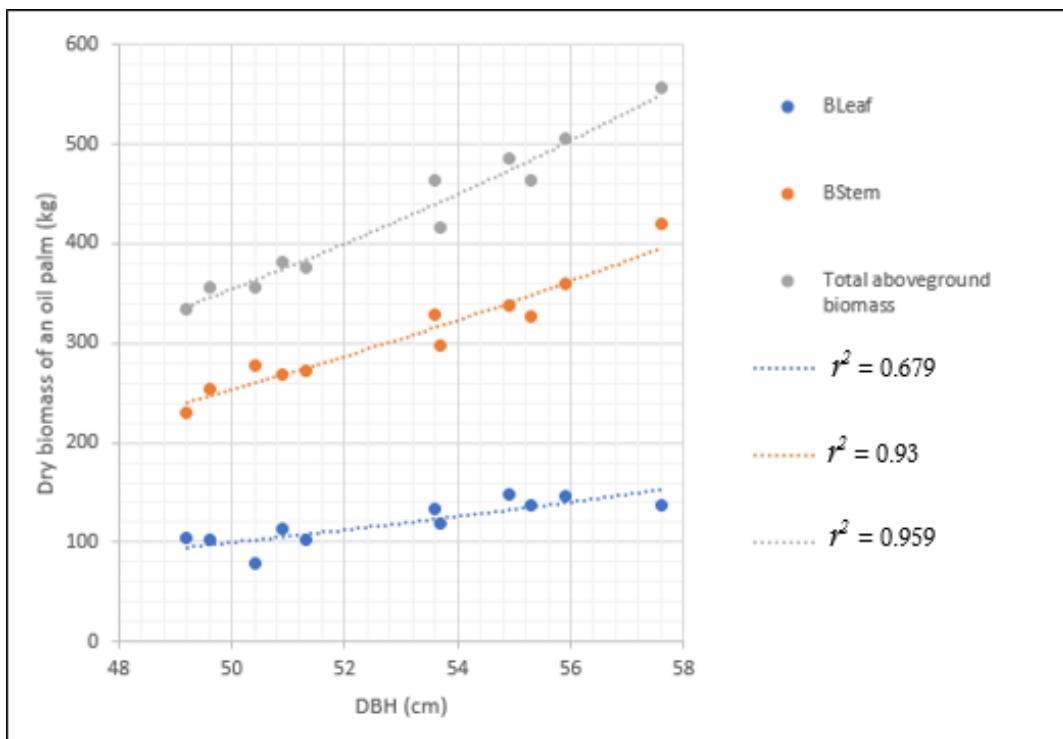


Figure 5.4. Allometric relationships between the biomass components of 11 oil palms and their corresponding DBH.

5.4.4 Validation of local allometric models

Seven palm trees were used to validate the relationships between the individual variables that were considered (ρ , H_{TOT} , H_T and N_F) and the DBH, together with the allometric relationships that were obtained with log sections. Validation results are reported in [Table 5.6](#). All the variables that were considered were significantly related to DBH ($r^2 \geq 0.66$; $p \leq 0.026$), with relatively small errors ($\%RMSE \leq 9.6\%$; $\%ER \leq 7.5\%$). The relationships that were obtained for the total height (Model 4) and infra-density (Model 1) appeared to be the most robust following validation ([Table 5.6](#)).

Table 5.6. Validation of the allometric relationships between the individual explanatory variables (ρ , H_{TOT} , H_T and N_F) and the DBH (for estimates of a and b , see [Table 5.4](#)).

Model	r^2	AIC	P	ER	%ER	RMSE	%RMSE
Model 1: $\ln(Q) = a + b \times \ln(DBH)$	0.787	-60.077	0.008	0.034	3.407	0.014	4.845
Model 2: $\ln(N_F) = a + b \times \ln(DBH)$	0.750	13.371	0.012	0.075	7.552	3.098	9.638
Model 3: $\ln(H_T) = a + b \times \ln(DBH)$	0.660	-3.111	0.026	0.0006	0.068	0.645	7.697
Model 4: $\ln(H_{TOT}) = a + b \times \ln(DBH)$	0.927	-15.660	0.001	0.001	0.136	0.583	3.712

Different local allometric biomass estimation models that were proposed in [Section 5.4.3](#) were validated using the data that were independently collected from the seven sample plots. The same performance evaluation metrics were considered. [Table 5.7](#) summarizes the validation results that were obtained. Adding the stem height and infra-density or the stem height and leaf count to the model using the DBH alone as the predictor improved the predictions, as shown in the results. The introduction of infra-density (ρ) to the models that were based upon the combination (DBH^2H_T) contributed to the improvement of all the validation criteria of these allometric models. As an example, the root mean square error decreased from 8.2% to 5.7% when moving from Model 9 (excluding infra-density) to Model 11 (including infra-density). In the same vein, taking into account the leaf number (N_F) in allometric models using DBH^2H_T improved the estimates of leaf biomass and by extension, the entire palm tree. The results of Allometric Models 14 and 15 clearly showed these improvements compared to models in which the leaves were not considered.

Model 9 yielded the highest r^2 (0.939, $p < 0.0001$), the smallest AIC (45.3) and the lowest %RMSE (8.2%) among all the allometric models using structural parameters that were measured directly on oil palm (DBH and H_T) ([Table 5.7](#)). With the addition of a variable that is not directly measurable, such as infra-density (ρ), Allometric Model 11 slightly improves upon Allometric Model 9. Allometric Model 15 includes both infra-density and leaf number (a parameter usually not available). This model exhibited the best performance in this study, with a relative RMSE of 5% ([Table 5.7](#)). By combining the aboveground biomass of the stems ($DBH^2H_T\rho$) and leaves ($DBH^2H_TN_F$), Model 15 stands out as the best of the local biomass allometric models that were developed in the study ([Table 5.7](#)). The expressions of these three (3) models are described below:

$$\text{Allometric Model 9: } B = 1.0007 \times \exp[-2.335 + 0.832 \times \ln(DBH^2H_T)] \quad (5.5)$$

$$\text{Allometric Model 11: } B = 1.0008 \times \exp[0.277 + 0.65 \times \ln(DBH^2H_T\rho)] \quad (5.6)$$

$$\begin{aligned} \text{Allometric Model 15: } B &= B_{\text{Stem}} + B_{\text{Leaf}} = 1.0005 \times \exp[-0.295 + \\ &0.678 \times \ln(DBH^2H_T\rho)] + 1.0043 \times \exp[-2.852 + 0.561 \times \ln(DBH^2H_TN_F)] \end{aligned} \quad (5.7)$$

Table 5.7. Validation of the local allometric models of oil palm biomass; estimates for a and b are available in [Table 5.5](#)

Model	r^2	AIC	P	ER	%ER	RMSE	%RMSE
Allometric equations using a single explanatory variable, i.e., infra-density or DBH							
Model 6 : $\ln(B) = a + b\ln(DBH)$	0.887	49.601	0.002	0.091	9.109	45.386	11.253
Model 5 : $\ln(B) = a + b\ln(\rho)$	0.757	54.962	0.011	0.010	1.079	38.143	9.457
Allometric equations using height as an explanatory variable							
Model 8: $\ln(B) = a + b\ln(H_{TOT})$	0.730	55.712	0.014	0.012	1.242	41.954	10.402
Model 7: $\ln(B) = a + b\ln(H_T)$	0.810	53.234	0.006	0.042	4.157	38.854	9.633
Allometric equations using DBH and Height as compound explanatory variables							
Model 9: $\ln(B) = a + b\ln(DBH^2H_T)$	0.939	45.305	0.0003	0.065	6.501	33.027	8.188
Allometric equations using DBH, Height, and ρ as compound explanatory variables							
Model 10: $\ln(B) = b\ln(DBH^2H_T \rho)$	0.961	42.153	0.0001	0.048	4.815	26.786	6.641
Model 11: $\ln(B) = a + b\ln(DBH^2H_T \rho)$	0.961	42.206	0.0001	0.042	4.247	23.339	5.786
Allometric equations using biomass components (stems, rachises, leaves with/without rachis)							
Model 12: $\ln(B) = [\ln(B_{Stem}) + \ln(B_{Leaf})] = [a_1 + b_1\ln(DBH) + a_2 + b_2\ln(DBH)]$	0.887	49.605	0.002	0.089	8,916	44.856	11.121
Model 13: $\ln(B) = [\ln(B_{Stem}) + \ln(B_{FSR}) + \ln(B_{Rachis})] = [a_1 + b_1\ln(DBH^2H_T) + a_2 + b_2\ln(DBH^2H_TN_F) + a_3 + b_3\ln(DBH^2H_TN_F)]$	0.956	42.950	0.0001	0.052	5.268	27.325	6.774
Model 14 : $\ln(B) = [\ln(B_{Stem}) + \ln(B_{Leaf})] = [b_1\ln(DBH^2H_TQ) + b_2\ln(DBH^2H_TN_F)]$	0.969	40.519	< 0.0001	0.044	4.420	21.352	5.294
Model 15: $[B_{Stem} + B_{Leaf}] = [a_1 + b_1\ln(DBH^2H_TQ) + a_2 + b_2\ln(DBH^2H_TN_F)]$	0.972	39.922	< 0.0001	0.036	3.684	20.692	5.130

5.4.5 Validation of existing allometric biomass models

Nine existing models ([Table 5.3](#)) were evaluated using the data from the seven palm trees. The results are compiled in [Table 5.8](#). Among the existing allometric models only using stem height as the predictor, the allometric equation Thenk2004a that was proposed by Thenkabail et al. [20] produced the lowest error (%RMSE = 13.7%). Although the values were lower, these results were relatively close to those provided by Allometric Model 7 that was proposed in this study (%RMSE = 9.63%). The other two existing allometric models that were based upon height had errors > 20% ([Table 5.8](#)). In the category of allometric models using the DBH and height together, the two existing models of Hughes et al. [25] and Saldarriaga et al. [18] could not be directly used in the study area because they produced very large estimation errors (%RMSE > 100%), unlike Model 9 in this study (%RMSE of about 8%). The allometric equation DaSilva2015a, which was devised by Da Silva et al. [22], stood out among the models that were based upon DBH, height, infra-density or the dry mass fraction (DMF) as composite explanatory variables. It produced a small error (%RMSE = 9.3%), which was close to that of the Local Allometric Model 11 which was developed in this study (%RMSE = 5.8%). [Figure 5.5a](#) illustrates the proximity of the two allometric models. Finally, in the category of allometric models estimating the total aerial biomass of the palm from the biomass of its components (stems, leaves or rachis) considering the DBH, H_T , and ρ and N_F as composite explanatory variables, the two existing models produced errors of less than 24% ([Table 5.8](#)). The allometric equation DaSilva2015b from Da Silva et al. [22] provided an %RMSE of 10.9%. However, this error was almost double that produced by Allometric Model 15 in this study. [Figure 5.5b](#) illustrates the results of the five existing models that produced the lowest errors in our study area. The results of the three best local allometric models that were proposed in this study are also shown for comparison purposes. Dispersion is greater in the estimated biomasses for larger diameters (>52 cm). The allometric equations ColEwe2006 [26] and Thenk2004b [20] systematically underestimated the biomass in the area. The associated errors were generally > 20%. Other existing allometric models in [Figure 5.5b](#) produced relative errors < 15%, although they were not developed specifically for the region. Of course, local models were more efficient with relative errors that were generally < 10%.

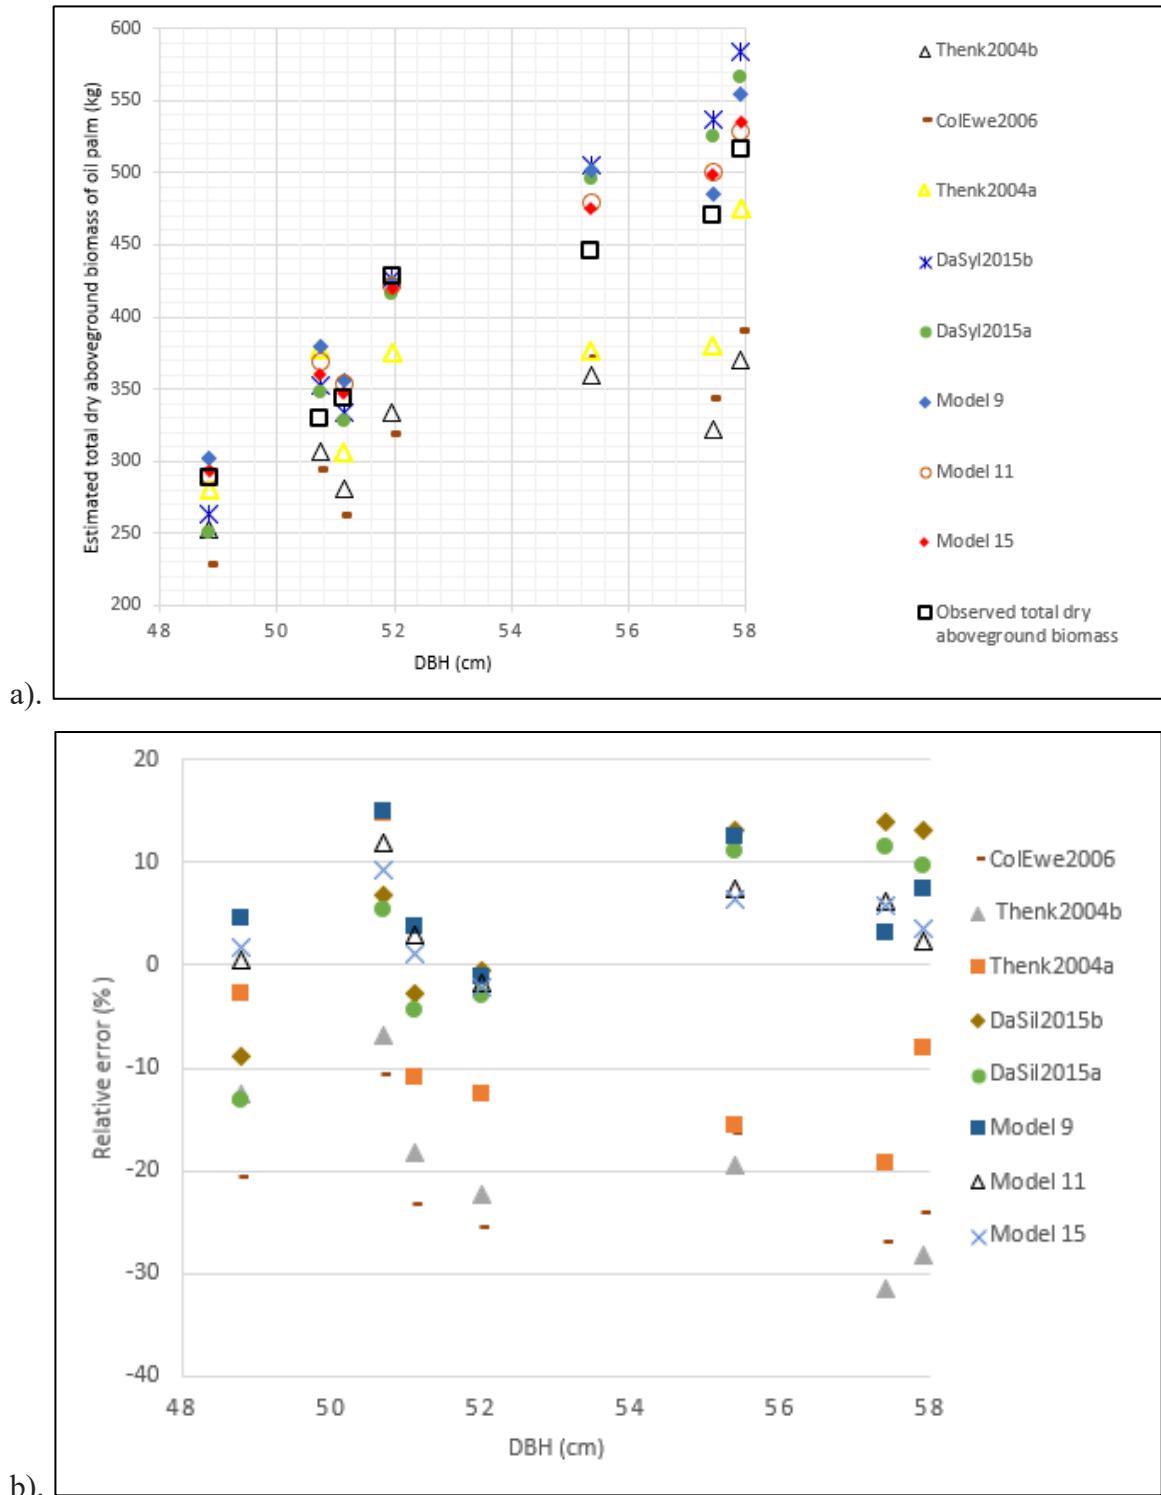


Figure 5.5. Comparison of the selected existing allometric models with the best allometric models that were proposed in this study: (a) biomass variation according to DBH; (b) relative error variation according to DBH.

Table 5.8. Comparison of the existing allometric biomass models to the corresponding local models that were developed in this study

Reference	Name	ER	%ER	RMSE	%RMSE
Allometric equations using height as an explanatory variable					
Khalid et al. [4]	Khal1999	1.725	172.583	669.968	166.109
Thenkabail et al. [20] (Dry biomass model)	Thenk2004b	-0.198	-19.838	96.752	23.988
Thenkabail et al. [20] (Fresh biomass model)	Thenk2004a	-0.077	-7.752	55.317	13.715
This study	Model 7	0.042	4.157	38.854	9.633
Allometric equations using DBH and height as compound explanatory variables					
Saldarriaga et al. [18]	Sald1988	-0.999	-99.999	410.677	101.821
Hughes et al. [25]	Flyn1999	-0.999	-99.996	410.664	101.818
This study	Model 9	0.065	6.501	33.027	8.188
Allometric equations using DBH, height and infra-density or dry-mass fraction as composite explanatory variables					
Goodman et al. [27]	Good2013	-0.994	-99.408	408.402	101.257
Da Silva	DaSil2015a	0.024	2.413	37.699	9.347
et al. [22] (Not compartmentalized allometric biomass model)					
This study	Model 11	0.042	4.247	23.339	5.786
Allometric equations estimating aboveground biomass (B) from biomass components (stems, leaves or rachis) using DBH, H_T and ρ or N_F					
Cole and Ewel [26]	ColEwe2006	-0.211	-21.122	92.841	23.018
Da Silva et al. [22] (Compartmentalized allometric biomass model)	DaSil2015b	0.050	5.007	44.157	10.948
This study	Model 15	0.036	3.684	20.692	5.130

5.5 Discussion

5.5.1 Interpretation of biomass distribution

The distribution of the aboveground oil palm biomass among the components showed that on average the stems produced most of the biomass (about 73%) compared to the leaves (rachis + petiole + fruits/leaflets), which produced a total of about 27%. The palms that were considered in this study were generally older (>30 years) than those that were measured in most previous studies. They were practically at the stage of maximum maturity in the case of plantations. Nevertheless, other studies have reported distributions of relatively similar proportions for younger age classes. For example, Da Silva et al. [22] also noted the high proportion of stem biomass (86.4%) to leaf biomass (13.6%) in Brazil for oil palms with DBHs between 3.9 and 12.7 cm. The results that were obtained by Cole and Ewel [26] in Costa Rica were even more comparable than those obtained in this study, i.e., about 78% for stems and 22% for leaves for 13-year-old oil palms with $\text{DBH} < 20$ cm. According to the various results, the proportions of oil palm compartment biomasses (stem vs. leaf) varied only slightly according to age and diameter in the tropical regions that were considered. This lack of variability could likely be attributed to the maintenance that was practiced in these plantations. In natural environments, palm growth may be less homogeneous, depending upon site conditions, which in turn could affect the proportions of biomass among tree compartments. The plantation considered in this study was composed of old trees of 35 years old. This constitutes a limitation, as it is not representative of young and medium age plantations which can be found in the Congo Basin and elsewhere.

5.5.2 Evaluation of local allometric biomass equations

In this study, the stem diameter was measured at 1.3 m above the ground surface (DBH), consistent with other studies estimating the aboveground biomass of oil palms [22,23,27]. Several allometric relationships were established to estimate the oil palm biomass in this research (see [Table 5.5](#)).

Our results show an improvement in allometric relationships between biomass and DBH when height or infra-density are taken into account ([Table 5.7](#)). The integrative variable DBH^2Ht (Model 9) is effective in estimating palm biomass on the study site, as has been the case in other tropical areas [18,25,36]. The cylindrical shape of the oil palm stem, geometrically characterized by the combination DBH^2Ht , could explain the strong relationship with biomass. Indeed, the latter is essentially concentrated in the stem ([Figure 5.2](#)). Estimating biomass using DBH^2Ht is an alternative, non-destructive method in different tropical oil palm-producing regions.

The infra-density (ρ) of wood varies according to the type of species, plantation density and growing conditions [30]. The average value of ρ obtained for the palm stems that were considered

in this study (>30-years) equals $0.293 \text{ g} \cdot \text{cm}^{-3}$. The estimate was within the range from 0.21 to $0.41 \text{ g} \cdot \text{cm}^{-3}$ that was defined by Supriadi et al. [40] for *Elaeis guineensis*-type palms. The relationship between biomass and infra-density appears to be very significant (see Allometric Model 5, [Table 5.7](#)). Thus, the weighting of the composite variable DBH^2H_T with infra-density resulted in considerable improvement in palm biomass prediction, as demonstrated by the very small error ($\%RMSE = 5.8\%$) that was obtained with Allometric Model 11 ([Table 5.7](#)). The combination of the three variables (DBH , H_T , ρ) has also provided significant results in previous work [[21,22](#)].

To consider the contributions of all the components of the palm, we integrated the biomass that was contained in the leaves with that of the stem. The resulting Allometric Model 15 stands out as the best performing of all models that were proposed in this study, with a $\%RMSE$ of 5.1% ([Table 5.5](#) and [Table 5.7](#)). Previous work in other regions has reported similarly convincing results and demonstrated the importance of considering the contributions of various components into account ([[22,26](#)]; see [Table 5.3](#)). Nevertheless, a close look at the results shows that leaf inclusion did not appreciably improve biomass estimates, compared to the results that were based solely upon $\text{DBH}^2\text{H}_{Tp}$ (Model 11) or DBH^2H_T (Allometric Model 9). Despite incurring larger errors, Allometric Model 9 remains an interesting alternative to Models 11 and 15 in the absence of infra-density or leaf number data.

Although strong relationships were developed in the study, it should be mentioned that the low number of samples used remains a limitation. The study was based on a destructive approach. Thus, only eighteen trees could be felled to acquire the data both for the development of the equations and for their validation. A larger number of samples associated with a wider range of DBH and height values is therefore recommended for future studies.

5.5.3 Comparison of local models to existing allometric biomass models

Several allometric relationships have been proposed for estimating oil palm biomass elsewhere in Africa, Asia–Oceania and the Neotropics (Central and South America). The current study sought to understand whether some of these relationships were directly applicable to our site in the Congo Basin. As expected, several allometric models produced large errors ($\%RMSE > 100\%$), together with unrealistic variation in predicted biomass, especially for the highest DBHs (52 to 58 cm). This was the case for the equations of Khalid et al. [[4](#)], Saldarriaga et al. [[18](#)], Goodman et al. [[27](#)] and Hughes et al. [[25](#)] that were established for Malaysia, Colombia and Venezuela as well as Peru and Mexico, respectively ([Table 5.8](#)). The very high errors could be explained by the very different site conditions and the great disparity in the experimental data that were available for constructing the equations. Nonetheless, the allometric equations of Thenkabail et al. [[20](#)] (Thenk2004a and b), Cole and Ewel [[26](#)] (ColEwe2006) and those of Da Silva et al. [[22](#)] seem to be very applicable to

the Congo Basin. Building upon research that was conducted by Yang et al. [30], we investigated errors that were associated with these five existing allometric relationships, together with our three best local models. [Figure 5.6](#) shows the performance of these different models as a function of the two selected classes of DBH (class 1: 48–52 cm; class 2: 52–58 cm). Among the different allometric models shown, the errors appeared larger for the ColEwe2006 model [26] and Thenk2004b model [20] in both DBH classes, but remained < 25%. The biomass errors observed with the allometric model of Thenkabail et al. [20] could be due to the small stem heights that were used in their study (28–195 cm). Those of Cole and Ewel [26] could possibly be explained by the short to tall oil palms that were considered in the development of their model (1.3 to 20 m). The Thenk2004b allometric model that was developed in Benin and the two models of Da Silva et al. [22] that were developed in Brazil yielded errors < 15%. In particular, the allometric model DaSilv2015a produced results that were close to those of the models proposed in this study, especially in the first DBH class. Indeed, the allometric models of Da Silva et al. [22] were constructed from data comparable to those collected in our study ($n = 20$; $H_T = 8.8$ m; $\rho = 0.3306 \text{ g}\cdot\text{cm}^{-3}$). This could be the cause of their strong performance, especially in class 1 DBH. The DBHs (3.9 and 12.7 cm) that were used to establish the allometric models of Da Silva et al. [22] could have caused the slightly larger errors that were observed in class 2.

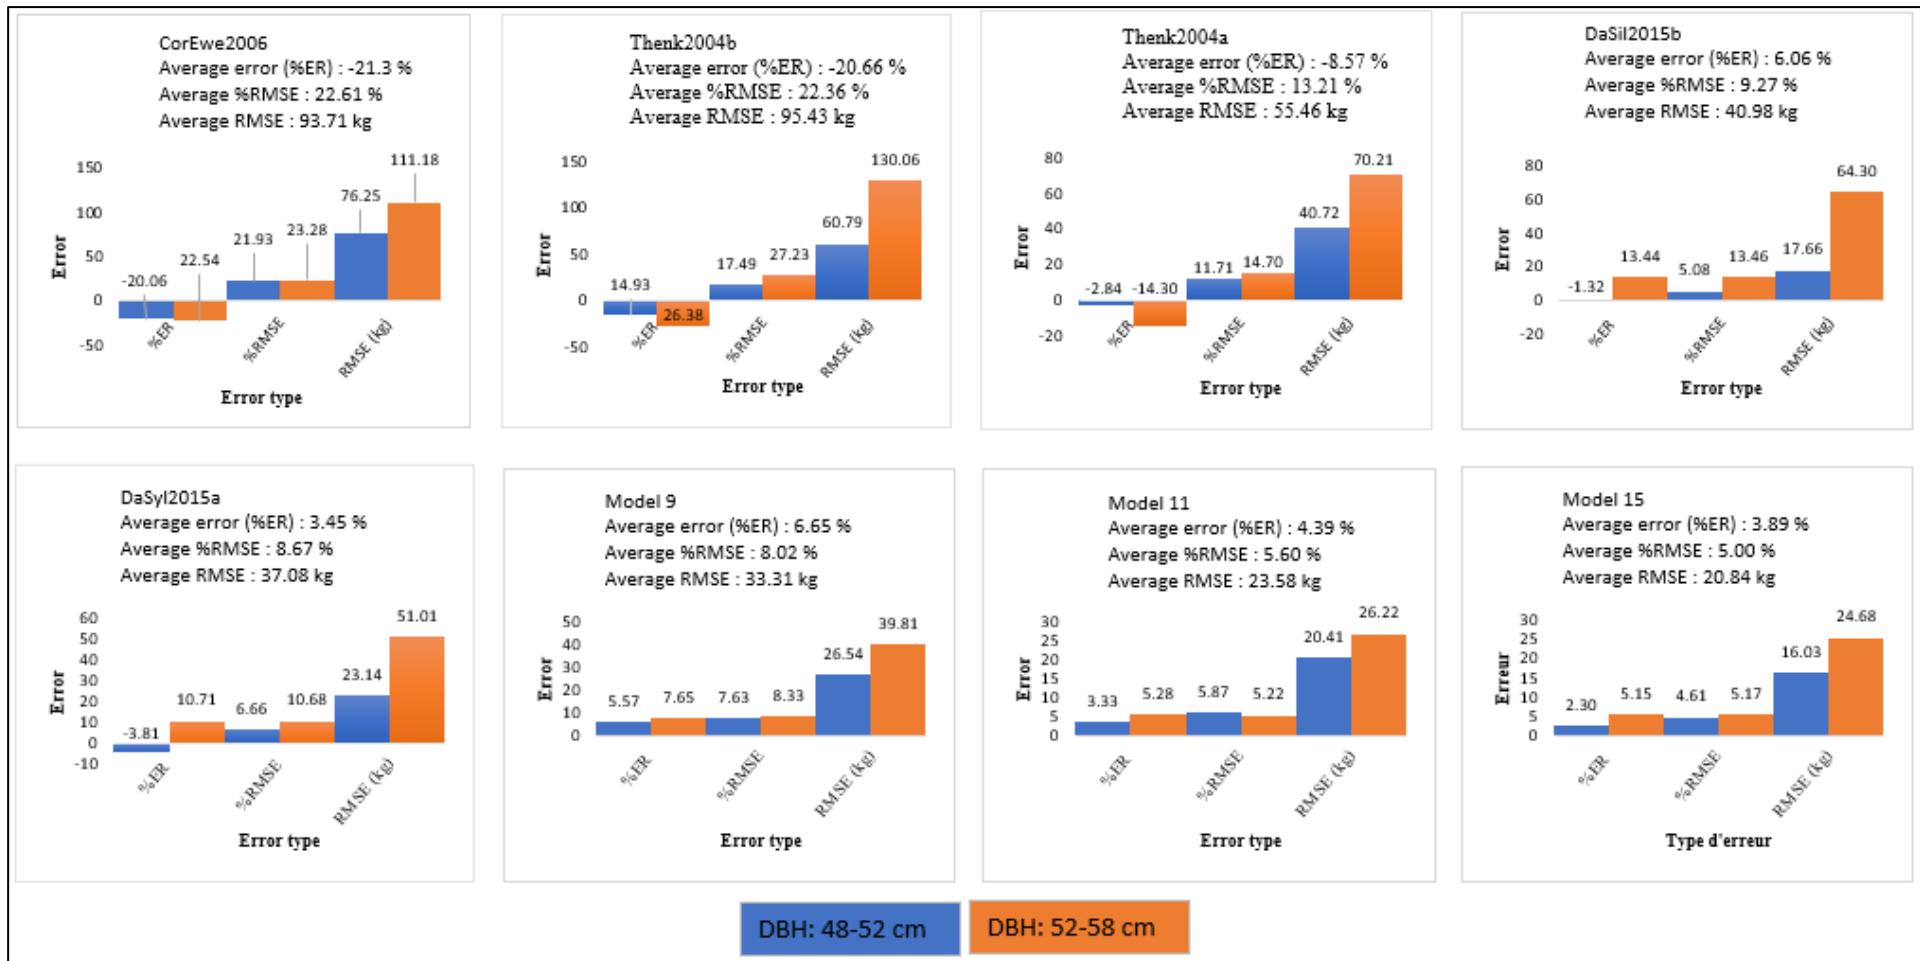


Figure 5.6. Errors in the allometric models when considering the two DBH classes (48–52 cm, 52–58 cm).

5.6 Conclusions

The present study estimated aboveground biomass using the structural parameters of oil palms that were acquired in the Congo Basin using destructive sampling. About three-quarters of the palm biomass was concentrated in the stem. Several allometric equations that were based on diameter at breast height, height, infra-density, number of leaves, or some combination of these different variables, were developed. The composite variable that was based upon the combination (DBH^2H_t) emerged as the most interesting and perhaps useful explanatory variable for estimating oil palm biomass in the current study. It was the basis of the three best models that were obtained. The best of the three (Allometric Model 15) integrates the contributions of leaves and is characterized by a low error (%RMSE about 5%). The second high-performance allometric model, which weights DBH^2H_t by infra-density, also produces a low error of about 6%. The third allometric model (Model 9), which was based solely upon DBH^2H_t , was the most practical alternative, given its relatively small error (about 8%) and the fact that information on infra-density and palm leaf number is not always available. The study shows that some allometric equations developed in other regions could have been used to estimate the palm biomass in the site that we selected in the Congo Basin, but with slightly larger errors than those of the three proposed allometric models. However, several existing models were not applicable because of the large errors they produced in the site, due to differences in palm oil species, age or site conditions.

One of the main limitations in this study resides in the reduced number of samples used to develop and then validate the allometric equations. Only the data from eighteen oil palms were available for this study. Increasing the number of samples in future works would allow the development of probably more robust equations. Such equations are essential to assess the carbon produced by oil palms and understand the impact of the establishment of agro-industrial plantations in tropical forest areas in the context of climate change, while helping their sustainable management. Combinations of data that were acquired from experimental sites in different tropical regions across the globe could make it possible to envisage the development of regional and pan-tropical allometric relationships for estimating the aboveground biomass of oil palms.

Author Contributions

Conceptualization, P.M. and K.G.; methodology, P.M., A.N., K.G.; software, P.M.; validation, P.M. and Kalifa Goïta.; formal analysis, P.M.; investigation, P.M.; resources, P.M., A.N. and A.P.M.B.; data curation, P.M.; writing—original draft preparation, P.M.; writing—review and editing, P.M., K.G., A.N., A.P.M.B.; visualization, P.M.; supervision, K.G.; project administration, P.M.; funding acquisition, P.M. and K.G. All authors have read and agreed to the published version of the manuscript.

Funding

This study was funded by the Programme Canadien de Bourses de la Francophonie (Government of Canada, Department of Foreign Affairs, Trade and Development, Canadian Partnership Branch) and by the Natural Sciences and Engineering Research Council of Canada (NSERC).

Acknowledgments

The authors acknowledge the financial support of the Programme Canadien de Bourses de la Francophonie (Government of Canada, Department of Foreign Affairs, Trade and Development, Canadian Partnership Branch) and the Natural Sciences and Engineering Research Council of Canada (NSERC). The following corporation and government institutions contributed substantially to the data measurement campaign: Olam Palm Gabon; Institut de Recherche en Ecologie Tropicale (IRET); Direction Générale des Eaux et Forêts and the Projet de Développement d'un Système d'Inventaire des Ressources Forestières Nationales contribuant à la Gestion Durable des Forêts (PDSIRFN); the Ecole Nationale des Eaux et Forêts (ENEF); and the Institut de Recherche Agronomiques et Forestières (IRAF). We are grateful to those individuals who participated in field surveys, and in drying and weighing samples, especially Jacques Mouloungou, Bruno Nkoumakali, Inès Nelly Moussavou, and Dieudonné Ndzungoro.

Conflicts of Interest

The authors declare no conflict of interest. The funders had no role in the design of the study; in the collection, analyses, or interpretation of data; in the writing of the manuscript, or in the decision to publish the results.

Appendix 5.A

Table 5.A1. Field and laboratory data that were used to develop aboveground biomass models for oil palm.

Plot number	B _F (Total fresh aboveground biomass of oil palm) (kg)	DBH (Diameter at breast height, 1.3 m) (cm)	H _{TOT} (Total height) (m)	H _T (Stem height) (m)	N _F (Number of leaves per palm)	DMF (Dry-mass fraction) Stem mean	DMF (Mean dry-mass fraction) of oil palm	Q (Mean infra-density of oil palm stem) (g·cm ⁻³)	B _{Rachis} (Dry rachis biomass) (kg)	B _{FSR} (Dry leaf biomass without rachis) (kg)	B _{Leaf} (Dry leaf biomass of oil palm: petioles, fruits, rachises and leaflets) (kg)	B _{Stem} (Dry stem biomass of oil palm) (kg)	B (Total dry aboveground biomass) (kg)
1	1336.80	50.9	16.3	8.0	32	0.2914	0.2857	0.2819	59.8752	52.9108	112.786	269.1137	381.8997
2	1643.30	53.6	16.7	9.1	36	0.3085	0.2818	0.2921	63.0907	70.4268	133.5175	329.4937	463.0112
3	1950.20	57.6	16.4	10.0	38	0.3081	0.2853	0.3279	66.9161	70.0291	136.9452	419.4599	556.4051
4	1176.95	49.2	15.0	7.4	30	0.3105	0.2836	0.2587	50.7830	53.1305	103.9135	229.9270	333.8405
5	1259.35	49.6	15.3	7.8	30	0.3314	0.2832	0.2872	43.1878	59.7505	102.9383	253.6564	356.5947
6	1227.44	50.4	15.3	7.5	29	0.3008	0.2902	0.2993	42.3007	36.6779	78.9786	277.2167	356.1953
7	1462.40	53.7	16.5	8.8	37	0.3365	0.2846	0.2917	55.4954	63.7667	119.2621	296.9790	416.2411
8	1623.30	55.3	16.2	8.5	34	0.3343	0.2855	0.2972	69.4109	67.4892	136.9001	326.5954	463.4955
9	1710.05	54.9	16.1	8.5	39	0.3471	0.2843	0.3077	74.2342	74.5585	148.7927	337.3431	486.1358
10	1294.15	51.3	15.5	8.5	31	0.2972	0.2901	0.2927	55.4954	46.9775	102.4729	272.9780	375.4509
11	1763.1	55.9	18.2	9.5	38	0.3115	0.2869	0.3180	83.1600	63.0959	146.2559	359.6233	505.8792
12	1803.75	57.9	16.6	9.8	38	0.3099	0.2862	0.3030	45.6964	68.9378	114.6342	401.5572	516.1914
13	1156.25	50.7	15.3	8.1	27	0.2987	0.2852	0.2749	29.3832	47.7701	77.1533	252.6299	329.7832
14	1672.25	57.4	17.0	8.5	37	0.2857	0.2814	0.3260	62.5918	74.5959	137.1877	333.4184	470.6061
15	1543.70	55.4	16.6	9.5	32	0.2536	0.2889	0.2935	65.1420	52.9177	118.0597	327.9238	445.9835
16	1216.85	51.1	15.0	7.4	28	0.2650	0.2822	0.2776	41.2474	51.4161	92.6635	250.6978	343.3613
17	1021.80	48.8	14.5	6.65	30	0.2706	0.2826	0.2500	40.8038	48.7180	89.5218	199.1936	288.7154
18	1493.20	52.0	15.1	8.8	33	0.2727	0.2871	0.2950	68.2466	48.4361	116.6827	311.9835	428.6662

References

- Food and Agriculture Organization. *Évaluation des Ressources Forestières Mondiales 2015 : Comment les Forêts de la Planète Changent-Elles?* 2nd ed.; FAO: Rome, Italy, 2016; pp. 30–31. Available online: <http://www.fao.org/3/a-i4793f.pdf> (accessed on 28 April 2018).
- Keenan, R.J.; Reams, G.A.; Achard, F.; de Freitas, J.V.; Grainger, A.; Lindquist, R. Dynamics of global forest area: Results from the FAO Global Forest Resources Assessment 2015. *For. Ecol. Manag.* **2015**, *352*, 9–20. [[Google Scholar](#)] [[CrossRef](#)]
- Tuma, J.; Fleiss, S.; Eggleton, P.; Frouz, J.; Klimes, P.; Lewis, O.T.; Yusah, K.M.; Fayle, T.M. Logging of rainforest and conversion to oil palm reduces bioturbator diversity but not levels of bioturbation. *Appl. Soil Ecol.* **2019**, *144*, 123–133. [[Google Scholar](#)] [[CrossRef](#)]
- Khalid, H.; Zin, Z.Z.; Anderson, J.M. Quantification of oil palm biomass and nutrient value in a mature plantation. I, Above-ground biomass. *J. Oil Palm Res.* **1999**, *11*, 23–32. Available online: <http://jopr.mpopb.gov.my/wp-content/uploads/2013/07/jopr11n1-p31.pdf> (accessed on 20 October 2018).
- Folefack, A.J.J.; Ngo Njiki, G.M.; Darr, D. Safeguarding forests from smallholder oil palm expansion by more intensive production? The case of Ngwei forest (Cameroon). *For. Policy Econ.* **2019**, *101*, 45–61. [[Google Scholar](#)] [[CrossRef](#)]
- Olorunfemi, I.E.; Komolafe, A.A.; Fasinmirin, J.T.; Olufayo, A.A. Biomass carbon stocks of different land use management in the forest vegetative zone of Nigeria. *Acta Oecol.* **2019**, *95*, 45–56. [[Google Scholar](#)] [[CrossRef](#)]
- Megevand, C.; Mosnier, A.; Hourticq, J.; Sanders, K.; Doetinchem, N.; Streck, C. *Deforestation Trends in the Congo Basin: Reconciling Economic Growth and Forest Protection*; The World Bank, Directions in Development—Environment and Sustainable Development: Washington, DC, USA, 2013; pp. 4–118. [[Google Scholar](#)] [[CrossRef](#)]
- Glinskis, E.A.; Gutiérrez-Vélez, V.H. Quantifying and understanding land cover changes by large and small oil palm expansion regimes in the Peruvian Amazon. *Land Use Policy* **2019**, *80*, 95–106. [[Google Scholar](#)] [[CrossRef](#)]
- De Almeida, A.S.; Vieira, I.C.G.; Ferraz, S.F.B. Long-term assessment of oil palm expansion and landscape change in the eastern Brazilian Amazon. *Land Use Policy* **2020**, *90*, 104321. [[Google Scholar](#)] [[CrossRef](#)]
- Rivera, Y.D.; Moreno, A.L.; Romero, H.M. Biochemical and physiological characterization of oil palm interspecific hybrids (*Elaeis oleifera* × *Elaeis guineensis*) grown in hydroponics. *Acta Biol. Colomb.* **2013**, *18*, 465–472. Available online: <https://www.researchgate.net/publication/257938174> (accessed on 11 January 2020).

11. Meléndez, M.R.; Ponce, W.P. Pollination in the oil palms *Elaeis guineensis*, *E. oleifera* and their hybrids (OxG), in tropical America. *Pesqui. Agropecu. Trop.* **2016**, *46*, 102–110. [[Google Scholar](#)] [[CrossRef](#)]
12. Pacheco-Palencia, L.A.; Mertens-Talcott, S. Chemical composition, antioxidant properties, and thermal stability of a phytochemical enriched oil from Acai (*Euterpe oleracea* Mart.). *J. Agric. Food Chem.* **2008**, *56*, 4631–4636. [[Google Scholar](#)] [[CrossRef](#)]
13. Morel, A.C.; Fisher, J.B.; Malhi, Y. Evaluating the potential to monitor aboveground biomass in forest and oil palm in Sabah, Malaysia, for 2000–2008 with Landsat ETM+ and ALOSPALSAR. *Int. J. Remote Sens.* **2012**, *33*, 3614–3639. [[Google Scholar](#)] [[CrossRef](#)]
14. Kho, L.-K.; Rudbeck Jepsen, M. Carbon stock of oil palm plantations and tropical forests in Malaysia: A review. *Singap. J. Trop. Geogr.* **2015**, *36*, 249–266. [[Google Scholar](#)] [[CrossRef](#)]
15. Lahteenoja, O.; Ruokolainen, K.; Schulman, L.; Oinonen, M. Amazonian peatlands: An ignored C sink and potential source. *Glob. Change Biol.* **2009**, *15*, 2311–2320. [[Google Scholar](#)] [[CrossRef](#)]
16. Neumann, M.; Moreno, A.; Mues, V.; Häkkinen, S.; Mura, M.; Bouriaud, O.; Lang, M.; Achten, W.M.J.; Thivolle-Cazat, A.; Bronisz, K.; et al. Comparison of carbon estimation methods for European forests. *For. Ecol. Manag.* **2016**, *361*, 397–420. [[Google Scholar](#)] [[CrossRef](#)]
17. Tinker, P.B.H.; Smilde, K.W. Dry-matter production and nutrient content of plantation oil palms in Nigeria. II. Nutrient Content. *Plant. Soil* **1963**, *19*, 350–363. Available online : <https://www.jstor.org/stable/42933246> (accessed on 15 May 2018). [[CrossRef](#)]
18. Saldarriaga, J.G.; West, D.C.; Tharp, M.L.; Uhl, C. Long-term chronosequence of forest succession in the upper Rio Negro of Colombia and Venezuela. *J. Ecol.* **1988**, *76*, 938–958. [[Google Scholar](#)] [[CrossRef](#)]
19. Yuen, J.Q.; Fung, T.; Ziegler, A.D. Review of allometric equations for major land covers in SE Asia: Uncertainty and implications for above- and below-ground carbon estimates. *For. Ecol. Manag.* **2016**, *360*, 323–340. [[Google Scholar](#)] [[CrossRef](#)]
20. Thenkabail, P.S.; Stucky, N.; Griscom, B.W.; Ashton, M.S.; Diels, J.; van der Meer, B.; Enclona, E. Biomass estimations and carbon stock calculations in the oil palm plantations of African derived savannas using IKONOS data. *Int. J. Remote* **2004**, *25*, 5447–5472. [[Google Scholar](#)] [[CrossRef](#)]
21. Corley, R.H.V.; Tinker, P.B.H. *The Oil Palm*, 4th ed.; Blackwell Science: Hoboken, NJ, USA, 2003; pp. 89–103. [[Google Scholar](#)]
22. Da Silva, F.; Suwa, R.; Kajimoto, T.; Ishizuka, M.; Higuchi, N.; Kunert, N. Allometric equations for estimating biomass of *Euterpe precatoria*, the most abundant palm species in the Amazon. *Forests* **2015**, *6*, 450–463. [[Google Scholar](#)] [[CrossRef](#)]

23. Kotowska, M.M.; Leuschner, C.; Triadiati, T.; Meriem, S.; Hertel, D. Quantifying above- and belowground biomass carbon loss with forest conversion in tropical lowlands of Sumatra (Indonesia). *Glob. Change Biol.* **2015**, *21*, 3620–3634. [[Google Scholar](#)] [[CrossRef](#)]
24. Aholoukpè, H.; Dubos, B.; Flori, A.; Deleporte, P.; Amadji, G.; Chotte, J.L.; Blavet, D. Estimating aboveground biomass of oil palm: Allometric equations for estimating frond biomass. *For. Ecol. Manag.* **2013**, *292*, 122–129. [[Google Scholar](#)] [[CrossRef](#)]
25. Hughes, R.F.; Kauffman, J.B.; Jaramillo, V.J. Biomass, carbon, and nutrient dynamics of secondary forests in a humid tropical region of Mexico. *Ecology* **1999**, *80*, 1892–1907. [[Google Scholar](#)] [[CrossRef](#)]
26. Cole, T.G.; Ewel, J.J. Allometric equations for four valuable tropical tree species. *For. Ecol. Manag.* **2006**, *229*, 351–360. [[Google Scholar](#)] [[CrossRef](#)]
27. Goodman, R.C.; Phillips, O.L.; Del Castillo Torres, D.; Freitas, L.; Cortese, S.T.; Monteagudo, A.; Baker, T.R. Amazon palm biomass and allometry. *For. Ecol. Manag.* **2013**, *310*, 994–1004. [[Google Scholar](#)] [[CrossRef](#)]
28. Moraes, R.M.; Borchsenius, F.; Blicher-Mathiesen, U. Notes on the biology and uses of the Motacú palm (*Attalea phalerata*, Arecaceae) from Bolivia. *Econ. Bot.* **1996**, *50*, 423–428. Available online: www.jstor.org/stable/4255886 (accessed on 10 January 2020).
29. Sunaryathy, P.-I.; Suhasman Kanniah, K.-D.; Tan, K.-P. Estimating aboveground biomass of oil palm trees by using the destructive method. *World J. Agric. Res.* **2015**, *3*, 17–19. [[Google Scholar](#)] [[CrossRef](#)]
30. Yang, X.; Blagodatsky, S.; Liu, F.; Beckschäfer, P.; Xu, J.; Cadisch, G. Rubber tree allometry, biomass partitioning and carbon stocks in mountainous landscapes of sub-tropical China. *For. Ecol. Manag.* **2017**, *404*, 84–99. [[Google Scholar](#)] [[CrossRef](#)]
31. Rondeux, J. *La Mesure des Arbres et des Peuplements Forestiers*, 2nd ed.; Les Presses Agronomiques de Gembloux : Gembloux, Belgium, 1999; pp. 97–108. [[Google Scholar](#)]
32. Bauwens, S.; Fayolle, A. Protocole de Collecte des Données sur le Terrain et au Laboratoire Nécessaires pour Quantifier la Biomasse Aérienne des Arbres et pour l'établissement d'équations Allométriques. *Nature +* **2014**, *40*. [[Google Scholar](#)] [[CrossRef](#)]
33. Gould, S.J. Allometry and size in ontogeny and phylogeny. *Biol. Rev.* **1966**, *41*, 587–640. [[Google Scholar](#)] [[CrossRef](#)]
34. Brown, S.; Gillespie, A.J.R.; Lugo, A.E. Biomass estimation methods for tropical forests with applications to forest inventory data. *For. Sci.* **1989**, *35*, 881–902. [[Google Scholar](#)] [[CrossRef](#)]

35. Onyekwelu, J.-C. Above-ground biomass production and biomass equations for even-aged *Gmelina arborea* (ROXB) plantations in southwestern Nigeria. *Biomass Bioenerg.* **2004**, *26*, 39–46. [[Google Scholar](#)] [[CrossRef](#)]
36. Chave, J.; Andalo, C.; Brown, S.; Cairns, M.A.; Chambers, J.Q.; Eamus, D.; Fölster, H.; Fromard, F.; Higuchi, N.; Kira, T.; et al. Tree allometry and improved estimation of carbon stocks and balance in tropical forests. *Oecologia* **2005**, *145*, 87–99. [[Google Scholar](#)] [[CrossRef](#)] [[PubMed](#)]
37. Ngomanda, A.; Engone Obiang, L.N.; Lebamba, J.; Moundounga Mavouroulou, Q.; Gomat, H.; Mankou, G.S.; Loumeto, J.; Midoko Iponga, D.; Kossi Ditsouga, F.; Zinga Koumba, R.; et al. Site-specific versus pantropical allometric equations: Which option to estimate the biomass of a moist central African forest? *For. Ecol. Manag.* **2014**, *312*, 1–9. [[Google Scholar](#)] [[CrossRef](#)]
38. Hansen, E.H.; Gobakken, T.; Bollandsås, O.M.; Zahabu, E.; Næsset, E. Modeling aboveground biomass in dense tropical submontane rainforest using airborne laser scanner data. *Remote Sens.* **2015**, *7*, 788–807. [[Google Scholar](#)] [[CrossRef](#)]
39. Kuyah, S.; Dietz, J.; Muthuri, C.; Jamnadass, R.; Mwangi, P.; Coe, R.; Neufeldt, H. Allometric equations for estimating biomass in agricultural landscapes: I. Aboveground biomass. *Agric. Ecosyst. Environ.* **2012**, *158*, 216–224. [[Google Scholar](#)] [[CrossRef](#)]
40. Supriadi, A.; Rachman, O.; Sarwono, E. Characteristics and sawing properties of oil-palm (*Elaeis guineensis* Jacq.) wood logs. *Mexique Penelitian Hasil Hutan* **1999**, *17*, 1–20. [[Google Scholar](#)] [[CrossRef](#)]

CHAPITRE 6. Evaluation of FORMOSAT-2 and PlanetScope imagery for aboveground oil palm biomass estimation in a mature plantation in the Congo Basin (Article 2)

6.1 Présentation de l'article

Dans cet article, des images satellitaires optiques de hautes résolutions spatiales sont utilisées pour estimer la BA des palmiers à huile d'une plantation mature dans le Bassin du Congo. Il n'existe pas, aux meilleures de nos connaissances, d'études de télédétection publiées sur l'estimation de la BA des palmiers à huile dans le Bassin du Congo. À cet égard, l'article est une contribution scientifique originale. Il est tout aussi original par les approches proposées. Des données d'inventaire (DHP et H_T) inédites des palmiers à huile sur pied de 35 ans ont été mesurés sur le terrain à Makouké au Gabon dans 40 placettes échantillons de 30,8 m×30,8 m. Le nombre de palmiers à huile par placette échantillon a aussi été inventorié sur le terrain. La surface terrière (ST) et la densité des palmiers à huile (D) par hectare ont été déterminées. Des indices de la transformée de Fourier basée sur l'ordination texturale (FOTO) ont été produits avec les bandes proches infrarouges des images satellitaires FORMOSAT-2 et PlanetScope pour décrire la texture et estimer la BA des palmiers à huile matures. Ces travaux ont été effectués avec des différences au niveau des résolutions spatiales et des corrections radiométriques de FORMOSAT-2 et PlanetScope. Des relations ont été établies entre les variables explicatives de la BA et les indices FOTO de deux types d'image. Les relations entre ces variables et les indices FOTO PC1 ont été les plus fortes et significatives (R^2 entre 0,5 et 0,84; $p < 0,0001$). Les BA des palmiers à huile de terrain ont également été estimées avec l'équation allométrique de Migolet *et al.*, (2020) utilisant la variable intégrée DHP²H_T. Les modèles de BA ont été développés avec les régressions multivariées par spline adaptative (MARS) et les régressions linéaires multiples (RLM) à l'aide des indices FOTO des images de l'étude. De tous les modèles développés, la BA a mieux été estimée avec les modèles MARS (%RMSE < 9,5%) que RLM (%RMSE < 10,1%) à l'aide des indices FOTO FORMOSAT-2 au détriment de PlanetScope. Une carte de BA des palmiers à huile a été produite pour la première fois dans le Bassin du Congo avec le meilleur modèle de l'étude (utilisant MARS et les indices FOTO FORMOSAT-2). Au-delà des résultats obtenus, le bruit radiométrique des images, les erreurs de mesures de terrain et le nombre de placettes échantillons de l'étude demeurent des limites pour l'exploitation des indices FOTO et le développement des modèles de BA. Les travaux de l'article 2 ont fait l'objet d'une présentation par affiche au 40^{ème} congrès Canadien de Télédétection et Géomatique Atlantique 2019 organisé par la Société Canadienne de

Télédétection (SCT) à Fredericton (Nouveau Brunswick), Canada. Les résultats des modèles développés et de la carte de BA ont été publiés dans le journal *Remote Sensing* :

Migolet, P. et Goïta, K. (2020) *Evaluation of FORMOSAT-2 and PlanetScope Imagery for Aboveground Oil Palm Biomass Estimation in a Mature Plantation in the Congo Basin.* *Remote Sensing*, vol. 12, n°18, p. 2926.

Le manuscrit publié est présenté dans les pages qui suivent.

**Evaluation of FORMOSAT-2 and PlanetScope imagery for
aboveground oil palm biomass estimation in a mature
plantation in the Congo Basin**

by Pierre Migolet and Kalifa Goïta

Remote Sensing

Volume 12, No 9, 2926, 9 September 2020

Evaluation of FORMOSAT-2 and PlanetScope imagery for aboveground oil palm biomass estimation in a mature plantation in the Congo Basin

Pierre Migolet ^{1*} and Kalifa Goïta ¹

¹ Centre d'applications et de recherches en télédétection (CARTEL), Département de géomatique appliquée, Université de Sherbrooke, Sherbrooke, Québec, Canada.

* Author to whom correspondence should be addressed

Abstract

The present study developed methods using remote sensing for estimation of total dry aboveground biomass (AGB) of oil palm in the Congo Basin. To achieve this, stem diameters at breast height (DBH, 1.3 m) and stem heights were measured in an oil palm plantation located in Gabon (Congo Basin, Central Africa). These measurements were used to determine AGB in-situ. The remote sensing approach that was used to estimate AGB was textural ordination (FOTO) based upon Fourier transforms that were applied, respectively, to PlanetScope and FORMOSAT-2 satellite images taken from the area. The FOTO method is based on the combined use of two-dimensional (2D) Fast Fourier Transform (FFT) and Principal Component Analysis (PCA). In the context of the present study, it was used to characterize the variation in canopy structure and to estimate the aboveground biomass of mature oil palms. Two types of equations linking FOTO indices to in-situ biomass were developed: multiple linear regressions (MLR); and multivariate adaptive spline regressions (MARS). All best models developed yielded significant results, regardless of whether they were derived from PlanetScope or from FORMOSAT-2 images. Coefficients of determination (R^2) varied between 0.80 and 0.92 ($p \leq 0.0005$); and relative root mean-square-errors (%RMSE) were less than 10.12% in all cases. The best model was obtained using MARS approach with FOTO indices from FORMOSAT-2 (%RMSE = 6.09%).

Keywords: aboveground biomass; oil palms; Congo Basin; textural ordination and Fourier transform; multivariate adaptive regression splines; multiple linear regression; remote sensing

Résumé

La présente étude a développé des méthodes utilisant la télédétection pour l'estimation de la biomasse aérienne totale sèche (BA) du palmier à huile dans le Bassin du Congo. Pour ce faire, des diamètres de tige à hauteur de poitrine (DHP, 1,3 m) et des hauteurs de tige ont été mesurés dans une plantation de palmiers à huile située au Gabon (Bassin du Congo, Afrique centrale). Ces mesures ont été utilisées pour déterminer la BA *in situ*. L'approche de télédétection qui a été utilisée pour estimer la BA était la transformée de Fourier basée sur l'ordination texturale (FOTO). Celle-ci a été appliquée, respectivement, aux images satellites PlanetScope et FORMOSAT-2 prises dans la zone. La méthode FOTO est basée sur l'utilisation combinée de la transformation de Fourier rapide (FFT) bidimensionnelle (2D) et de l'analyse en composantes principales (ACP). Dans le cadre de la présente étude, il a été utilisé pour caractériser la variation de la structure de la canopée et pour estimer la biomasse aérienne des palmiers à huile matures. Deux types d'équations liant les indices FOTO à la biomasse *in situ* ont été développés : les régressions linéaires multiples (RLM); et les régressions multivariées par splines adaptatives (MARS). Tous les meilleurs modèles développés ont donné des résultats significatifs, qu'ils soient dérivés de PlanetScope ou d'images FORMOSAT-2. Les coefficients de détermination (R^2) variaient entre 0,80 et 0,92 ($p \leq 0,0005$); et les erreurs quadratiques moyennes relatives (% RMSE) étaient inférieures à 10,12 % dans tous les cas. Le meilleur modèle a été obtenu en utilisant l'approche MARS avec des indices FOTO de FORMOSAT-2 (% RMSE = 6,09 %).

Mots-clés : biomasse aérienne ; palmiers à huile ; Bassin du Congo ; transformée de Fourier et ordination texturale ; régression multivariée par spline adaptative ; régression linéaire multiple ; télédétection

6.2 Introduction

The amassing information on the total dry aboveground biomass (AGB) of plants is essential for understanding and monitoring their contributions to the global carbon cycle, together with their responses to climate change [1,2]. On small parcels of land, AGB can be estimated without too much difficulty from the complete biomass harvest of field sample plots and, subsequently, extrapolated to the unit area [3]. Another more common approach develops functional allometric relationships between field measurements of aboveground tree dry masses and structural parameters, such as DBH (diameter at breast height), stem height, basal area, wood density or crown area [3,4,5]. Over large areas, the financial constraints that are imposed by high costs of data collection, together with the large quantities of data that must necessarily be collected, have always limited the estimation of AGB.

Several studies have demonstrated the potential for using remote sensing as a complementary alternative for overcoming these limitations [5,6,7]. Predictive relationships can be established between structural variables and remotely sensed data [1,3,6,8,9]. These relationships are generally empirical, often have local or regional scopes, and are frequently difficult to transfer in space and time. In the tropics, optical and radar images are often affected by saturation due to high biomass values [3,6,10,11,12]. LiDAR (Light Detection And Ranging) permits characterization of different biomass levels in tropical forests, but data acquisition remains expensive, thereby limiting their use over large areas [3,6,12,13].

Studies focusing upon the estimation of oil palm biomass are relatively limited. Most approaches that are used in this context are based upon analyses of radiometric intensity or vegetation indices from medium- or high-spatial resolution optical images [4,10,11]. Some research works have recommended contextual analysis to exploit textural and structural elements within images for estimating aboveground forest biomass [6,14,15,16,17]. This recommendation was motivated by the complex nature of canopy structures, and the saturation observed in the high biomass values estimated with non-textural remote sensing approaches [14].

Satellite images provide useful information describing the texture of vegetation in various landscapes (forests, oil palms, etc.). This information also contributes to the estimation of AGB. Several authors recommend the use of FOTO (Fourier transform based on textural ordination) to exploit the information provided by the images [6,8,14,15]. FOTO is a spectral approach, which could be used to characterize the structure of the canopy in terms of coarse/fine texture, and open/ closed canopy. Two techniques are used to implement the FOTO approach, i.e., the two-dimensional fast Fourier transform (FFT 2D) and principal component analysis (PCA). FFT 2D converts spatial information into the frequency domain, and PCA performs the

ordination of the r-spectrum values of FFT 2D [6,8,14]. These values could be used to classify the texture of the canopy and characterize landscapes (mature, young, degraded vegetation, etc.). These same values are also considered as FOTO indices that can predict the AGB. The FOTO method is based on the hypothesis that frequency signatures are strongly correlated with the grain size of the canopy [8,14].

The repetitive canopy structure of vegetation has been regularly analyzed with the FOTO approach, by converting the intensity signal into different spatial frequencies. This conversion is carried out using very high spatial resolution images [8,17]. The FOTO method has often been applied with aerial photographs and satellite images from different platforms, including Google Earth, SPOT 5, or Ikonos [6,8,14,16]. Several studies have shown its efficiency in analyzing the canopy texture, and predicting AGB [6,14,16,17,18,19]. The FOTO method is not affected by the saturation of the estimated aboveground biomass values, and is also able to estimate various stand variables, such as basal area, tree density, diameter, or height [6]. For example, the FOTO approach has been exploited to estimate the biomass of mangroves in French Guiana [6]. Singh et al. [14a] also established AGB models of mixed landscapes (forest and oil palms of varying ages of 5–8 years) in Malaysia using FOTO indices. The approach was also used to map relief and landscape spatial entities of a border area between French Guiana and Brazil [20]. The forest containing the arctic tree line in Russia has also been classified using the FOTO method [19]. In these different studies, the FOTO indices show interesting correlations with various characteristics of vegetation, including AGB.

Prediction models that have been generally used are multiple linear regressions (MLR), which link vegetation structural parameters to FOTO indices that are derived from satellite images [6,8,14,18,21]. The major disadvantage of MLR methods is that they do not account for non-linearities, which are frequent when ecological variables are considered [7,22,23]. Several studies that are based upon MLRs have reported significant results in estimating AGB of forests [6,16,24] and oil palm plantations [14].

Approaches beyond MLRs are being used increasingly to estimate AGB. These include, for example, machine learning methods or multivariate techniques that are capable of dealing with non-linearities in the relationships between variables [23,25,26]. For example, Multivariate Adaptive Regression Splines (MARS) offers some promise. MARS is a non-parametric, recursive modelling algorithm that was introduced by [27]. Yet, its use has not been widely explored in the field of remote sensing, particularly in regard to estimating AGB [23]. MARS models the interactions and non-linearity of the data by establishing non-linear regression models, based upon a product of functions that are referred to as “smoothed basis

functions” [23,28,29]. MARS has been successfully used in other fields, including ecology [30], medicine [31], pedology [32], hydrology [33] and biomass energy [34].

Despite the diversity of remote sensing data available, the FOTO approach has not been used extensively. In particular, it has not been evaluated in combination with MARS or MLR approaches using various images, such as FORMOSAT-2 and PlanetScope, to describe canopy texture and estimate *AGB*. Studies on oil palms are rather limited or nonexistent. The relationships between FOTO indices and structural parameters of oil palms have not been established yet in the tropical zones, except for young oil palms (≤ 9 years old) *AGB* [14].

In this paper, we applied the FOTO method on the near infrared bands of FORMOSAT-2 and PlanetScope to describe the textural structure of the canopy and assess *AGB* of mature oil palms (≥ 30 years) in the Congo Basin. Several oil palms *AGB* models were developed with MARS and MLR using the FOTO indices derived from each image in the study area. The models were compared to select those predicting the best results. This study was the first attempt to produce *AGB* map of mature oil palms in the Congo Basin using the combination of MARS or MLR and FOTO indices.

6.3 Materials and methods

6.3.1 Description of the study area

The study site was located in Makouké, Moyen-Ogooué Province, Gabon. Gabon is a Central African country covered by moist tropical forest typical of the Congo Basin. Its boundaries extend from about 2° N to 4° S (Equatorial Guinea and Cameroon in the north, Republic of the Congo in the south) and from 9° E to 15° E (Atlantic Ocean in the west, Republic of the Congo in the east). The site is an oil palm plantation block that was located between $10^{\circ}24'27''$ E and $10^{\circ}24'57''$ E, and $0^{\circ}30'6''$ S and $0^{\circ}30'16''$ S ([Figure 6.1](#)). The property is owned by Olam Palm Gabon (OPG), which is a company that has several agro-industrial oil palm plantations. This is the oldest plantation in the country, having been in production for 39 years. It covers 5700 ha, with mature oil palms occupying an area of 1500 ha. A watercourse crosses the site (North-South) in its eastern half ([Figure 6.2](#)). Individual trees in the study consisted of mature palms, which are mainly in drier uplands, but some of them are found in the poorly drained shallows along the watercourse. Regional climate is warm-humid equatorial, with temperatures ranging from 27 to 38 °C, and annual rainfall ranging from 1800 to 2000 mm.

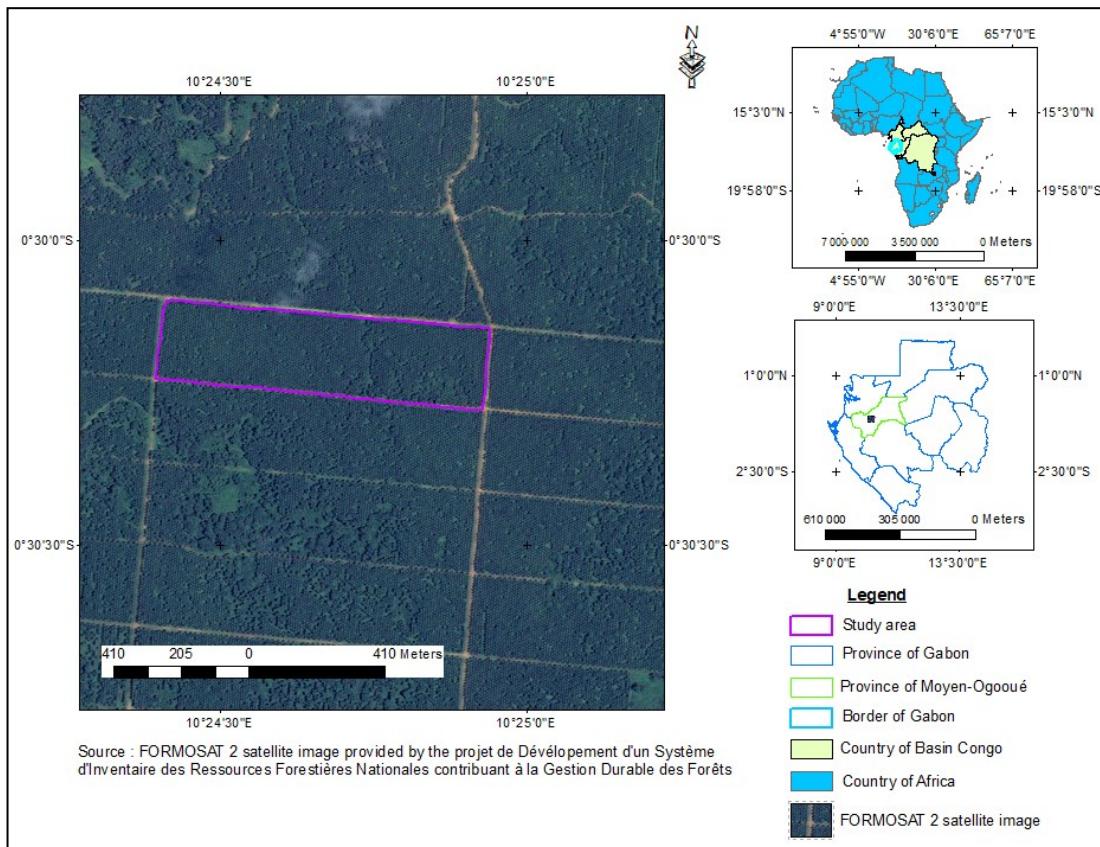


Figure 6.1 Study site location.

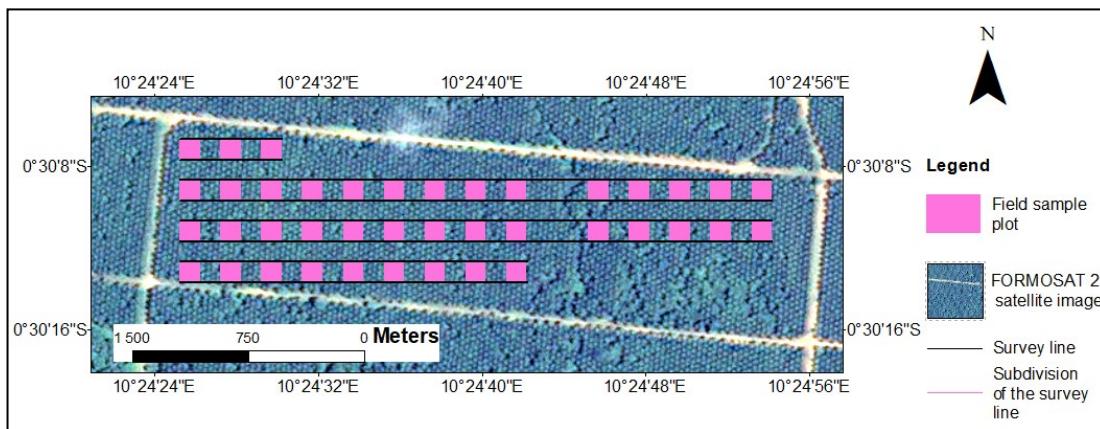


Figure 6.2. Plot sampling scheme.

6.3.2 Data

6.3.2.1 Satellite data

Satellite images for this study come from PlanetScope (L3Harris Geospatial, Broomfield, CO, USA) and FORMOSAT-2 (Decommissioned, National Space Organization, Taiwan). PlanetScope images were acquired in April 2017 as an *Analytic Ortho Tile Product* (spatial resolution: 3.125 m × 3.125 m). The data were radiances at the top of the atmosphere and did not undergo further correction during the study. FORMOSAT-2 images are pansharpening products at 2 m × 2 m resolution (i.e., merging of high-resolution panchromatic and lower resolution multispectral images) from February 2011. Geometric corrections were applied to

both types of images. Acquisitions were made in four similar spectral bands: 455–515 nm, 500–590 nm, 590–670 nm and 780–860 nm for PlanetScope; and 450–520 nm, 520–600 nm, 630–690 nm and 760–900 nm for FORMOSAT-2.

6.3.2.2 In-situ measurements

Several field measurements were carried out during the study. Different structural parameters of oil palms that could be used for AGB calculations were measured. Given that the plantation was considered mature, all measurements were made on palm trees that were >30 years old. Instruments that were used in the field included a global positioning system (Garmin GPSMAP 64SC), compass (TOPOCHAIX), DBH tape and a vertex IV associated with a transponder 3. The GPS was used to position the sample plots in the field. The compass helped to materialize the directions of the transects. DBH were measured with a tape. The vertex coupled to the transponder allowed us to measure the stem height at two different positions at a distance of 10 m from the considered oil palm tree. Fieldwork was conducted in October 2017 on 40 sample plots that were established in the plantation, based upon systematic sampling. Plots (0.1 ha) were aligned East-West on four belt transects, each of which was 30.8 m wide and about 900 m long. The total area that was sampled was 25 ha. Natural obstacles, such as watercourses or tall grasses, limited accessibility and constrained sampling that was proposed along all survey lines. [Figure 6.2](#) shows the sampling scheme for the sample plots.

Stem height (H_T) and diameter at breast height (DBH, 1.3 m) were recorded for all oil palms within each plot, as was their total number (NP). The density (D) values were determined from ratios between NP and individual plot areas. Basal area (BA, $m^2 \text{ ha}^{-1}$) was calculated [35] as the cross-sectional area of each stem measured at 1.3 m above the ground, i.e., $(\pi \times DBH^2)/4$. Mean BA was estimated as the sum of all oil palms that were contained in each sample plot. Mean values for these variables are summarized in [Table 6.1](#).

Table 6.1. Descriptive statistics for measurements taken from 510 oil palms distributed across 40 sample plots. DBH is diameter at breast height, H_T is stem height, NP is the number of stems per plot, D is the density of palm trees per hectare, BA is basal area and AGB is total dry aboveground biomass calculated from in-situ measurements using Equation (1)

Parameter	DBH (cm)	H_T (m)	NP	D (stem ha^{-1})	BA ($m^2 \text{ ha}^{-1}$)	AGB (t ha^{-1})
Mean	52.4	9.3	13	134	29.2	60.8
Minimum	47.3	7.5	10	105	18.7	35.9
Maximum	55.0	10.0	15	158	36.2	75.1
Standard deviation	2.1	0.6	1	12	4.2	10.4

Mean in-situ AGB (kg) was evaluated in each sample plot using the following ln-transformed allometric equation:

$$\ln(AGB) = -2.335 + 0.832 \times \ln(DBH^2 \times H_T) \quad (6.1)$$

This equation was derived from a previous study that had been conducted in the same area [36], which proposed different allometric models that were based upon in-situ measurements that were collected during destructive sampling. For the rest of the present study, in-situ AGB is expressed in tons ha⁻¹ (**Table 6.1**).

6.3.3 Use of the FOTO method and estimation of aboveground biomass

Our methodological approach consisted of four parts: (i) the use of Fourier transformations in textural ordination (FOTO) to generate texture indices from the PlanetScope and FORMOSAT-2 images; (ii) development of MLR-type models for estimating AGB; (iii) development of MARS-type models for estimating AGB; and (iv) validation of the different models. The flowchart in **Figure 6.3** summarizes the research approach.

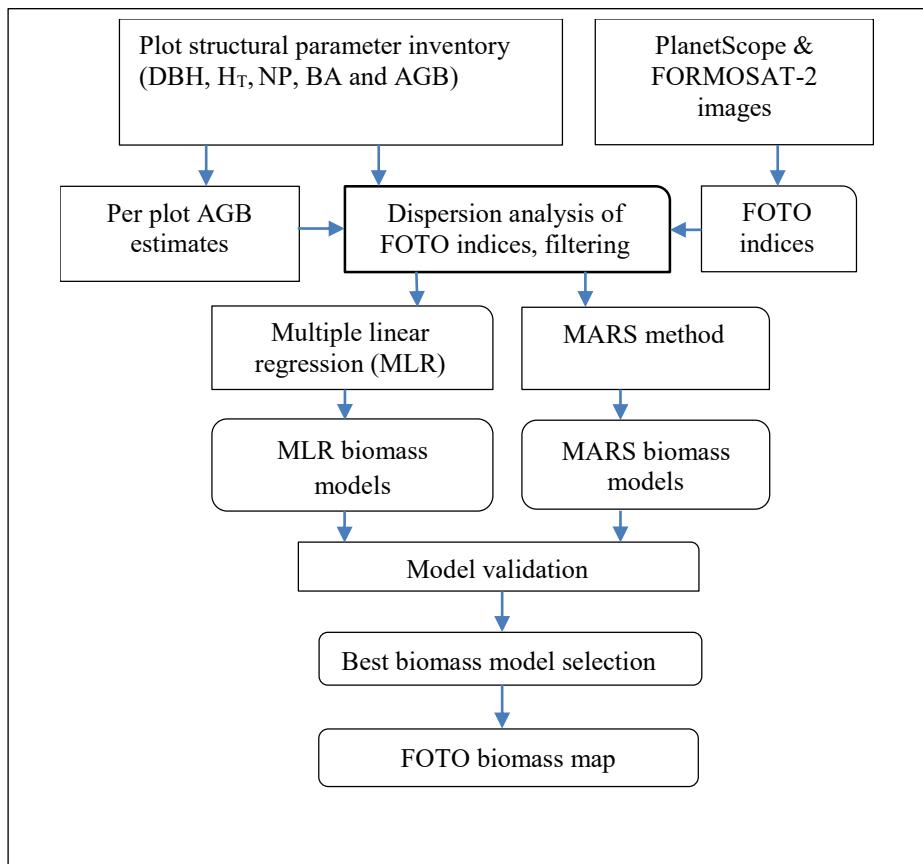


Figure 6.3. Organizational flowchart for the study.

6.3.3.1 Textural index generation using the FOTO approach

FOTO was implemented in this study following steps that are described in [37] and [8]. These steps allow gradients of variation in image texture to be characterized by coupling two-dimensional discrete fast-Fourier transformation (FFT-2D) with principal component analysis [8,14,18,20]. On one hand, the approach permits textural characterization of very high-resolution PlanetScope and FORMOSAT-2 images that were acquired over oil palm plantations; on the other hand, we assume textural indices that we generated are related to aboveground biomass of these plants [6,8,11]. In this study, FOTO was performed in MatLab R2016a (MathWorks, Natick, MA, USA). Near-infrared spectral bands of the two images were selected and analyzed for their sensitivity to vegetation [8]. The main steps are explained below.

The first step consisted of masking aspects of the images that were not related to the vegetation cover, i.e., bare ground, clouds and their shadows, among others. Images of the palm trees were then masked. We accomplished this masking using a combination of unsupervised classification with the k-means algorithm on the near infrared spectral band of each of the images in the study and visual examination to isolate unwanted features. Oil palm plantations were distinguished from natural forests and non-forest areas in the classification process. Following this operation, a mask was applied to the infrared band of each original image to retain only areas that were occupied by oil palms, thereby defining the area of application of FOTO in each case.

The second step consisted of defining window sizes that were needed to calculate the 2D Fourier spectra on the different images. Following most previous work (e.g., [6,14]), we estimate these square window (WS) sizes in this study, such that $WS = N * \Delta S$ (N = number of pixels in the X or Y direction; ΔS = pixel size in meters). In a forest context, window sizes of 50 to 150 m are usually selected for applying FFT-2D [6,8,37]. Yet, Proisy et al. [8] demonstrated that window sizes between 75 and 120 m were best suited for characterizing near-infrared data in the IKONOS images that they examined. These sizes improved the results of principal component analysis (i.e., PCA), especially between 75 and 100 m. When choosing window sizes, the best possible compromises should be sought. Smaller sizes may not capture characteristics of the mature canopy, while sizes that are too large tend to represent landscapes more than canopy granularity, thereby reducing the spatial resolution of the FOTO maps [8,37]. Based upon these findings, we adopted three window sizes, i.e., 75 m, 100 m and 120 m. The WS report on ΔS provides the corresponding numbers of pixels N in the X and Y directions for these windows. The respective window sizes that were selected for the PlanetScope image

are 24×24 , 32×32 and 38×38 pixels. Window sizes (in pixels) for the FORMOSAT-2 image were respectively 38×38 , 50×50 and 60×60 pixels.

The third step applied FFT-2D using the selected different sizes of square windows. FFT-2D yielded the radial spectra (or r -spectra), thereby converting the spectral radiance from the space domain to the frequency domain. Hence, a spectral radiance that is expressed in the space domain by $I(x,y)$ of the x -column and y -row image is converted in the frequency domain into a function $F(p,q)$, where p and q are spatial frequencies (or wavenumbers) along both Cartesian directions. These frequencies indicate the number of repetitions of an object within a given radial distance. They are expressed in cycles km^{-1} , making it easier to compare results that are obtained from different window sizes. For any given window size WS , the Fourier transform is applied over a set of discrete wavelengths, defined as the ratios of WS to wavenumbers [19]. The highest wavenumber corresponds to the Nyquist frequency of $WS/2$. Wavenumbers p and q are thus constrained to the following intervals: $1 \leq p \leq WS/2$ and $1 \leq q \leq WS/2$. Phase information is not very relevant to the texture and, therefore, can be neglected. Thus, periodograms (I_{pq}) can be calculated for each pair of spatial frequencies (p,q) using Fourier coefficients (a_{pq} and b_{pq}), such that:

$$I_{pq} = WS^{-2}(a_{pq} \cdot ^2 + b_{pq} \cdot ^2) \quad (6.2)$$

The periodogram provides information on the variance of the image, according to the relative contributions of textural categories at various spatial scales. Based on its polar form, it is possible to conveniently characterize and recognize the distribution of surface patterns within the window considered, both in terms of scale and direction. The value of the periodogram in its polar form ($I_{r\theta}$) reflects the portion of the variance of the image that can be explained by waveforms having a given wavenumber r and direction of motion θ , such that $r = \sqrt{p^2 + q^2}$ and $\theta = \tan^{-1}(p/q)$. The r -wavenumber corresponds to the number of times the same waveform, i.e., the same reference pattern, is repeated within the window in the θ direction.

Additional simplifications can be applied to periodograms when the objective is textural analysis. They consist of calculating the average value of periodograms in all possible directions of motion θ to generate an averaged radial spectrum $I(r)$. This spectrum is commonly referred to as the “ r -spectrum”:

$$I(r) = (k\sigma^2)^{-1} \sum_{\theta} I_{r\theta} \quad (6.4)$$

where k is the number of periodogram values at spatial frequency r and σ^2 is the variance of the image. The r -spectrum thus makes it possible to summarize the characteristics of textural variation in terms of the state of grain size and fineness, which is very useful for vegetation studies such as oil palm plantations. More details regarding the calculation of r -spectra can be

found in Renshaw and Ford [38], Mugglestone and Renshaw [39], Couteron et al. [37], Proisy et al. [8], and Guo and Rees [19].

As previously noted, the current study considers three increasing window sizes for each image and determines which one is the best. The optimal *WS* (window size) that was used to generate the FOTO textural indices corresponds to the one that exhibits the highest Nyquist frequency among the three. The Nyquist frequency is the maximum frequency that the signal can display without containing errors, i.e., one-half of the sampling frequency. It often takes a wavenumber between 1 and 3. The *r*-spectra and Nyquist frequencies were obtained for the different windows and summarized in **Figure 6.4**. The best window size is 38×38 pixels for the PlanetScope image, while 60×60 pixels is the best size for the FORMOSAT-2 image. *WS* is almost the same for the two images, i.e., 119 m for PlanetScope and 120 m for FORMOSAT-2.

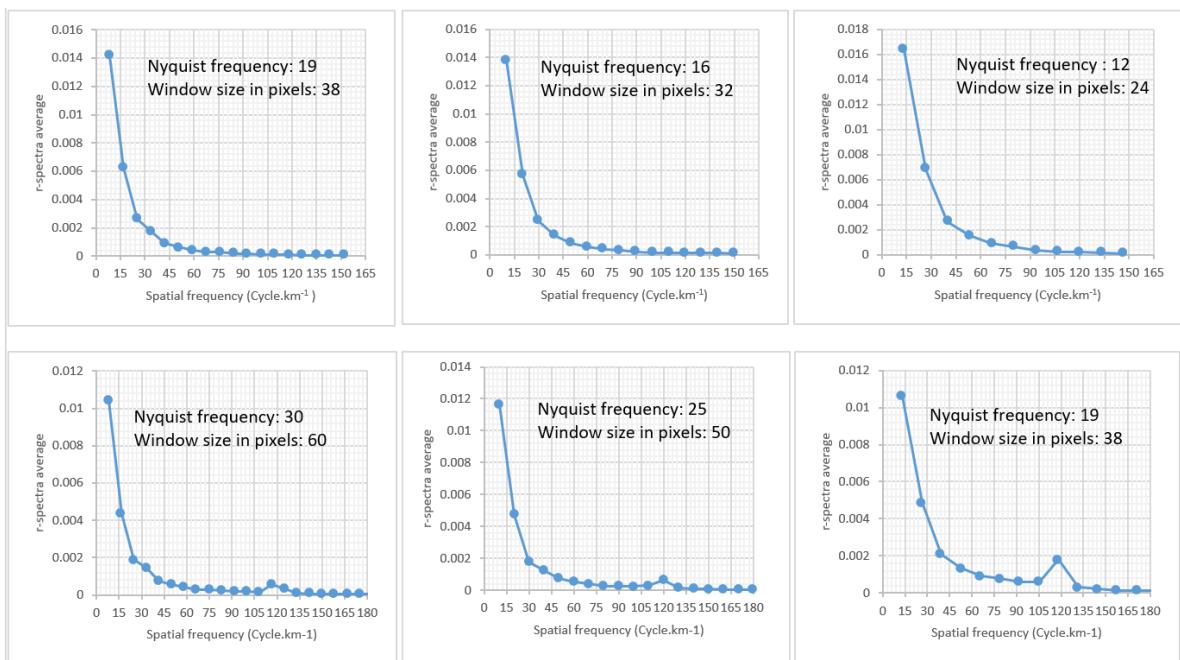


Figure 6.4. Nyquist and spatial frequencies as a function of mean *r*-spectra for window sizes ranging from 24 to 38 pixels for PlanetScope (top row) and 38 to 60 pixels for FORMOSAT-2 (bottom row).

The fourth step involves textural ordination. The *r*-spectra that are produced were incorporated into a two-dimensional table, the rows of which represent the *r*-spectrum of the given window and the columns are the amplitude *H* values. Normalization was performed on the columns of the table, after which the normalized spectra were subjected to principal component analysis (PCA). PCA characterizes the variability and measures the dispersion between *r*-spectra, reducing the dimensionality of the data to a few components (three in the current study). Principal component axis 1 contrasts coarse (negative scores) and fine (positive

scores) textures of canopy grain. Coarse textures generally represent large canopy sizes, while fine textures are more consistent with small- to medium-sized tree canopies. Principal component (PC) axis 2 could be interpreted as a gradient of canopy openness, from closed canopy (negative scores) to open canopy (positive scores) conditions, as has been indicated in various studies [6,37,40,41,42]. By definition, the first three PCs that were extracted explain most of the variation in the data; factor scores for these components were used as textural indices (FOTO indices). Their values were mapped as Red-Green-Blue (RGB) texture images to produce FOTO maps, with a spatial resolution equal to the window size (*WS*).

6.3.3.2 Estimation of AGB by multiple regression

Oil palm structural parameters from the 40 field sample plots were first averaged before proceeding to the AGB model step. To achieve this, field sample plots that were contained in the *WS* window sizes (120 m × 120 m) of both image types were identified for FOTO analysis. Parameter averages for these plots were then calculated for each window. Depending upon position, the window could contain one or a maximum of three plots. Mean values of oil palm structural parameters that were estimated were examined using scatter plots. Field data and calculations were checked for possible outliers.

Mean values of the principal component (PC) scores for the normalized *r*-spectra (corresponding to the FOTO indices) were calculated for each window and then combined with the plot averages of the structural parameters. ArcGIS V10.7.1 (ESRI, Redlands, CA) was used for the overlay and spatial processing of the data. The values of the structural parameters and the FOTO indices for the study are presented by sample plots in [Appendix 6.A](#).

Before developing biomass models using MLR, we examined the relationships between FOTO indices and each palm structural parameter (DBH, H_T, BA, D) estimated from field sample plots data in the study. This analysis identified parameters that best explained variations in the textural index, which would be the most influential in the MLR models. Finally, an MLR model was developed to estimate AGB from the PlanetScope and FORMOSAT-2 images, respectively. The general form of the equation is as follows [8]:

$$AGB = a_0 \sum_{C=1}^3 a_C.FI_C \quad (6.5)$$

where a_0 and a_C are the MLR coefficients, and *FI* represents FOTO indices that were obtained from scores for the first three axes of PCA. To develop MLR models for estimating *AGB*, 75% of the total 40 samples available were used. These data were randomly selected. The remaining 10 samples were held back for the independent validation of the results.

Evaluation of various relationships that were developed (FOTO indices vs. structural parameters; *AGB* vs. FOTO indices) was performed using several statistical metrics.

Relationships were deemed satisfactory when coefficients of determination (R^2) were greater than 0.5, with $p < 0.05$. (P-values were calculated at a significance level of 5%). RMSE (*Root-Mean-Square Error*) and %RMSE (Relative RMSE) were further used to evaluate *AGB* models with MLR. The lowest values were sought. Ultimately, the choice of the best model in the present study was based more upon RMSE than upon R^2 , following recommendations from previous studies (e.g., [43]).

6.3.3.3 Estimation of AGB using MARS

According to various studies that were mentioned in the introduction ([Section 6.2](#)), the MARS approach seems well suited to accounting for non-linearities in the data. It models relationships through summation of a series of so-called “basis functions” [27], which in fact constitute a set of stepwise adaptive linear regressions. We applied this method for the first time in the estimation of oil palm *AGB*. The generic expression of the MARS model that is based upon the dependent variable (y) and explanatory variable (x) is written as follows [28,32,44]:

$$y = f(x) + \varepsilon \quad (6.6)$$

where ε is the error and $f(x)$ is the unknown regression function, which can be written as:

$$f(x) = \beta_0 + \sum_{m=1}^M \beta_m K_m(x) \quad (6.7)$$

where β_0 is the constant in the model, $K_m(x)$ is the m^{th} basis function, β_m is the coefficient associated with the function $K_m(x)$, and M is the number of basis functions in the model. Each basis function $K_m(x)$ consists of a hinge function of the form $\max(0, x-k)$ or $\max(0, k-x)$, where k is a constant value. This formulation takes into account individual effects of the independent variables plus those resulting from interactions between two or more predictors (x). MARS eliminates less significant and redundant basis functions to create the final model [25]. To do this, basis functions are compared using the Generalized Cross-Validation Criterion (*GCV*). *GCV* is the residual Root-Mean-Square Error divided by a penalty determined by the complexity of the model [28]:

$$GCV(M) = \frac{\sum_{i=1}^n (y_i - f_M(x_i))^2}{n(1 - \frac{P_M}{n})^2} \quad (6.8)$$

where y_i are the observed values of the dependent variable, n is the number of observations, $f_M(x_i)$ is the MARS model with basis functions M , x_i are the observed values of the explanatory variables that are included in the MARS model, and P_M is the number of parameters in the MARS model. The lowest *GCV* value corresponds to the appropriate model. In this study, MARS equations for *AGB* were developed from the FOTO indices using Statistica (TIBCO, Palo Alto, CA, USA).

6.3.3.4 Validation of the estimate

Validation of the different models that were developed for estimating AGB used 25% of the samples (10 samples), independent of the development or training phase. The different metrics that were considered in performance analysis included R^2 , p -values, RMSE and %RMSE [25,45]. The best model was subsequently used to produce a FOTO map of AGB. The best model was subsequently used to produce a FOTO map of *AGB* [28,46,47] using ArcGIS software.

6.4 Results

6.4.1 Textural indices using the FOTO approach

FOTO was applied to infrared bands of PlanetScope and FORMOSAT-2 images to extract r -spectra for the oil palms. [Figure 6.5a](#) shows the variations in these spectra as a function of the r -wave number. The r -spectra for both images capture the entire gradient of the oil palm canopy cover. Maximum values are reached at r -wavenumber = 1, with low spatial frequencies of 8.4 cycles km^{-1} and 8.3 cycles km^{-1} for PlanetScope and FORMOSAT-2, respectively ([Figure 6.4](#)). These values characterize canopy texture of the oil palm plantation. Beyond these estimates, mean r -spectrum values remain observable at wave numbers 2 and 3 ([Figure 6.5a](#)). The latter appear at spatial frequencies greater than the maxima for both images, as shown in [Figure 6.4](#). These values further characterize the texture of oil palms for FORMOSAT-2 with a 60-pixel window size, but did not fully characterize the texture for PlanetScope with a 38-pixel window size ([Figure 6.4](#)). Minimum r -spectrum values were obtained at r -wavenumber ≥ 4 , with high spatial frequencies (≥ 33 cycles km^{-1}) for both images ([Figure 6.4](#)). These values are more consistent with spatial patterns that do not represent the texture of oil palms.

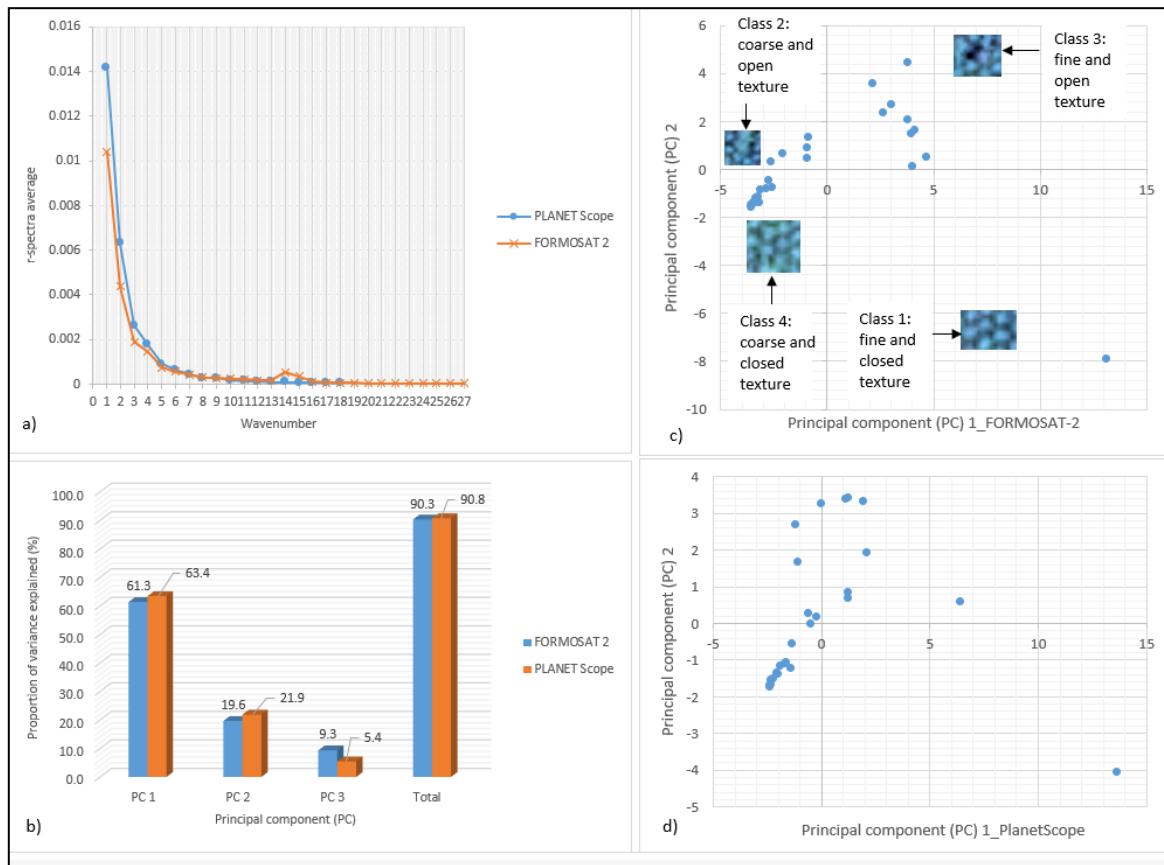


Figure 6.5. Spatial frequencies as a function of mean *r*-spectra from Fourier transformations in textural ordination (FOTO) analysis of the near infrared spectral bands of PlanetScope and FORMOSAT-2 (a); variance proportions explained by the 3 principal components (PCs) (b); ordination of plot scores on PCs 1 and 2 for FORMOSAT-2 (c) and PlanetScope (d).

PCA of PlanetScope and FORMOSAT-2 *r*-spectra demonstrates that factor scores derived from the first three axes are sufficient to explain most variations in oil palm canopy textures in the images ([Figure 6.5b](#)). For PlanetScope, the three components account, respectively, for 61.3%, 21.9% and 5.4% of the variance (90.8% of total variation). For FORMOSAT-2, they account, respectively, for 63.4%, 19.6% and 9.3% of the variance (90.3% of total variation). Ordinations of the first two axes (PC1 and PC2) are presented in [Figure 6.5c,d](#) for FORMOSAT-2 and PlanetScope, respectively. PC1 and PC2 account for just over 80% of total explained variance. The observed dispersions indicate the lack of correlation (orthogonality) between the two components in each case, consistent with expectation. In the case of FORMOSAT-2, four distinct clusters or texture classes emerge in the ordination ([Figure 6.5c](#)), i.e., open coarse texture, closed coarse texture, open fine texture and closed fine texture. These classes are encountered in the PlanetScope image, although distinctions among clusters are much less clear-cut than in FORMOSAT-2. The coarse or fine texture is related to the size of

the canopies of oil palm trees. Coarse textures represent wider tops. Opening or closing refers to spacing between the crowns. Wide-open spaces indicate open canopies, while the tops of closed canopy textures are more compact.

Using factor scores for the first two principal component axes (PC1 and PC2), red-green-blue representations of FOTO canopy texture maps were produced for each of the images ([Figure 6.6](#)). The colors are indicative not only of PC factor scores for both axes, but also textural classes. Yellow denotes the open fine-textured oil palm class. Here, scores are positive on both PC1 and PC2 ([Figure 6.5](#)). This class occupies the entire central portion of the plantation and extends eastwards. It is dominated by palms with lower-stature crowns, with an average stem height of around 8.8 m and DBH of 50.8 cm. Oil palms in the coarse-closed class are shown in blue ([Figure 6.6](#)). This class is characterized by negative scores on both PC axes ([Figure 6.5](#)). It is found in the western and eastern regions of the plantation. In these areas, palms have high average stem heights (about 9.7 m), larger average diameters (about 54.1 cm) and dominant broad crowns. Areas featuring the coarse-textured, open oil palm class are depicted in light green ([Figure 6.6](#)). Here, scores on PC1 are negative and positive on PC2 ([Figure 6.5](#)). This class of oil palms have dimensions similar to those of the previously mentioned class, with an average height of around 9.5 m, average DBH of 53.5 cm and dominant broad crowns, but open this time. Closed and open coarse texture classes are found on drier uplands, in contrast to open-fine texture, much of which is found in low-lying areas around the watercourse running through the plantation. This last class (in red) is characterized by fine, closed texture and appears in the northeastern part of the plantation ([Figure 6.6](#)). Scores defining this class are positive on PC1 and negative on PC2. Average palm height is identical to that of the open-fine texture class (8.8 m), but average stem diameter is smaller (48.8 cm compared to 50.8 cm). This class is localized in lowlands near the watercourse and, thus, potentially subject to growing conditions that are indicative of poorly drained soils.

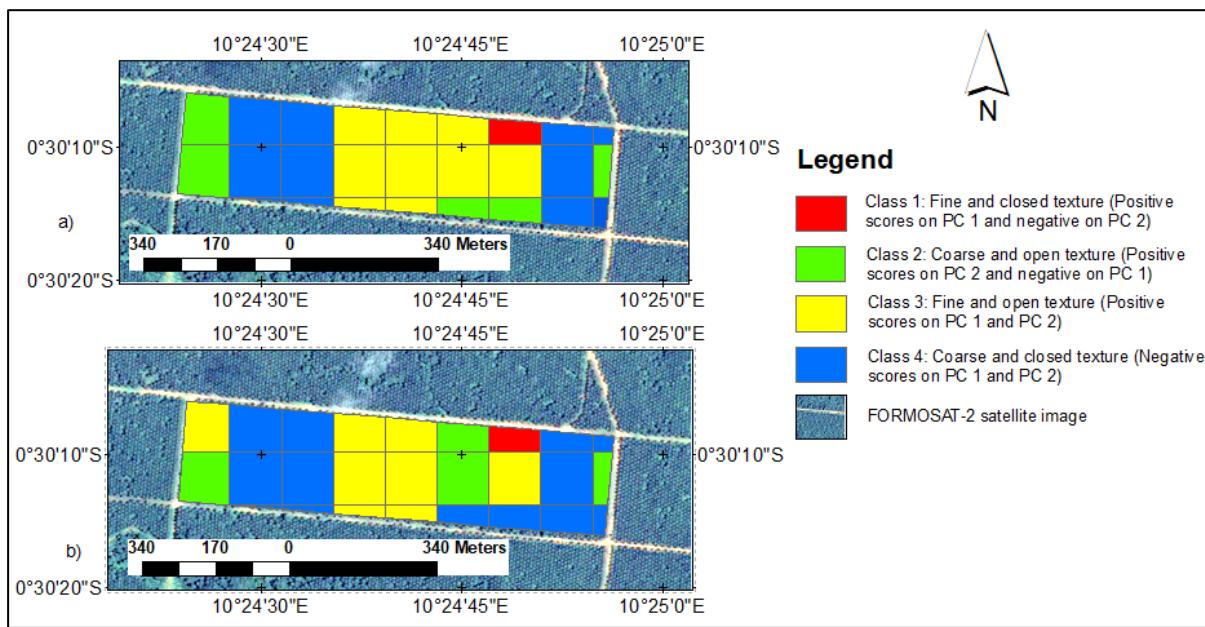


Figure 6.6. FOTO maps of oil palm canopy texture derived from actual RGB values of the FOTO indices of FORMOSAT-2 (a) and PlanetScope (b).

6.4.2 Estimation of AGB by multiple regression

Correlations between FOTO indices and the various structural parameters of the oil palms were first analyzed. [Table 6.2](#) summarizes correlations (as R^2 values) with factor scores for the three principal components in both image types. For illustrative purposes, [Figure 6.7](#) displays the results with PC1. The negative relationships that are obtained between PC1 from FORMOSAT-2 and plant structural parameters are the most significant overall ($p < 0.0001$). In particular, variation in PC1 not only strongly explains BA ($R^2 = 0.84$), but also that of stem diameter ($R^2 = 0.78$). Despite being significant, the weakest correlations are obtained with stem height ($R^2 = 0.56$) and canopy density ($R^2 = 0.54$). With PlanetScope, the results follow the same trends, but with weaker correlations in general. Basal area and DBH are the parameters that are best explained by PC1 in this case, with R^2 values of 0.68 and 0.64, respectively ($p \leq 0.0001$). Stem height and density are the least explained with PC1 from PlanetScope ($R^2 < 0.55$). Other than PC1, the other components (PC2, PC3) generally show insignificant relationships with the structural parameters of oil palms, regardless of the satellite data considered ([Table 6.2](#)).

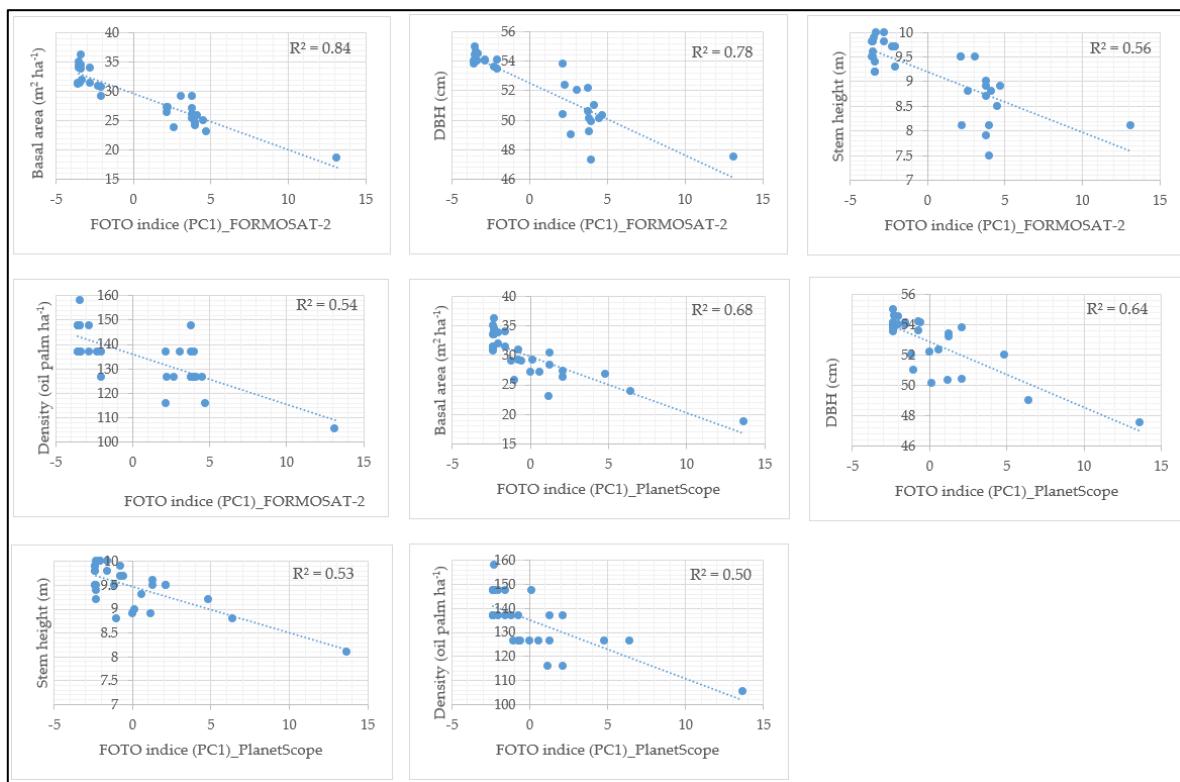


Figure 6.7. Relationships between oil palm structural parameters obtained from the field plots and PC1 derived from PlanetScope and FORMOSAT-2 images.

Table 6.2. Correlations between FOTO FORMOSAT-2 and PlanetScope indices versus structural parameters of oil palm. The table summarizes coefficients of determination (R^2), and their associated P-values (P). PC1, PC2 and PC3 are, respectively, the principal component scores of axes 1, 2 and 3 of the principal component analysis (PCA) of the r -spectra of the 2D Fourier transform analysis.

Parameter	FORMOSAT-2						PlanetScope					
	PC1		PC2		PC3		PC1		PC2		PC3	
	R ²	P	R ²	P	R ²	P	R ²	P	R ²	P	R ²	P
Basal area ($\text{m}^2 \text{ha}^{-1}$)	0.84	< 0.0001	0.040	0.291	4.10 ⁻⁴	0.915	0.68	< 0.0001	0.163	0.027	0.022	0.430
DBH (cm)	0.78	< 0.0001	0.042	0.280	0.022	0.438	0.64	< 0.0001	0.125	0.055	0.005	0.724
Ht (m)	0.56	< 0.0001	0.020	0.460	0.129	0.051	0.53	< 0.0001	0.075	0.144	0.001	0.840
Density (oil palm ha^{-1})	0.54	< 0.0001	0.003	0.772	0.016	0.507	0.50	< 0.0001	0.083	0.122	0.029	0.369

Structural parameters of oil palms are explanatory variables of the aboveground biomass. A relationship between these parameters and FOTO indices that are from FORMOSAT-2 and PlanetScope, in particular PC1 (Table 6.2), suggests links between these indices and *AGB*. Based upon this preliminary analysis, MLR models of *AGB* were developed by considering the three components (PC1, PC2 and PC3) for each of the two image types. In the case of FORMOSAT-2, the best relationship that was obtained (Model 1) integrates all three indices (Table 6.3). It is a strong and significant relationship ($R^2 = 0.86, p < 0.0001$). The associated RMSE was estimated to be 4.03 tons ha^{-1} . The best MLR model constructed considering

PlanetScope FOTO indices (Model 2) uses also the three components (PC1, PC2 and PC3). This model offers comparable metrics to that of FORMOSAT-2 ($R^2 = 0.83$; $p < 0.0001$, RMSE = 3.77 tons ha^{-1} , as indicated in [Table 6.3](#).

Table 6.3. Multiple linear regression models developed for estimating aboveground oil palm biomass using indices estimated by textural ordinations on Fourier transforms (FOTO), which were produced from PlanetScope and FORMOSAT-2 images. The constants a , b_1 , b_2 , and b_3 are coefficients of the respective multiple linear regressions (MLR) equations. RMSE (tons ha^{-1}) is the Root-Mean-Square-Error and %RMSE is its percentage. P -values are calculated at a significance level of 5%.

Model	a	b_1	b_2	b_3	R^2	P-value	RMSE	%RMSE
<i>Model 1 (MLR FORMOSAT – 2):</i>								
$AGB = a + b_1 \times PC1 + b_2 \times PC2 + b_3 \times PC3$								
	61.548	-2.369	-0.450	-0.409	0.86	< 0.0001	4.03	6.70
<i>Model 2 (MLR PlanetScope):</i>								
$AGB = a + b_1 \times PC1 + b_2 \times PC2 + b_3 + PC3$								
	62.923	-2.271	-1.889	0.534	0.83	< 0.0001	3.77	5.98

6.4.3 Biomass estimation using MARS

AGB models were developed with the MARS approach using FOTO indices of the FORMOSAT-2 and PlanetScope images, according to methods that are detailed in Section IV. Several combinations of indices PC1 to PC3 could be used to generate interesting equations. [Table 6.4](#) summarizes the models that we have developed, and retained for validation purposes and to select the best model for each image type. All three models that were produced from FORMOSAT-2 data have very satisfactory performance criteria ($R^2 \geq 0.89$, $p < 0.0001$; RMSE < 3.6 tons ha^{-1} ; %RMSE < 5.9%). Among them, Models 3 and 4 incorporate interactions between PC1 and PC3, thereby making additional adjustments compared to Model 5, which rely solely upon basic linear functions. The integration of interaction terms reduces slightly the estimation errors (less than 1%), but increases the degrees-of-freedom that are associated with the equations.

Table 6.4. Aboveground biomass models estimated using multivariate adaptive spline regressions (MARS).

MODEL	EQUATION	R ²	P-value	RMSE (t ha ⁻¹)	%RMSE
MARS models using FOTO indices of FORMOSAT-2					
Model 3	$AGB = 70.415 - 3.287 \times \max(0; PC1 + 3.555) + 4.871 \times \max(0; PC2 - 0.508) - 0.531 \times \max(0; PC1 + 3.555) \times \max(0; 0.708 - PC3) + 1.807 \times \max(0; 0.508 - PC2) \times \max(0; 0.708 - PC3)$	0.90	< 0.0001	3.33	5.47
Model 4	$AGB = 70.933 - 3.354 \times \max(0; PC1 + 3.555) + 4.873 \times \max(0; PC2 - 0.508) - 0.541 \times \max(0; PC1 + 3.555) \times \max(0; 0.708 - PC3) + 0.353 \times \max(0; PC1 + 3.555) \times \max(0; 0.508 - PC2)$	0.90	< 0.0001	3.36	5.52
Model 5	$AGB = 68.913 - 2.436 \times \max(0; PC1 + 3.555) + 1.848 \times \max(0; PC2 - 0.508) + 1.304 \times \max(0; 0.508 - PC2) - 1.515 \times \max(0; PC3 - 0.708) - 1.187 \times \max(0; 0.7084 - PC3)$	0.89	< 0.0001	3.57	5.87
MARS models using FOTO indices of PlanetScope					
Model 6	$AGB = 98.714 - 2.764 \times \max(0; PC1 + 1.182) + 1.311 \times \max(0; -1.182 - PC1) - 3.154 \times \max(0; PC2 + 4.085) + 0.189 \times \max(0; PC1 + 1.182) \times \max(0; PC2 + 4.085) + 5.299 \times \max(0; -1.182 - PC1) \times \max(0; PC3 + 0.031) - 7.189 \times \max(0; -1.182 - PC1) \times \max(0; -0.031 - PC3) + 1.786 \times \max(0; PC2 + 4.085) \times \max(0; PC3 + 0.031) - 1.386 \times \max(0; PC2 + 4.085) \times \max(0; -0.031 - PC3) - 8.953 \times \max(0; PC3 + 2.231)$	0.87	< 0.0001	3.33	5.31
Model 7	$AGB = 76.574 - 2.727 \times \max(0; PC1 + 1.182) + 3.191 \times \max(0; -1.182 - PC1) - 2.808 \times \max(0; PC2 + 4.085) + 0.071 \times \max(0; PC1 + 1.182) \times \max(0; PC2 + 4.085) + 0.245 \times \max(0; -1.182 - PC1) \times \max(0; PC3 + 0.031) - 2.678 \times \max(0; -1.182 - PC1) \times \max(0; -0.031 - PC3) + 0.096 \times \max(0; PC1 + 1.182) \times \max(0; PC2 + 4.085) \times \max(0; PC3 + 2.231)$	0.87	< 0.0001	3.36	5.37
Model 8	$AGB = 74.739 - 2.346 \times \max(0; PC1 + 1.182) + 1.867 \times \max(0; -1.182 - PC1) - 1.981 \times \max(0; PC2 + 4.085) - 1.170 \times \max(0; PC3 + 0.031) - 1.262 \times \max(0; -0.031 - PC3)$	0.84	< 0.0001	3.74	5.97

Three models were also developed using FOTO indices derived from PlanetScope. Models 6 and 7 incorporate interaction terms, while Model 8 sums piecewise linear functions of the form $\beta_i(PC_i - k_i)$, where PC_i corresponds to FOTO indices PC1, PC2 or PC3, and β_i and k_i are constants. As was the case with FORMOSAT-2, models taking interactions into account yield slightly smaller errors, but the differences are non-significant. Overall, the three models developed for PlanetScope appear as strong as those developed with FORMOSAT-2 data, with errors of the same order of magnitude ($R^2 \geq 0.84$, $p < 0.0001$; $RMSE < 3.8$ tons ha⁻¹; %RMSE < 6%).

6.4.4 Validation of estimate

AGB models that were developed using MLR and MARS approaches, based on the FOTO indices, were validated from independent samples that were not considered during the training or development phase (see [Section 6.3.3.44.1](#)). [Table 6.5](#) summarizes results that were obtained. The validation exercise confirms strong relationships between biomass and FOTO indices for both PlanetScope and FORMOSAT-2, as demonstrated by the summary statistics ($R^2 \geq 0.80$; $p \leq 0.0005$; $RMSE < 5.5 \text{ t ha}^{-1}$; $\%RMSE < 10.2\%$), regardless of the approach (MLR or MARS) used. In this study, MLR appears to be just as effective as the MARS method, especially when FORMOSAT-2 data are used. Overall, the best validation results are obtained with FORMOSAT-2 data ($R^2 \geq 0.89$; $p < 0.0001$), especially for Models 3, 4 and 5, which yield lowest errors ($\%RMSE \leq 6.40\%$). Model 1 (based on MLR) gives quite similar validation results. Slight elevated errors were obtained with PlanetScope MARS models at the validation stage (on average about 3% above FORMOSAT-2 models in terms of $\%RMSE$).

Table 6.5. Validation of aboveground biomass models.

Model	R ²	P-value	RMSE (t ha ⁻¹)	%RMSE
<i>Model 1 (MLR FORMOSAT-2)</i>	0.85	0.0001	4.18	6.56
<i>Model 2 (MLR PlanetScope)</i>	0.81	0.0004	5.45	10.11
MARS model validation for FORMOSAT-2				
<i>Model 3</i>	0.92	< 0.0001	3.88	6.09
<i>Model 4</i>	0.91	< 0.0001	3.97	6.24
<i>Model 5</i>	0.89	< 0.0001	4.08	6.40
MARS model validation for PlanetScope				
<i>Model 6</i>	0.82	0.0003	4.59	8.51
<i>Model 7</i>	0.80	0.0005	4.98	9.24
<i>Model 8</i>	0.82	0.0003	5.11	9.47

Examination of the various results obtained shows that proposed approaches, when combined with the use of FOTO texture indices, are effective in estimating oil palm aboveground biomass. The use of PlanetScope or FORMOSAT-2 images does not introduce important differences. Of all proposed models that were based upon MARS, Model 3 for FORMOSAT-2 and Model 6 for PlanetScope appear to be the best models. These two models have errors of 6.09% and 8.51%, respectively, on the estimated AGB ([Table 6.5](#)). Model 1 that is based upon the MLR approach with FORMOSAT-2 is just as efficient, with a similar error level of 6.56%.

Following validation, an *AGB* map was generated with Model 3 using FORMOSAT-2 data for illustrative purposes ([Figure 6.8](#)). Observable spatial variability in the map ([Figure 6.8b](#)) reflects variations in oil palm structure that were observed in the field during sampling. It is also similar to variability in oil palm texture ([Figure 6.6a](#)). Thus, highest AGB ($>59.00 \text{ t ha}^{-1}$)

is found in dry land areas (dark green and medium dark green, [Figure 6.8b](#)). These areas benefit from regular maintenance of the oil palms by OPG. On one hand, they are characterized by an open or closed coarse texture (Classes 2 and 4, [Figure 6.6b](#)), i.e., they are dominated by mature oil palms with large tops. On the other hand, lowest AGB ($<59.00 \text{ t ha}^{-1}$) is in the poorly drained lowland area surrounding the stream crossing the eastern section of the plantation ([Figure 6.8b](#), light green and medium light green). Pockets of continuous stagnant water are found here; palms do not benefit from the same silvicultural maintenance. Consequently, these oil palms exhibit lower growth and appear less mature. They are characterized by smaller crowns, as observed during fieldwork. The corresponding textures in the images are rather thin open or closed in these areas (classes 1 and 3, [Figure 6.6b](#)).

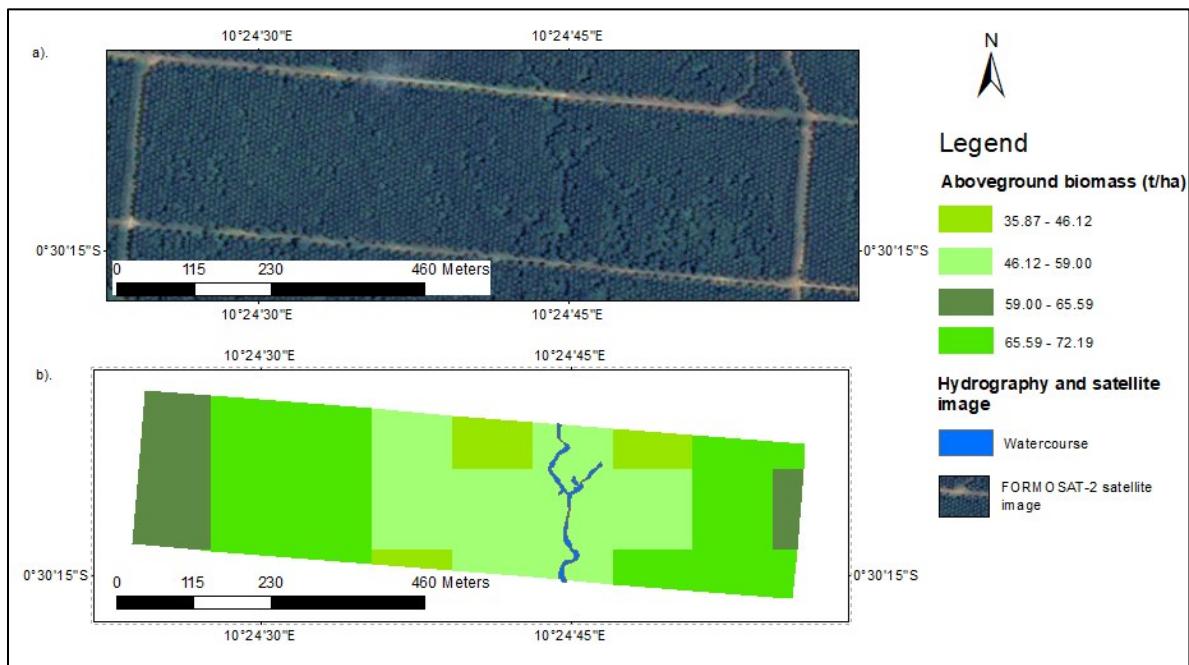


Figure 6.8. Multispectral satellite image of the study area (a) and aboveground oil palm biomass map derived with MARS (Model 3) from FORMOSAT-2 FOTO indices (b).

6.5 Discussion

6.5.1 Potential of FOTO indices for oil palms

FOTO indices that were obtained using factor scores for the first three axes of the principal component analysis allowed us to capture coarse and fine textures of oil palm crowns. They also made it possible to characterize the degree of canopy openness and closure. Various studies have also shown the ability of FOTO indices to describe the textures of the canopy of forests and oil palms [6,8,14]. The homogeneity and the simple structures of the mature oil palm stand in an agro-industrial plantation context certainly favored the performance of FOTO indices. According to its original applications, the FOTO method is best suited for treating homogeneous stands [18,48]. Overall, the palms that were considered were mature (>30-years-

old) and the differences that were observed between them could be mainly attributed to their location, i.e., either in uplands or in low-lying areas, which conferred greater homogeneity to the images. Yet, FORMOSAT-2 data captured texture information better than PlanetScope did. These data resulted from a pansharpening process and showed greater contrast with a fine spatial resolution ($2\text{ m} \times 2\text{ m}$), thereby favoring a sharper delineation of palm crowns. In addition, radiometric uncertainty of FORMOSAT-2 was less than 5% [49], which helped to reduce noise in the data. To minimize information losses and noise, no radiometric correction was applied to the FORMOSAT-2 image, as recommended in previous work employing the FOTO method [8]. A low noise level favors full coverage of the Nyquist frequency by the spatial frequencies of the r -spectrum over the very first wavenumbers, as was the case in this study with the FORMOSAT-2 image ([Figure 6.5](#)).

FOTO indices that were derived from PlanetScope also captured variation in the texture of oil palms, but in a less clear-cut manner. By comparing the Nyquist frequencies that were obtained, we observe that spatial frequencies of the PlanetScope r -spectrum contain more noise than those of FORMOSAT-2, especially for the first three wavenumbers. Several factors could explain these differences. The spatial resolution of PlanetScope ($3.125\text{ m} \times 3.125\text{ m}$), although very good, is lower than that of the FORMOSAT-2 product used here. This may possibly affect the discrimination of palm crowns. The PlanetScope image had already undergone radiometric corrections, changing from grey levels to radiances at the top of the atmosphere. Further, radiometric uncertainty of PlanetScope is on the order of 5–6% [50], which is higher than that of FORMOSAT-2. The combination of these different factors can promote loss of information and limit the performance of PlanetScope [50].

Nevertheless, we found that FOTO indices that were derived independently from the two types of images are significantly correlated, except for the third component. Indeed, the correlation between FORMOSAT-2 PC1 and PlanetScope PC1 is $r = 0.80$, while the correlation between the two PC2 is $r = 0.81$. PC3, which consisted primarily of noise, is uncorrelated ($r = -0.36$). These significant correlations indicated that FORMOSAT-2 and PlanetScope captured very similar information in their first two FOTO indices, even though the images were acquired on very different dates (2011 for FORMOSAT-2; 2017 for PlanetScope). This difference in years could initially be viewed as a handicap. However, several studies agree that the growth rate of oil palm in agro-industrial plantations stabilizes after 25 years, and that its height growth gradually slows down towards 30 years [51,52,53]. The stabilization of the growth rate affects several structural parameters (diameter, crown size), which may be important for estimating AGB using FOTO indices [42]. As the study was carried out on a mature plantation, the effect of different dates of image acquisition was not noticed.

Choosing the best window size is a very important step in implementing FOTO. To determine this size in this study, the window size that produced the highest Nyquist frequency was selected for each image. This choice also took into account the decomposition or separation of the principal component scores. This separation was observed in the ordination of factor scores for the two principal components of the *r*-spectra for each of the images in the study. With this choice, the number of scores that were available in each principal component with each window was also considered sufficient for establishing relationships between the FOTO indices and AGB [8]. These different choices made it possible to facilitate the application of FFT-2D analysis and production of the *r*-spectra. Some scores in the present study appear very high (**Figure 6.6**). However, as also observed and reported in Couteron et al. [37,40], these high values closely match the fine textured grain, and are not outliers.

6.5.2 Estimation of aboveground biomass

The study established different models for estimating AGB based on the MLR approach and the MARS method. Equations that were developed with MLR were very significant overall. The validation process confirmed the robustness of these relationships, especially with FORMOSAT-2 (Model 1, $R^2 = 0.85$, $p = 0.0001$, $\text{RMSE} = 4.18 \text{ t ha}^{-1}$, %RMSE = 6.56%). With MARS, we developed three models for each type of image. Some of these models used only basic piecewise functions, while others integrated the interactions that occurred between FOTO indices (PC1, PC2 and PC3). Integration of these terms provided additional adjustments that slightly improved model performance. Yet, this improvement frequently was not significant considering the RMSE differences. For the best two models with FORMOSAT-2 data, the difference is <0.2%, while it is less than 0.8% for PlanetScope. With MARS, it is possible to consider several combinations of basic functions. Models 3 to 5 that were developed for FORMOSAT-2 and Models 6 to 8 for PlanetScope were apparently the best compromises in this study. Of these, Model 3 stands out as the most efficient following the validation process, with $R^2 = 0.92$, $p < 0.0001$, and %RMSE = 6.09%. For comparison, larger errors, ranging from 28 to 36% were reported in [4] for AGB prediction uncertainties of young oil palms (1 to 5 years), based on models using spectral indices and Normalized Difference Vegetation Index (NDVI). The FOTO PC1 index plays a crucial role in each of the models developed in the present study. This was not very surprising, since PC1 already explains several important structural parameters of the oil palm stand, including basal area ($R^2 = 0.68$ to 0.84), DBH ($R^2 = 0.64$ to 0.78), stem height ($R^2 = 0.53$ to 0.56) and density ($R^2 = 0.50$ to 0.54) (see **Figure 6.7**). These different parameters are critical for biomass estimation. PC2 (and, to a lesser extent, PC3) provided additional information that favors more accurate biomass estimation.

The relatively homogeneous structure of the oil palm plantation is well captured by the FOTO indices, particularly at the FORMOSAT-2 scale, thereby favoring a more accurate estimate of aboveground biomass. In a study in Malaysian Borneo, Singh et al. [14a] similarly reported very significant results ($R^2 = 0.83$) between AGB of young oil palms (<9-year) and FOTO indices that were derived from SPOT 5 imagery acquired at a fine spatial resolution similar to that of FORMOSAT-2 (2.5 m \times 2.5 m). The results found in this study are comparable to those reported in several other studies for different vegetation types. Indeed, strong relationships ($R^2 = 0.92$) have been shown between AGB of mangroves in French Guiana and the FOTO indices (PC1, PC2 and PC3) derived from panchromatic Ikonos image at a spatial resolution of 1 m [8]. In several studies, the FOTO index (PC1) was well correlated to structural parameters of tropical forests [6,14,40,42], as was the case here for oil palms. For example, the study in [40] on tropical forest reported $R^2 = 0.57$ between FOTO PC1 and stem height, which is similar to the values we found here for oil palms ($R^2 = 0.56$ with FORMOSAT-2, and 0.53 with PlanetScope). In addition, based on simulations, Barbier et al. [42] reported good relationships between PC1 and forest canopy DBH ($R^2 = 0.75$), crown size ($R^2 = 0.62$), but the correlation with density was relatively weak ($R^2 = 0.35$). Singh et al. [14a] found strong relationships between FOTO indices and structural parameters of a mixed forest landscape. The biomass models that were developed in our study with FORMOSAT-2 FOTO indices apparently performed slightly better than those of PlanetScope, as shown during the validation phase (**Table 6.5**). The average difference in terms of %RMSE is in the order of about 3%. Radiometric noise in PlanetScope images (5 to 6%; [50]) was higher than in FORMOSAT-2 (<5%; [49]), as were differences in spatial resolution and the influence of image processing on calculation of the FOTO indices. Aside from the characteristics and the quality inherent to the different types of images, potential measurement errors of oil palm variables in the field may also affect the results found.

Models that were based on the MARS approach are more dependent on the range of data values and their degree of autocorrelation than on pre-processing applied to satellite images [54]. This result underscores the importance of principal component analysis, which reduces correlations in FOTO indices. In all of the results that we obtained, the MARS approach was well suited to estimating AGB in oil palm plantations, both with PlanetScope and FORMOSAT-2 imagery. The performance of MARS is attributable to the method's ability to transform and select important variables, and then to identify non-linear and multidimensional interactions between them [25,33,55]. Therefore, it was not surprising that various previous studies have reported favorable results for the MARS method compared to other statistical methods (logistic regression, MLR, among others) in a range of fields, such as medicine,

pedology, hydrology and forestry [23,31,32,33]. The MARS approach deserves further investigation in remote sensing for AGB estimation, not only of plantations but also of natural forests. Other advanced methods that are based on the concept should also be introduced, including Multivariate Adaptive Regression Spline Differential Evolution (MARS-DE), which has been recently proposed by Al-Sudani et al. [56].

Despite the very significant results that were obtained, the study had some limitations that should be mentioned. The number of sample plots that were considered is relatively small. The use of a sufficient number of sample plots randomly distributed on plantations at various growth stages would improve the robustness of AGB models that are based upon FOTO indices. In this sense, PlanetScope images and other types of fine-resolution optical images (SPOT, PLEADES, SkySat, among others) could be analyzed to better understand the effects of spatial resolution, radiometric noise and pre-processing. The very encouraging results that were obtained here with FOTO indices also permit the use of other texture indices that are derived, for example, from a grey-scale co-occurrence matrix, wavelet decomposition or multiband texture analysis. The addition of auxiliary information, such as topographic, climatic or geomorphological data, could also be considered for improving estimates of AGB [13,57].

6.6 Conclusion

This study estimated oil palm AGB with MARS and MLR using PCA scores (components 1, 2 and 3) performed on FORMOSAT-2 and PlanetScope *r*-spectra. These scores were considered as FOTO textural indices for each image type. The results that were obtained with both approaches are very good overall, especially when FORMOSAT-2 data are considered. Slightly higher errors were obtained with PlanetScope compared to FORMOSAT-2, according to the validation performed. The different models that were developed with MARS, particularly those integrating interaction terms between the FOTO indices (explanatory variables), proved to be more efficient in the study for both type of satellite data. They all integrate the basis functions of the FOTO indices of the three PCA axes and contain their interaction terms. The best model in the study is based on FORMOSAT-2 FOTO indices. It was chosen to produce an AGB map of the study area. Upon further studies, such a model could be used to map *AGB* of oil palms in the Congo Basin using remote sensing data. Then corresponding sequestered carbon could be evaluated, with linkage to climate change. The present study focused mainly on a mature oil palm plantation. Subsequent work would have to extend it to larger plantation areas with different stages of palm growth and development, and use a larger number of sample plots. The MARS approach should be further investigated not only with different types of very

high-resolution commercial images, but also with free medium-resolution images (e.g., Landsat, Sentinel) for mapping plantation biomass at larger scales.

Author Contributions

Conceptualization, P.M. and K.G.; methodology, P.M. and K.G.; software, P.M.; validation, P.M. and K.G.; formal analysis, P.M.; investigation, P.M.; resources, P.M.; data curation, P.M.; writing—original draft preparation, P.M.; writing—review and editing, P.M and K.G.; visualization, P.M.; supervision, K.G.; project administration, P.M.; funding acquisition, P.M. and K.G. All authors have read and agreed to the published version of the manuscript.

Funding

This study was funded by the Programme Canadien de Bourses de la Francophonie (Government of Canada, Department of Foreign Affairs, Trade and Development, Canadian Partnership Branch) and by the Natural Sciences and Engineering Research Council of Canada (NSERC).

Acknowledgments

This study was funded by Programme Canadien de Bourses de la Francophonie (Government of Canada, Canadian Partnership Branch, Department of Foreign Affairs, Trade and Development) and by NSERC (Natural Sciences and Engineering Research Council of Canada). We thank Gabonese companies and government institutions that contributed substantially to the field data measurement campaign and satellite images that were used in this study: Olam Palm Gabon, the Institut de Recherche en Ecologie Tropicale (IRET), and the Project for the Development of a National Forest Resources Inventory System Contributing to Sustainable Forest Management (PDSIRFN), Ministère en charge des Eaux et Forêts au Gabon. We thank the many people who contributed to various aspects of the study, including the experimental design and fieldwork in Makouké (Pr. Alfred Ngomanda, Andréana P.M. Biyogo, Quentin B. Meunier, Simplice Ntem, Cynel G. Moundounga, Quentin M. Mavouroulo, Lucien Ligna, Davy N. Ikapi and Landry A.C. Ndjella, Fatoumata A. Eba and Herman Kombo), and W.F.J. Parsons for English translation.

Conflicts of Interest

The authors declare no conflict of interest.

Appendix 6.A

Table 6.A1. Mean measurements of structural attributes of oil palms and FOTO indices of FORMOSAT-2 and PlanetScope from 40 sample plots

Sample plot	DBH (cm)	Ht (m)	NP	Sample plot size (ha)	Density (D, stems ha ⁻¹)	Basal area (BA, m ² ha ⁻¹)	AGB (t ha ⁻¹)	FOTO FORMOSAT-2		FOTO FORMOSAT-2		Sample plot	FOTO PlanetScope		FOTO PlanetScope	
								Index PC 1	Index PC 2	Index PC 3	Index PC 1		Index PC 1	Index PC 2	Index PC 3	
1	50.1	9.0	14	0.0949	147.58	29.12	59.98	3.8250	1.9841	1.3269	33	-2.0411	-1.3696	0.8058		
2	49.2	8.7	13	0.0949	137.04	26.05	52.50	3.8250	1.9841	1.3269	28	-1.0427	1.6428	0.4886		
3	52.0	9.5	13	0.0949	137.04	29.10	61.94	3.0635	2.6853	0.5705	6	-2.3456	-1.7279	-1.1479		
4	49.9	8.1	12	0.0949	126.50	24.74	46.75	3.9768	1.4688	2.0267	35	1.2730	0.6543	0.5863		
5	52.2	8.9	12	0.0949	126.50	27.07	54.50	3.8010	2.0356	1.2569	37	-2.3456	-1.7279	-1.1479		
6	55.0	9.8	14	0.0949	147.58	35.06	75.15	-3.5172	-1.5532	0.7565	39	-2.3484	-1.7393	-1.0638		
7	47.5	8.1	10	0.0949	105.41	18.68	35.89	13.1415	-7.9270	-2.4761	15	-2.2906	-1.6971	-1.1064		
8	53.6	9.7	13	0.0949	137.04	30.92	66.28	-2.2736	-0.3779	-0.3589	20	1.1568	3.3801	-0.4313		
9	54.0	9.2	14	0.0949	147.58	33.80	69.16	-3.3880	-1.4290	0.7084	7	13.6523	-4.0852	0.2206		
10	50.6	7.9	12	0.0949	126.50	25.44	46.87	3.8010	2.0356	1.2569	23	-1.5804	-0.8723	-0.0309		
11	52.4	8.1	12	0.0949	126.50	27.28	50.71	2.2651	0.7727	1.8012	40	4.8270	0.1599	-0.8179		
12	50.1	8.5	12	0.0949	126.50	24.94	48.99	4.5290	0.7573	3.1037	29	-2.2852	-1.5613	0.2094		
13	49.0	8.8	12	0.0949	126.50	23.85	48.60	2.6622	2.3338	-1.7137	25	-2.3446	-1.7236	-1.1794		
14	53.8	9.5	13	0.0949	137.04	31.15	65.55	-3.5548	-1.5942	0.7865	13	6.4176	0.5759	-0.6511		
15	54.0	9.2	15	0.0949	158.12	36.21	74.10	-3.3880	-1.4290	0.7084	17	2.1185	1.9107	-0.1541		
16	54.1	9.5	14	0.0949	147.58	33.94	71.27	-3.5198	-1.5316	0.7925	31	-0.7382	-0.5980	0.3733		
17	53.8	9.5	11	0.0949	115.96	26.36	55.46	2.1518	3.5466	-2.6997	34	0.5918	2.4826	-2.2313		
18	47.3	7.5	13	0.0949	137.04	24.08	43.46	3.9768	1.4688	2.0267	22	-2.3484	-1.7393	-1.0638		
19	54.4	9.6	14	0.0949	147.58	34.30	72.53	-3.4823	-1.4911	0.6804	21	-2.0411	-1.3696	0.8058		
20	50.3	8.9	11	0.0949	115.96	23.04	46.97	4.7157	0.5084	3.3331	5	0.0175	3.2484	0.3644		
21	54.5	10.0	13	0.0949	137.04	31.97	69.89	-3.3296	-1.2211	-0.1283	27	2.1185	1.9107	-0.1541		
22	54.0	9.9	13	0.0949	137.04	31.38	68.26	-3.4365	-1.4652	0.6766	30	-0.5819	0.2548	1.3118		
23	54.1	10.0	14	0.0949	147.58	33.92	74.35	-2.8117	-0.5214	-0.1735	38	-2.2852	-1.5613	0.2094		
24	53.4	9.3	13	0.0949	137.04	30.74	63.68	-2.0619	0.6111	-1.4960	8	-0.7382	-0.5980	0.3733		
25	54.0	9.8	13	0.0949	137.04	31.38	67.68	-3.5548	-1.5942	0.7865	14	-2.3446	-1.7236	-1.1794		
26	54.0	9.8	13	0.0949	137.04	31.38	67.68	-2.8117	-0.5214	-0.1735	1	0.1290	3.2638	0.2358		
27	50.4	9.5	13	0.0949	137.04	27.34	58.80	2.1518	3.5466	-2.6997	32	1.2730	0.6543	0.5863		
28	51.0	8.8	12	0.0949	126.50	25.84	51.94	4.1436	1.5851	2.1661	3	-1.1820	2.6869	0.6168		
29	54.6	9.4	14	0.0949	147.58	34.55	71.71	-3.4018	-1.4043	0.3814	16	-2.3308	-1.7119	-1.5686		
30	54.1	9.7	12	0.0949	126.50	29.08	62.14	-2.0619	0.6111	-1.4960	26	-1.5804	-0.8723	-0.0309		
31	54.2	9.9	12	0.0949	126.50	29.16	63.35	-2.2736	-0.3779	-0.3589	36	13.6523	-4.0852	0.2206		
32	53.2	9.6	13	0.0949	137.04	30.46	64.90	-0.9198	0.8538	-1.5104	10	0.0175	3.2484	0.3644		
33	54.0	10.0	14	0.0949	147.58	33.80	74.12	-3.3296	-1.2211	-0.1283	4	1.2443	3.4173	-2.4650		
34	52.3	9.3	12	0.0949	126.50	27.18	56.71	2.2651	0.7727	1.8012	2	0.1290	3.2638	0.2358		
35	53.4	9.5	12	0.0949	126.50	28.33	59.76	-0.9198	0.8538	-1.5104	24	-0.5819	0.2548	1.3118		
36	50.0	9.5	10	0.0949	105.41	20.70	44.64	13.1415	-7.9270	-2.4761	18	1.2443	3.4173	-2.4650		

37	53.8	9.5	14	0.0949	147.58	33.55	70.59	-3.5172	-1.5532	0.7565	12	1.6351	3.2526	-0.4513
38	53.8	10.0	14	0.0949	147.58	33.55	73.67	-3.4018	-1.4043	0.3814	9	-2.2906	-1.6971	-1.1064
39	53.5	9.9	13	0.0949	137.04	30.81	67.21	-3.4365	-1.4652	0.6766	11	0.5918	2.4826	-2.2313
40	52.0	9.2	12	0.0949	126.50	26.86	55.67	1.2572	1.4553	-1.1441	19	-2.3184	-1.6708	-1.0029

References

1. Kumar, L.; Mutanga, O. Remote Sensing of Above-Ground Biomass. *Remote Sens.* **2017**, *9*, 935. [[Google Scholar](#)] [[CrossRef](#)]
2. Forkuor, G.; Benewinde Zoungrana, J.B.; Dimobe, K.; Ouattara, B.; Vadrevu, K.P.; Tondoh, J.E. Above-ground biomass mapping in West African dryland forest using Sentinel-1 and 2 datasets—A case study. *Remote Sens. Environ.* **2020**, *236*, 111496. [[Google Scholar](#)] [[CrossRef](#)]
3. Kumar, L.; Sinha, P.; Taylor, S.; Alqrashi, A.F. Review of the use of remote sensing for biomass estimation to support renewable energy generation. *J. Appl. Remote Sens.* **2015**, *9*, 097696. [[Google Scholar](#)] [[CrossRef](#)]
4. Thenkabail, P.S.; Stucky, N.; Griscom, B.W.; Ashton, M.S.; Diels, J.; Van der Meer, B.; Enclona, E. Biomass estimations and carbon stock calculations in the oil palm plantations of African derived savannas using IKONOS data. *Int. J. Remote Sens.* **2004**, *25*, 5447–5472. [[Google Scholar](#)] [[CrossRef](#)]
5. Ningthoujam, R.K.; Joshi, P.K.; Roy, P.S. Retrieval of forest biomass for tropical deciduous mixed forest using ALOS PALSAR mosaic imagery and field plot data. *Int. J. Appl. Earth Obs. Geoinf.* **2018**, *69*, 206–216. [[Google Scholar](#)] [[CrossRef](#)]
6. Ploton, P.; Pélissier, R.; Proisy, C.; Flavenot, T.; Barbier, N.; Rai, S.N.; Couteron, P. Assessing aboveground tropical forest biomass using Google Earth canopy images. *Ecol. Appl.* **2012**, *22*, 993–1003. [[Google Scholar](#)] [[CrossRef](#)] [[PubMed](#)]
7. Lu, J.; Wang, H.; Qin, S.; Cao, L.; Pu, R.; Li, G.; Sun, J. Estimation of aboveground biomass of Robinia pseudoacacia forest in the Yellow River Delta based on UAV and Backpack LiDAR point clouds. *Int. J. Appl. Earth Obs. Geoinf.* **2020**, *86*, 102014. [[Google Scholar](#)] [[CrossRef](#)]
8. Proisy, C.; Couteron, P.; Fromard, F. Predicting and mapping mangrove biomass from canopy grain analysis using Fourier-based textural ordination of IKONOS images. *Remote Sens. Environ.* **2007**, *109*, 379–392. [[Google Scholar](#)] [[CrossRef](#)]
9. Puliti, S.; Hauglin, M.; Breidenbach, J.; Montesano, P.; Neigh, C.S.R.; Rahlf, J.; Solberg, S.; Klingenberg, T.F.; Astrup, R. Modelling above-ground biomass stock over Norway using national forest inventory data with ArcticDEM and Sentinel-2 data. *Remote Sens. Environ.* **2020**, *236*, 111501. [[Google Scholar](#)] [[CrossRef](#)]

10. Morel, A.C.; Fisher, J.B.; Malhi, Y. Evaluating the potential to monitor aboveground biomass in forest and oil palm in Sabah, Malaysia, for 2000–2008 with Landsat ETM+ and ALOS-PALSAR. *Int. J. Remote Sens.* **2012**, *33*, 3614–3639. [[Google Scholar](#)] [[CrossRef](#)]
11. Singh, M.; Malhi, Y.; Bhagwat, S. Evaluating land use and aboveground biomass dynamics in an oil palm-dominated landscape in Borneo using optical remote sensing. *J. Appl. Remote Sens.* **2014b**, *8*, 083695. [[Google Scholar](#)] [[CrossRef](#)]
12. García, M.; Saatchi, S.; Ustin, S.; Balzter, H. Modelling forest canopy height by integrating airborne LiDAR samples with satellite Radar and multispectral imagery. *Int. J. Appl. Earth Obs. Geoinf.* **2018**, *66*, 159–173. [[Google Scholar](#)] [[CrossRef](#)]
13. Wang, G.; Guan, D.; Xiao, L.; Peart, M.R. Forest biomass-carbon variation affected by the climatic and topographic factors in Pearl River Delta, South China. *J. Environ. Manag.* **2019**, *232*, 781–788. [[Google Scholar](#)] [[CrossRef](#)] [[PubMed](#)]
14. Singh, M.; Malhi, Y.; Bhagwat, S. Biomass estimation of mixed forest landscape using a Fourier transform texture-based approach on very-high-resolution optical satellite imagery. *Int. J. Remote Sens.* **2014a**, *35*, 3331–3349. [[Google Scholar](#)] [[CrossRef](#)]
15. Ganivet, E.; Bloomberg, M. Towards rapid assessments of tree species diversity and structure in fragmented tropical forests: A review of perspectives offered by remotely-sensed and field-based data. *For. Ecol. Manag.* **2019**, *432*, 40–53. [[Google Scholar](#)] [[CrossRef](#)]
16. Singh, M.; Evans, D.; Friess, D.; Tan, B.; Nin, C. Mapping Above-Ground Biomass in a Tropical Forest in Cambodia Using Canopy Textures Derived from Google Earth. *Remote Sens.* **2015**, *7*, 5057–5076. [[Google Scholar](#)] [[CrossRef](#)]
17. Barbier, N.; Couteron, P. Attenuating the bidirectional texture variation of satellite images of tropical forest canopies. *Remote Sens. Environ.* **2015**, *171*, 245–260. [[Google Scholar](#)] [[CrossRef](#)]
18. Ploton, P.; Barbier, N.; Couteron, P.; Antin, C.M.; Ayyappan, N.; Balachandran, N.; Barathan, N.; Bastin, J.F.; Chuyong, G.; Dauby, G.; et al. Toward a general tropical forest biomass prediction model from very high resolution optical satellite images. *Remote Sens. Environ.* **2017**, *200*, 140–153. [[Google Scholar](#)] [[CrossRef](#)]
19. Guo, W.; Rees, W.G. Altitudinal forest-tundra ecotone categorization using texture-based classification. *Remote Sens. Environ.* **2019**, *232*, 111312. [[Google Scholar](#)] [[CrossRef](#)]
20. Bugnicourt, P.; Guitet, S.; Santos, V.F.; Blanc, L.; Sotta, E.D.; Barbier, N.; Couteron, P. Using textural analysis for regional landform and landscape mapping, Eastern Guiana Shield. *Geomorphology* **2018**, *317*, 23–44. [[Google Scholar](#)] [[CrossRef](#)]

21. Chong, K.L.; Kanniah, K.D.; Pohl, C.; Tan, K.P. A review of remote sensing applications for oil palm studies. *Geo-Spat. Inf. Sci.* **2017**, *20*, 184–200. [[Google Scholar](#)] [[CrossRef](#)]
22. Liang, L.; Di, L.; Zhang, L.; Deng, M.; Qin, Z.; Zhao, S.; Lin, H. Estimation of crop LAI using hyperspectral vegetation indices and a hybrid inversion method. *Remote Sens. Environ.* **2015**, *165*, 123–134. [[Google Scholar](#)] [[CrossRef](#)]
23. Vaglio-Laurin, G.; Puletti, N.; Chen, Q.; Corona, P.; Papale, D.; Valentini, R. Above ground biomass and tree species richness estimation with airborne lidar in tropical Ghana forests. *Int. J. Appl. Earth Obs. Geoinf.* **2016**, *52*, 371–379. [[Google Scholar](#)] [[CrossRef](#)]
24. Navarro, J.A.; Algeet, N.; Fernández-Landa, A.; Esteban, J.; Rodríguez-Noriega, P.; Guillén-Climent, M.L. Integration of UAV, Sentinel-1, and Sentinel-2 Data for Mangrove Plantation Aboveground Biomass Monitoring in Senegal. *Remote Sens.* **2019**, *11*, 77. [[Google Scholar](#)] [[CrossRef](#)]
25. Zhang, W.; Goh, A.T.C. Multivariate adaptive regression splines and neural network models for prediction of pile drivability. *Geosci. Front.* **2016**, *7*, 45–52. [[Google Scholar](#)] [[CrossRef](#)]
26. Chen, L.; Wang, Y.; Ren, C.; Zhang, B.; Wang, Z. Optimal Combination of Predictors and Algorithms for Forest Above-Ground Biomass Mapping from Sentinel and SRTM Data. *Remote Sens.* **2019**, *11*, 414. [[Google Scholar](#)] [[CrossRef](#)]
27. Friedman, J.H. Multivariate Adaptive Regression Splines. *Ann. Stat.* **1991**, *19*, 1–67. [[Google Scholar](#)] [[CrossRef](#)]
28. López Serrano, P.; Corral-Rivas, J.J.; Díaz Varela, R.; Álvarez González, J.G.; López-Sánchez, C. Evaluation of Radiometric and Atmospheric Correction Algorithms for Aboveground Forest Biomass Estimation Using Landsat 5 TM Data. *Remote Sens.* **2016**, *8*, 369. [[Google Scholar](#)] [[CrossRef](#)]
29. Piikki, K.; Söderström, M. Digital soil mapping of arable land in Sweden—Validation of performance at multiple scales. *Geoderma* **2019**, *352*, 342–350. [[Google Scholar](#)] [[CrossRef](#)]
30. Leathwick, J.R.; Elith, J.; Hastie, T. Comparative performance of generalized additive models and multivariate adaptive regression splines for statistical modelling of species distributions. *Ecol. Model.* **2006**, *199*, 188–196. [[Google Scholar](#)] [[CrossRef](#)]
31. Pramila, P.V.; Mahesh, V. Comparison of Multivariate Adaptive Regression Splines and Random Forest Regression in Predicting Forced Expiratory Volume in One Second. *Int. J. Bioeng. Life Sci.* **2015**, *9*, 338–342. [[Google Scholar](#)] [[CrossRef](#)]
32. Wang, L.J.; Guo, M.; Sawada, K.; Lin, J.; Zhang, J. Landslide susceptibility mapping in Mizunami City, Japan: A comparison between logistic regression, bivariate statistical

- analysis and multivariate adaptive regression spline models. *CATENA* **2015**, *135*, 271–282. [Google Scholar] [CrossRef]
33. Park, S.; Hamm, S.Y.; Jeon, H.T.; Kim, J. Evaluation of Logistic Regression and Multivariate Adaptive Regression Spline Models for Groundwater Potential Mapping Using R and GIS. *Sustainability* **2017**, *9*, 1157. [Google Scholar] [CrossRef]
 34. García Nieto, P.J.; García-Gonzalo, E.; Sánchez Lasheras, F.; Paredes-Sánchez, J.P.; Riesgo Fernández, P. Forecast of the higher heating value in biomass torrefaction by means of machine learning techniques. *J. Comput. Appl. Math.* **2019**, *357*, 284–301. [Google Scholar] [CrossRef]
 35. Pardé, J.; Bouchon, J. *Dendrométrie*, 2nd ed.; Ecole Nationale du génie rural, des Eaux et Forêts : Nancy, Mexique, 1988; p. 328. ISBN 2-85710-025-6. [Google Scholar]
 36. Migolet, P.; Goïta, K.; Ngomanda, A.; Mekui Biyogo, A.P. Estimation of Aboveground Oil Palm Biomass in a Mature Plantation in the Congo Basin. *Forests* **2020**, *11*, 544. [Google Scholar] [CrossRef]
 37. Couteron, P.; Barbier, N.; Gautier, D. Textural Ordination Based on Fourier Spectral Decomposition: A Method to Analyze and Compare Landscape Patterns. *Landsc. Ecol.* **2006**, *21*, 555–567. [Google Scholar] [CrossRef]
 38. Renshaw, E.; Ford, E.D. The Interpretation of Process from Pattern Using Two-Dimensional Spectral Analysis: Methods and Problems of Interpretation. *J. R. Stat. Soc. Ser. C* **1983**, *32*, 51–63. [Google Scholar] [CrossRef]
 39. Mugglesstone, M.A.; Renshaw, E. Detection of geological lineations on aerial photographs using two-dimensional spectral analysis. *Comput. Geosci.* **1998**, *24*, 771–784. [Google Scholar] [CrossRef]
 40. Couteron, P.; Pelissier, R.; Nicolini, E.A.; Paget, D. Predicting tropical forest stand structure parameters from Fourier transform of very high-resolution remotely sensed canopy images. *J. Appl. Ecol.* **2005**, *42*, 1121–1128. [Google Scholar] [CrossRef]
 41. Barbier, N.; Couteron, P.; Proisy, C.; Malhi, Y.; Gastellu-Etchegorry, J.P. The variation of apparent crown size and canopy heterogeneity across lowland Amazonian forests. *Glob. Ecol. Biogeogr.* **2010**, *19*, 72–84. [Google Scholar] [CrossRef]
 42. Barbier, N.; Couteron, P.; Gastelly-Etchegorry, J.P.; Proisy, C. Linking canopy images to forest structural parameters: Potential of a modeling framework. *Ann. For. Sci.* **2012**, *69*, 305–311. [Google Scholar] [CrossRef]
 43. Kuyah, S.; Dietz, J.; Muthuri, C.; Jamnadass, R.; Mwangi, P.; Coe, R.; Neufeldt, H. Allometric equations for estimating biomass in agricultural landscapes: I. Aboveground biomass. *Agric. Ecosyst. Environ.* **2012**, *158*, 216–224. [Google Scholar] [CrossRef]

44. Nisbet, R.; Miner, G.; Yale, K.; Nisbet, R. Advanced Algorithms for Data Mining. In *Handbook of Statistical Analysis and Data Mining Applications*, 2nd ed.; Elsevier: London, UK, 2018; pp. 149–167. ISBN 978-0-12-416632-5. [[Google Scholar](#)] [[CrossRef](#)]
45. Nguyen, T.H.; Jones, S.D.; Soto-Berelov, M.; Haywood, A.; Hislop, S. Monitoring aboveground forest biomass dynamics over three decades using Landsat time-series and single-date inventory data. *Int. J. Appl. Earth Obs. Geoinf.* **2020**, *84*, 101952. [[Google Scholar](#)] [[CrossRef](#)]
46. Xiong, Y.; Cakir, R.; Phan, S.M.; Ola, A.; Krauss, K.W.; Lovelock, C.E. Global patterns of tree stem growth and stand aboveground wood production in mangrove forests. *For. Ecol. Manag.* **2019**, *444*, 382–392. [[Google Scholar](#)] [[CrossRef](#)]
47. Chen, W.; Zhao, H.; Li, J.; Zhu, L.; Wang, Z.; Zeng, J. Land use transitions and the associated impacts on ecosystem services in the Middle Reaches of the Yangtze River Economic Belt in China based on the geo-informatic Tupu method. *Sci. Total Environ.* **2020**, *701*, 134690. [[Google Scholar](#)] [[CrossRef](#)] [[PubMed](#)]
48. Bastin, J.F.; Barbier, N.; Couteron, P.; Adams, B.; Shapiro, A.; Bogaert, J.; De Cannière, C. Aboveground biomass mapping of African forest mosaics using canopy texture analysis: Toward a regional approach. *Ecol. Appl.* **2014**, *24*, 1984–2001. [[Google Scholar](#)] [[CrossRef](#)] [[PubMed](#)]
49. Liu, C.C.; Kamei, A.; Hsu, K.H.; Tsuchida, S.; Huang, H.M.; Kato, S.; Nakamura, R.; Wu, A.M. Vicarious calibration of the Formosat-2 remote sensing instrument. *IEEE Trans. Geosci. Remote Sens.* **2010**, *48*, 2162–2169. [[Google Scholar](#)] [[CrossRef](#)]
50. Cooley, S.; Smith, L.; Stepan, L.; Mascaro, J. Tracking Dynamic Northern Surface Water Changes with High-Frequency Planet CubeSat Imagery. *Remote Sens.* **2017**, *9*, 1306. [[Google Scholar](#)] [[CrossRef](#)]
51. De Berchoux, C.; Quencez, P. Etude de la croissance en hauteur' huile en Côte-d' Ivoire du palmier a Application pratique au problème de la replantation. *Oléagineux* **1980**, *35*, 431–438. [[Google Scholar](#)]
52. Jacquemard, J.C.; Baudouin, L. Contribution à l'étude de la croissance du palmier à huile. Présentation d'un modèle descriptif. *Oléagineux* **1987**, *42*, 343–351. [[Google Scholar](#)]
53. Masani, M.Y.A.; Izawati, A.M.D.; Rasid, O.A.; Parveez, G.K.A. Biotechnology of oil palm: Current status of oil palm genetic transformation. *Biocatal. Agric. Biotechnol.* **2018**, *15*, 335–347. [[Google Scholar](#)] [[CrossRef](#)]
54. Volkan Bilgili, A.; van Es, H.M.; Akbas, F.; Durak, A.; Hively, W.D. Visible-near infrared reflectance spectroscopy for assessment of soil properties in a semi-arid area of Turkey. *J. Arid Environ.* **2010**, *74*, 229–238. [[Google Scholar](#)] [[CrossRef](#)]

55. García Nieto, P.J.; Martínez Torres, J.; De Cos Juez, F.J.; Sánchez Lasheras, F. Using multivariate adaptive regression splines and multilayer perceptron networks to evaluate paper manufactured using *Eucalyptus globulus*. *Appl. Math. Comput.* **2012**, *219*, 755–763. [[Google Scholar](#)] [[CrossRef](#)]
56. Al-Sudani, Z.A.; Salih, S.Q.; Sharafati, A.; Yaseen, Z.M. Development of multivariate adaptive regression spline integrated with differential evolution model for streamflow simulation. *J. Hydrol.* **2019**, *573*, 1–12. [[Google Scholar](#)] [[CrossRef](#)]
57. Xu, M.; Zhang, S.; Wen, J.; Yang, X. Multiscale spatial patterns of species diversity and biomass together with their correlations along geographical gradients in subalpine meadows. *PloS ONE* **2019**, *14*, e0211560. [[Google Scholar](#)] [[CrossRef](#)] [[PubMed](#)]

CHAPITRE 7. Estimation of the total dry aboveground biomass in the tropical forests of Congo Basin using optical, LiDAR, and radar data (Article 3)

7.1 Présentation de l'article

Dans cet article, la BA des forêts dans le Bassin du Congo est estimée avec MARS à l'aide des données de télédétection optique, LiDAR et radar. Son originalité découle de l'importance de la thématique traitée, de l'utilisation des données d'inventaires forestier et de télédétection (optique, LiDAR et radar) de la campagne AfriSAR de 2016 et des données d'inventaire forestier de 2017 propres à l'étude. L'originalité résulte aussi de l'estimation de la BA dans le Bassin du Congo avec MARS par la combinaison des indices FOTO et texture de la matrice de co-occurrence de niveaux de gris (GLCM) de SPOT7, des hauteurs médianes de la canapée (RH50) dérivées des données LiDAR, du coefficient de rétrodiffusion (σ^0) et des hauteurs au sommet de la canopée (H_R) acquis à partir des données radar en bande L. Les BA de terrain ont été estimées avec l'équation de Chave *et al.*, (2014) à l'aide du diamètre (D), de la hauteur maximale modélisée de l'arbre (H_T) et de la densité du bois (ρ) des placettes échantillons de 30,8 m × 30,8 m. Deux modèles de BA ont capté notre attention pour leurs faibles erreurs d'estimation des BA de validation ($RMSE \leq 28\%$). Ces deux modèles de BA ont considéré les variables 1) intégrant uniquement RH50 ($RMSE = 28\%$) et 2) combinant RH50, indice FOTO PC2, indice de texture GLCM moyenne et σ^0 ($RMSE = 24\%$). La carte de BA de l'étude de résolution spatiale 0,1 ha a été réalisée avec le meilleur modèle de l'étude. Les performances des BA de la carte de l'étude ($RMSE = 24\%$) ont été meilleures à celles de toutes les BA des cartes existantes ($RMSE \geq 68\%$). Dans le contexte de la présente étude, le développement des modèles de BA est confronté à des limites liées aux erreurs de mesures de terrain, au bruit et à la réduction de la sensibilité des données de télédétection due aux conditions environnementales (forêt tropicale dense, topographie avec variation, sol nus).

Les résultats de cette étude ont été publiés dans la revue *GIScience & Remote Sensing* :

Migolet, P., Goïta, K., Pambo, A. F. K. et Mambimba, A. N. (2022) *Estimation of the total dry aboveground biomass in the tropical forests of Congo Basin using optical, LiDAR, and radar data*. *GIScience & Remote Sensing*, vol. 59, n°1, p. 431-460.

Le contenu du manuscrit publié est présenté dans les pages qui suivent.

Estimation of the total dry aboveground biomass in the tropical forests of Congo Basin using optical, LiDAR, and radar data

by Pierre Migolet, Kalifa Goïta, Aurélie Flore Kouumba Pambo et Aboubakar Ndjouroungui

Mambimba

Remote Sensing

Volume 59, n°1, p. 431-460, 16 février 2022

Estimation of the total dry aboveground biomass in the tropical forests of Congo Basin using optical, LiDAR, and radar data

Pierre Migolet ^{a*}, Kalifa Goïta ^a Aurélie Flore Kouumba Pambo ^b and Aboubakar Ndjomoungui Mambimba^c

^a Centre d'applications et de recherches en télédétection (CARTEL), Département de géomatique appliquée, Université de Sherbrooke, Sherbrooke, Québec, Canada; ^b Agence nationale des parcs nationaux (ANPN) et Centre national de la recherche scientifique et technologique (CENAREST), Libreville, Gabon; ^c Agence Gabonaise d'études et d'Observation Spatiale (AGEOS), Libreville, Gabon.

* Author to whom correspondence should be addressed

Abstract

In this investigation, optical (SPOT-7 NAOMI), airborne LiDAR, and PolInSAR L-band data, along with forest inventories, were employed to develop models for estimating total dry aboveground biomass (AGB) over the tropical forests in the Congo Basin (Gabon) of Central Africa. Remote sensing-based variables like texture (from SPOT), median canopy height (from LiDAR), and backscattering coefficient along with canopy surface heights (from PolInSAR) were used to estimate the AGB. These variables were used individually (or combined) to develop the AGB models based on the multivariate adaptive regression splines (MARS) approach. Validation indicated that in case of the single variable models, the LiDAR-based model yielded the lowest estimation root-mean-square error (RMSE = 28%). The error decreased further when the median canopy height was combined with the texture or with the radar variables (RMSE <25%). The texture derived from the Fourier transform textural ordination (FOTO) approach was more effective in improving the results as compared to the gray level co-occurrence matrices (GLCM) approach. Model validation indicated that the best performance in AGB estimation was achieved by combining optical, LiDAR, and radar data ($R^2 = 0.89$ and RMSE = 24%).

Keywords: Remote sensing; total dry aboveground biomass; tropical forests; Congo Basin; Multivariate Adaptive Regression Splines (MARS).

Résumé

Dans cette étude, des données optiques (SPOT-7 NAOMI), LiDAR aéroportées et PolInSAR en bande L, ainsi que des inventaires forestiers, ont été utilisés pour développer des modèles d'estimation de la biomasse aérienne sèche totale (BA) sur les forêts tropicales du Bassin du Congo (Gabon) d'Afrique centrale. Des variables basées sur la télédétection telles que la texture (de SPOT), la hauteur médiane de la canopée (de LiDAR) et le coefficient de rétrodiffusion ainsi que les hauteurs de surface de la canopée (de PolInSAR) ont été utilisées pour estimer la BA. Ces variables ont été utilisées individuellement (ou combinées) pour développer les modèles BA basés sur l'approche des régressions multivariées par spline adaptative (MARS). La validation a montré que dans le cas des modèles à variable unique, le modèle basé sur LiDAR a produit l'erreur quadratique moyenne d'estimation la plus faible ($RMSE = 28\%$). L'erreur diminuait davantage lorsque la hauteur médiane de la canopée était combinée à la texture ou aux variables radar ($RMSE < 25\%$). La texture dérivée de l'approche d'ordination texturale par transformée de Fourier (FOTO) était plus efficace pour améliorer les résultats par rapport à l'approche des matrices de cooccurrence de niveaux de gris (GLCM). La validation du modèle a indiqué que les meilleures performances dans l'estimation de la BA ont été obtenues en combinant des données optiques, LiDAR et radar ($R^2 = 0,89$ et $RMSE = 24\%$).

Mots-clés : Télédétection ; biomasse aérienne sèche totale; forêts tropicales; Bassin du Congo ; régression multivariée par spline adaptative (MARS).

7.2. Introduction

Forests play a key role in mitigating the effects of climate change (Picard et al. 2018). After the oceans, forests constitute the second largest atmospheric carbon sink, which accounts for more than 70% of the total vegetation biomass (Villard et al. 2016). Carbon is captured and stored by the different components of the trees, which includes branches, trunks, leaves, and roots (Jones et al. 2019). Carbon content assessment routinely considers the total dry above- and belowground biomass (Scharlemann et al. 2014; Wade et al. 2019). Total dry aboveground biomass (AGB) of trees is the total quantity of dry organic matter that is located above the ground, which is accommodated by the branches, leaves, stems, stumps, bark, and fruits (Neumann et al. 2016; Migolet et al. 2020). This dry matter constitutes more than 80% of total forest biomass (Villard et al. 2016).

Traditionally, AGB is estimated using allometric equations, which are based upon forest inventory data. The critical variables that are generally used include diameter, height, and wood density (Chave et al. 2014; Ngomanda et al. 2014; Fayolle et al. 2018). AGB can also be estimated using a combination of remotely sensing data and ground measurements (Migolet et al. 2007; Coulibaly et al. 2008; Cartus, Santoro, and Kellndorfer 2012; Chaparro et al. 2019; Knapp et al. 2020). In this regard, remotely sensed information from a variety of sensors (for example, optical, radar, and LiDAR) at different spatial and temporal resolution have been used over the last several decades (Xue and Su 2017; Cracknell 2018).

However, remote sensing approaches confront various challenges, particularly over the tropical forests. These challenges can include saturation of indices extracted from optical and radar data, or effects of complex topography (Fung 1994; Ploton et al. 2017; Bouvet et al. 2018; García et al. 2018; Marselis et al. 2018; Chaparro et al. 2019; El Hajj et al. 2019; Hiatshwayo et al. 2019; Pourshamsi et al. 2021). Saturation of an index renders it insensitive to characterize changes in the target (Bréda, Soudani, and Bergonzini 2002; Aubert 2012). For example, due to the density of the vegetation, the C-band backscattering coefficient saturates at AGB values evaluated between 70 and 150 t ha⁻¹. Saturation can lead to an underestimation of forest variables, such as canopy height or AGB (Mermoz et al. 2015; García et al. 2018; Bouvet et al. 2018; Pourshamsi et al. 2021). Some indices are relatively less prone to saturation than the others. For instance, FOTO (Fourier transform textural ordination) based indices seem to better resist saturation in stands where AGB can attain 500 Mg ha⁻¹ (Bastin et al. 2014; Tapamo et al. 2014). Synthetic Aperture Radar (SAR) data acquired in L- and P-bands (longer wavelengths) also offer excellent potential in tropical forests (e.g. Sinha et al. 2015; Cartus and Santoro 2019; Pourshamsi et

al. 2018, 2021). LiDAR offers promising performance in estimating tree height (up to 40 m) and biomass (Zolkos, Goetz, and Dubayah 2013; Chen, Vaglio Laurin, and Valentini 2015; Réjou-Méchain et al. 2015; El Hajj et al. 2018; Silva et al. 2018). Nevertheless, LiDAR data might as well be affected by the complexity of the topography/vegetation and the extent of the spatial coverage being considered (Lefsky et al. 2005; Gopalakrishnan et al. 2015; Urbazaev et al. 2018). The links between AGB and remotely sensed indices are generally established using statistical approaches, such as multiple linear regressions (MLR) or power functions (Singh et al. 2015; Chong et al. 2017; Kamir, Waldner, and Hochman 2020). These approaches often have difficulty modeling high-dimensional data from diverse or redundant sources (Almeida et al. 2019b; Ku and Popescu 2019). Almeida et al. (2019b), while formulating AGB models over the Brazilian forests using a combination of LiDAR and hyperspectral data, showed that machine learning (ML) models performed better than linear regressions. In order to overcome the inadequacies of classical regression methods, ML techniques are increasingly being considered (Domingues et al. 2020; Knapp et al. 2020). Multivariate adaptive regression splines (MARS) is one such technique that models interactions and non-linearities in large datasets, which are regularly encountered in remote sensing (Abdullah Al-Sudani et al. 2019) and ecology (García Nieto et al. 2019). In this technique, the model for estimating the dependent variable (like AGB) is established as a function of the most relevant biomass-sensitive variables (like forest height determined from the remotely sensed information), while the less significant and redundant ones are eliminated. MARS is well known for its performance of estimation. Investigations have reported better performance while employing MARS as compared to the other statistical approaches (Pramila and Mahesh 2015; Park et al. 2017), logistic regressions, and neural networks (Li et al. 2019). Since the early 2000s, several models have been proposed to produce AGB maps at various resolutions (ranging from 30 m to 1 km) and spatial scales: global (Chen, Peng, and Fei 2019); pan-tropical (Avitabile et al. 2016; Baccini et al. 2017); continental (Bouvet et al. 2018); regional (Baccini et al. 2008; Almeida et al. 2019b); and local (Bastin et al. 2014; Liao et al. 2019; Van Pham et al. 2019).

Over the tropical Central African nation of Gabon, Landsat Enhanced Thematic Mapper Plus (ETM+) (Goïta, Moulougou, and Goze 2017), LiDAR (Labrière et al. 2018), and radar (Cartus and Santoro 2019) or merged LiDAR-radar (Mitchard et al. 2012) data were used to predict AGB over selected sites. However, large uncertainties have been reported (Gopalakrishnan et al. 2015; Loubota Panzou et al. 2016; Li et al. 2017; Gonçalves, Malico, and Sousa 2018; Reichstein and Carvalhais 2019; Hansen, Potapov,

and Tyukavina 2019). One of the major difficulties associated with AGB retrieval in tropical forests is the scarcity of both in-situ and remote sensing data, which is partly due to the complexity of these environments, their accessibility, and the presence of persistent cloud cover, among other obstacles. This situation is particularly true over the Congo Basin, where large-scale experimental remote-sensing data are limited. The AfriSAR 2016 campaign in Gabon, jointly conducted by NASA, ESA, and AGEOS, attempted to address this gap. The campaign enabled the acquisition of airborne LiDAR and radar data along with forest measurements (available at <https://daac.ornl.gov/>). Many approaches that have been proposed for estimating AGB in tropical forests since 2017 are based upon these experimental data (El Hajj et al. 2018; Labrière et al. 2018; Saatchi et al. 2019). Nevertheless, important uncertainties remain in the estimated AGB. For example, Labrière et al. (2018), reported RMSE errors varying between 40.2 t ha^{-1} (23.3%) and 85.6 t ha^{-1} (49.7%), and bias between 9.61% and 15.9% for AGB map produced at a spatial resolution of 1 ha and 0.25 ha, respectively, in the Mondah forest (including Raponda Walker Arboretum) in Gabon. El Hajj et al. (2019), also produced such maps in Gabon at a spatial resolution of 0.25 ha using different algorithms and reported initially a RMSE of 63.3 t ha^{-1} (38.1%) with a bias of 19.1 t ha^{-1} (11.5%). The level of uncertainties still affecting AGB estimation, especially in tropical forests, motivates the development of new approaches in order to better address issues related to climate change and sustainable development (Labrière et al. 2018; Bouvet et al. 2018; Saatchi et al. 2019; El Hajj et al. 2019; Epple et al. 2016; Mulongoy and Cung 2011). These concerns serve as the main motivation for this research. Our study proposes new models for estimating AGB and indicates their effectiveness over the Congo Basin. We hypothesized that a combination of multi-source remote sensing data (like optical, LiDAR, radar etc.) will offer the best potential for predicting AGB in the complex forest environments, which is often the case over the Congo Basin. A field campaign was conducted as part of this study to collect relevant forest variables from a number of test plots. These datasets were combined with those acquired during the AfriSAR campaign for this investigation. Unlike other investigations conducted over the Congo Basin, all models that were developed in this work are based on the MARS approach. Despite its promising potential, this approach has been under-utilized for estimating tropical forest AGB (Vaglio Laurin et al. 2016). The key contribution of this paper is the development of MARS-based models to better estimate AGB, based on a combination of multi-source data. The paper is organized in the following manner: Section I: Introduction, Section II: Data and Methodology, Section III: Results, Section IV: Discussion, and Section V: Conclusion.

7.3. Materials and methods

7.3.1. Study area

The study site is located in Gabon (Congo Basin, Central Africa), which is a country covered by dense tropical rainforest. In 2010, Gabon's forests represented 88% of the country's total area i.e. 266,667 km² (Sannier, Fichet, and Massard 2014). The site chosen for this investigation is situated between 9°18'42.29" E and 9°25'53.10" E, and 0°35'19.72" N and 0°32'1.58" N and has an area of 8092 ha (Figure 7.1). The area is characterized by low elevations (up to 41 m asl), and includes mostly mature and secondary forests, forest regrowth, and floodplains including mangroves. A portion of the site is included within the Raponda Walker Arboretum Conservation Area (formerly known as Forêt de la Mondah).

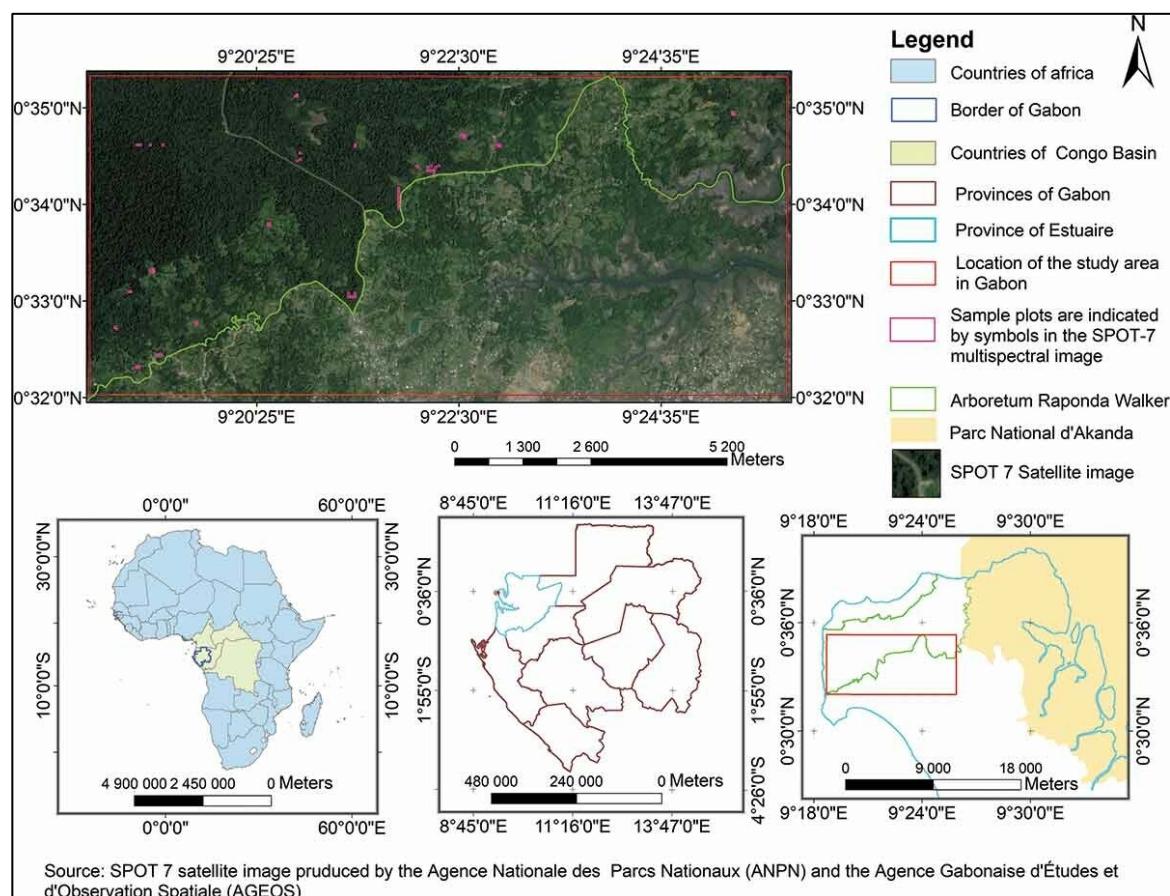


Figure 7.1. Figure 1. Location of the study area in Gabon (Central Africa). The sample plots are indicated by symbols in magenta over the SPOT-7 true color composite image.

7.3.2 Data collection

This study is based on in-situ measurements that were acquired from two different field campaigns. The first is the AfriSAR campaign in Gabon, which was conducted in 2016 as

a collaborative effort between NASA, ESA, and AGEOS (Fatoyinbo et al. 2018). This campaign included 15 one-hectare sample plots, but only 14 of them were used due to data availability. A publicly available database provides access to different measured variables, including the number of trees (N_a) per plot and their diameters at breast height (D). All trees with a diameter greater than or equal to 10 cm have been counted, and their D measurements were measured with a tape at 1.30 m above the ground. Calculated variables are also available in the database, especially modeled maximum height (H_T) and AGB. For more details on how the in-situ measurements were taken during the AfriSAR campaign, please see Fatoyinbo et al. (2018) and Labrière et al. (2018). H_T is calculated locally based upon measured diameters (Labrière et al. 2018) as equation 7.1:

$$H_T = (53.679 \times D) / (34.022 + D) \quad (7.1)$$

The standard residual error of the height in the Mondah forest is estimated around 7.4 m, i.e. about 23.2% of average maximum height in the region (Labrière et al. 2018). The AGB of individual trees that were geo-referenced in the field within each 1-ha sample plot were estimated with the equation of Chave et al. (2014) (Fatoyinbo et al. 2018):

$$AGB \text{ (en kg)} = 0.0673 \times (\rho D^2 H_T)^{0.976} \quad (7.2)$$

where ρ is wood density (g cm^{-3}), D is the diameter at breast height (cm), and H_T is the modeled maximum height (m) of the tree. The variable ρ is derived with the BIOMASS package of R, based upon tree species, genus or family (Fatoyinbo et al. 2018; Donegan et al. 2014). According to Chave et al. (2014) the standard residual error of AGB estimation using equation 2 is evaluated to 0.357 kg, i.e. 0.03% of the average AGB from 4004 sample plots. The authors reported underestimation of 20% for $AGB > 30 \text{ t ha}^{-1}$ and overestimation of 2.7% for AGB between 10 and 30 t ha^{-1} .

The second campaign was carried out in this study specifically to increase the in-situ measurements. It was undertaken over the same site as the AfriSAR campaign from December 2017 to January 2018. A total of 27 plots were randomly sampled. Each measured $30.8 \times 30.8 \text{ m}$, the size of which differed from those of the AfriSAR campaign (1-ha). Within each plot, the total number of trees (N_a) were counted. Bole (trunk) diameters (D, cm) were measured with a DBH tape at 1.3 m above the ground surface. For each tree, its scientific binomial (genus, species, and authority) and family were recorded. Height H_T and AGB were calculated, respectively, over the different plots using equations 7.1 and 7.2, similar to the AfriSAR campaign. Wood density values (ρ) of the trees were extracted from the International Center for Research in Agroforestry (ICRAF, Nairobi,

Kenya) database (<http://db.worldagroforestry.org//wd>), based upon species, genus and family of each tree. The ICRAF and the BIOMASS package of R employ the same relationship to calculate the density.

Since the plots of the AfriSAR campaign had a different size (1 ha) compared to those used during the second campaign (30.8 x 30.8 m), a grid of 30.8 x 30.8 m sample plots was superimposed on each of the 14 AfriSAR plots (100 x 100 m each). In some cases, the 30.8 x 30.8 m grids were cut or did not fully align within the 1-ha AfriSAR campaign plots. These grids were excluded from the investigation to keep only those completely located inside the AfriSAR plots, which allowed random selection of 48 plots of 30.8 x 30.8 m. In addition to this, there were 27 plots from the second campaign. Therefore, a total of 75 sample plots of 30.8 x 30.8 m were available, which were randomly distributed across the study site. These plots contained a total of 3076 trees. The mean values of the related attributes are presented in Table 7.1.

Table 7.1. Descriptive statistics for forest parameters in the 75 sample plots (30.8 m x 30.8 m, or 0.1 ha). H_T, D, AGB and Na represent respectively the modeled maximum height (m), diameter (cm), total dry aboveground biomass (t ha⁻¹) and total number of trees.

Parameter	Mean	Minimum	Maximum
H _T (m) (modeled)	15.1	8.6	24.6
D (cm) (measured)	16.82	5.95	37.17
AGB (t ha ⁻¹) (modeled)	136.49	0.24	578.96
Na (measured)	41	1	115

In addition to the in-situ measurements, this investigation employed the following remotely sensed datasets.

i) SPOT-7 New AstroSat Optical Modular Instrument (NAOMI) data: This data was acquired in 2015 and provided by l'Agence Nationale des Parcs Nationaux (ANPN) and AGEOS for research purposes. The image contains four spectral bands, including Blue band (450–525 nm), Green (530–590 nm), Red (625–695 nm), and Infrared (760 à 890 nm) at 6 m spatial resolution. In addition to this, there is a panchromatic band (450–745 nm) at 1.5 m resolution. The image is geo-referenced and corrected for unwanted radiometric effects. The four spectral bands are pan-sharpened with the help of the panchromatic band to enhance the spatial resolution to 1.5 x 1.5 m. As reported in previous studies, such a fine spatial resolution allows better characterization of texture and canopy crowns structure (Ploton et al. 2012; Migolet and Kalifa 2020).

ii) Full waveform airborne LiDAR data: This data was acquired by NASA's Land Vegetation and Ice Sensor (LVIS) during the AfriSAR campaign, with a density of 2.3 points per square meter (Labriere et al. 2018). More specifically, this study uses the median heights (RH50, in m) of the canopy extracted from the LiDAR acquisitions. Past investigation observed that RH50 was more effective than top canopy RH100 heights in estimating AGB (Labriere et al. 2018). Details on how canopy height information is derived from the AfriSAR LiDAR measurements is available in Blair and Hofton (2017).

iii) Polarimetric and interferometric SAR data (PolInSAR): This data was acquired at L-Band during the AfriSAR campaign (see details in Lavalle et al. 2018). The measurements were taken with the UAVSAR (Uninhabited Aerial Vehicle Synthetic Aperture Radar flown by Jet Propulsion Laboratory, Pasadena, CA). The radar variables considered here are the backscatter coefficient (σ^0 , in decibels dB) and the height to top of canopy (H_R , in m). Backscattering coefficient σ^0 corresponds to the normalized value of the radar return from a distributed target. It depends on several factors such as radar frequency, surface type and dielectric state, as well as sensor geometry. L-Band σ^0 has been employed by different studies to estimate forest biomass (Villard et al. 2016; Agrawal and Tolpekin 2019). Canopy height H_R was derived in the AfriSAR campaign using the Random Volume over Ground (RVoG) model applied to PolInSAR data (Lavalle et al. 2018). More information on the model and its inversion can be found in Denbina, Simard, and Hawkins (2018) and Papathanassiou and Cloude (2001). H_R is an estimation of forest height from PolInSAR that could be a relevant variable for the computation of AGB. The choice of σ^0 was dictated by its sensitivity to vegetation physical characteristics (Sinha et al. 2015; Mermoz et al. 2015; Agrawal and Tolpekin 2019; Pourshamsi et al. 2021).

7.3.3 Methodology

The methodology of the study focused on the following three components: The computation of texture indices, the development and validation of the AGB models, and the comparison of the estimated AGB with the existing AGB maps. The methodological flowchart of the study is presented in Figure 7.2.

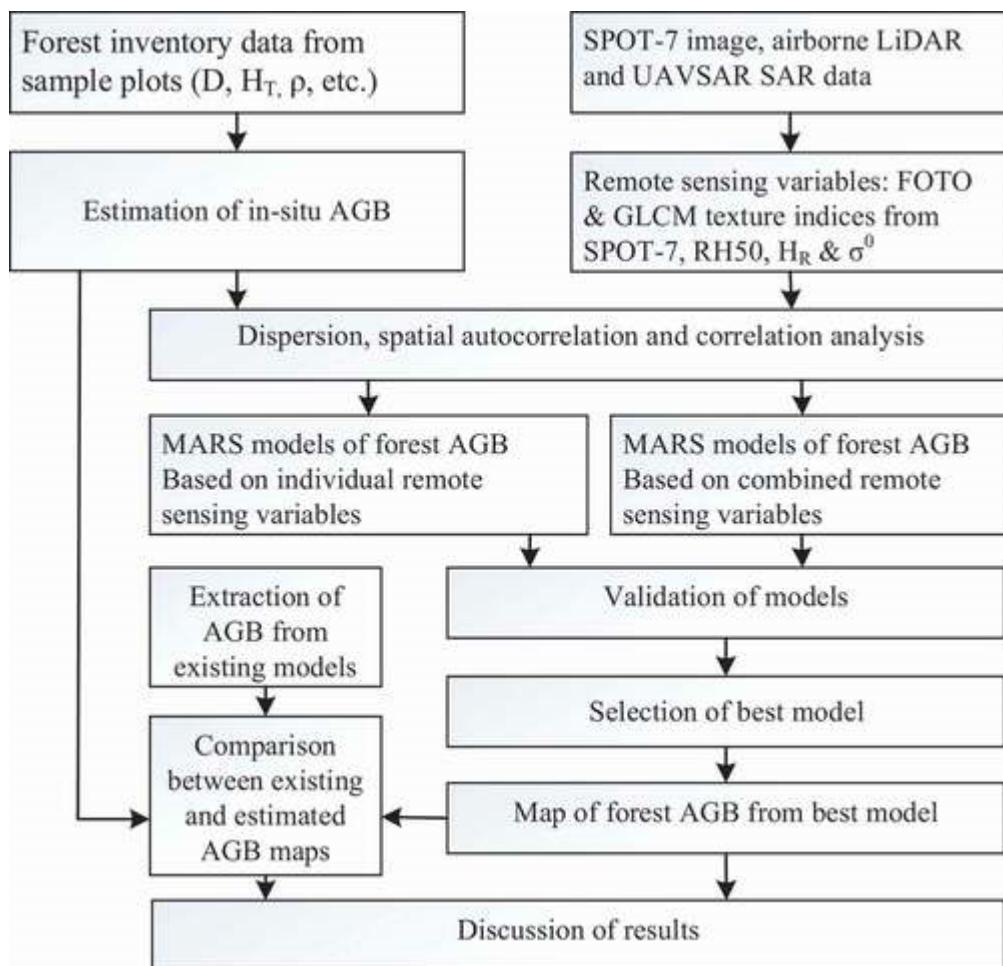


Figure 7.2. Methodological flowchart of the study

7.3.3.1 Production of texture indices

The initial step involves the computation of texture indices from the SPOT-7 pan-sharpened image at 1.5 m resolution. The choice of texture indices was determined by their resistance to saturation under high biomass conditions as compared to spectral indices (Bastin et al. 2014; Tapamo et al. 2014; Ploton et al. 2017; Chen and Wang 2020; Li, Zhou and Xu, 2021). Texture quantifies the relative arrangement of gray levels, spatial patterns, and geometric structures within the image (Haralick 1979). Its properties are exploited in a variety of image analysis and computer vision applications such as object recognition and classification. In the recent past, texture information has been employed for forest biomass estimation (e.g. Alberto et al. 2012; Kelsey and Neff 2014; Singh, Malhi, and Bhagwat 2014; Singh et al. 2015; Li, Zhou, and Wenbin 2021). It can be quantified using different statistical, frequency, and geometrical measures. In this investigation, texture parameters are derived using,

- i) A frequency approach based on the Fourier transform by textural ordination (FOTO). The FOTO approach combines two-dimensional discrete Fast-Fourier Transform (FFT-2D)

and Principal Component Analysis (PCA). Its implementation requires different steps, which have been reported by several investigations (Couteron, Barbier, and Gautier 2006; Proisy, Couteron, and Fromard 2007; Ploton et al. 2012; Barbier and Couteron 2015; Migolet and Kalifa 2020). The initial step involves converting the spectra from the spatial domain to the frequency domain by calculating a periodogram (i.e. spectral density of the signal) for each pair of spatial frequencies with Fourier coefficients. This operation is generally performed with different window sizes within the image. The mean values of the periodograms must then be calculated in all possible sliding window directions to generate an averaged radial spectrum (r-spectrum). The r-spectra synthesizes the characteristics of texture variations in terms of grain fineness, which is important for characterizing forests. Coarse grain textures are related to forests with higher heights and larger crowns, while fine grains correspond more to forests with small to medium crowns. In tropical forests, and particularly in our study area, coarse and fine texture grains characterize mature and secondary forests, respectively (Couteron, Raphael Pelissier, and Paget 2005; Couteron, Barbier, and Gautier 2006; Barbier et al. 2012; Ploton et al. 2012; Migolet and Kalifa 2020). The next step involves applying textural ordination to the r-spectrum values in order to characterize their variability, measure the dispersion between them, and reduce the dimension of the data. To realize the ordination, the r-spectrum values are integrated into a two-dimensional table, where each row corresponds to the r-spectrum of a given window and each column contains the amplitudes of the r-spectrum. The column values are then normalized and subjected to PCA. The PCA scores of the r-spectra correspond to the FOTO indices. Texture grain types are usually interpreted from the factor scores that are derived from principal components (PC) 1 and 2. Negative scores on the PC1 axis indicate coarse texture (mature forests), while positive scores are related to fine texture (secondary forest). On the other hand, PC2 explains the openness of the canopy, with negative and positive scores for closed and open canopies respectively. This ability to describe forest structures appears useful for estimating structural parameters (height and diameter) or AGB (e.g. Proisy, Couteron, and Fromard 2007; Barbier et al. 2012; Migolet and Kalifa 2020). In this investigation, the FOTO approach was applied on the pansharped SPOT-7 near-infrared band due to its high sensitivity to vegetation (Proisy, Couteron, and Fromard 2007). Unsupervised classification by K-Means clustering was applied to the image to mask all areas except those covered by forests. By considering the previous studies in forest environments (Couteron, Raphael Pelissier, and Paget 2005; Couteron, Barbier, and Gautier 2006; Proisy, Couteron, and Fromard 2007; Ploton et al. 2012; Barbier and Couteron 2015), four increasing window sizes were considered for the application of FFT-

2D, namely, 75 m, 100 m, 150 m and 175 m. The r-spectra were then generated and analyzed for the different window sizes.

ii) The gray level co-occurrence matrix (GLCM) proposed by Haralick (1979) (Coulibaly and Gwyn 2005; Alberto et al. 2012; Kelsey and Neff 2014; Moya et al. 2019; Liao, He, and Quan 2019). In addition to the FOTO approach, the GLCM technique was employed to generate the texture parameters. Six parameters were selected (Table 7.2) based on their performances reported in the previous studies on forest environments (e.g. Alberto et al. 2012; Kelsey and Neff 2014; Singh, Malhi, and Bhagwat 2014). GLCM indices can be extracted from either the red or the near infrared band. Based on past investigations, the red band was chosen over the infrared band to generate the GLCM parameters (Alberto et al. 2012; Singh, Malhi, and Bhagwat 2014; Hiatshwayo et al. 2019). The reflectance in the red band is sensitive to the absorption by the chlorophyll in plant tissues for photosynthesis (Devineau 1990; Briottet 2016). The contrast in the light absorption requirements of the different forest species probably leads to better sensitivity of texture features in forested environments. For the computation of GLCM indices, four sampling directions (0° , 45° , 90° , and 135°) and a single inter-pixel distance were adopted in order to maximize discrimination among the land cover classes (Messier, Cavayas, and Pierre 2001). Several window sizes were tested during the parameter computation. Based on the analysis of curves of the coefficients of variation, the optimal window size was chosen to be 5×5 m (Coulibaly and Gwyn 2005).

Table 7.2. GLCM texture indices that were used in the study. $P(i,j,d,\theta)$ is the probability of moving from gray-level pixel i to gray-level pixel j that are located at a distance d from one another in an orientation θ . The values μ_x and σ_x are respectively the mean and standard deviation of the rows of the co-occurrence matrix, while μ_y and σ_y define the same statistics for the columns. L corresponds to the maximum quantification level of the gray levels.

GLCM Statistical Texture Index	Meaning	Formula	Source
Mean	<i>Mean</i> measures the mean of the gray level distribution of the basic elements or patterns from which the texture is formed	$\text{Mean} = \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} i P(i,j,d,\theta)$	Coulibaly and Gwyn (2005)
Standard deviation	<i>Standard deviation</i> characterizes the gray level dispersion of the basic elements or patterns from which the texture is formed	$\text{Standard deviation} = \sqrt{\sum_{i=0}^{L-1} \sum_{j=0}^{L-1} [P(i,j,d,\theta)(i - \text{Mean})]^2}$	Coulibaly and Goïta (2006) Singh, Malhi, and Bhagwat (2014)
Homogeneity	<i>Homogeneity</i> quantifies the level of texture uniformity.	$\text{Homogeneity} = \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} P(i,j,d,\theta)/1 + (i - j)^2$	

Entropy	Entropy measures the degree of organization or disorder of the texture.	$\text{Entropy} = \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} P(i, j, d, \theta) \ln [P(i, j, d, \theta)]$	Moya <i>et al.</i> (2019)
Correlation	Measures the linear dependence of gray levels in an image	$\text{Correlation} = \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} [(i - \mu_x)(j - \mu_y)P(i, j, d, \theta)] / \sigma_x \sigma_y$	Pandit, Tsuyuki, and Dube (2020)
Contrast	Calculate the importance of local variation of gray levels within a window	$\text{Contrast} = \sum_{i=0}^{L-1} \sum_{j=1}^{L-1} (i - j)^2 P(i, j, d, \theta)$	

7.3.3.2 Model development and validation

7.3.3.2.1 Preliminary processing and analysis

The randomly selected ground samples (75 sample plots) were analyzed with respect to the remote sensing measurements (RH50, H_R, σ⁰, and texture indices from FOTO and GLCM). Total in-situ AGB for each sample plot was determined by summing the AGB value for each tree located inside the plot. Moreover, for each of the 75 plots, we calculated the average modeled maximum height H_T and the diameter at breast height D. Mean values of the remote sensing parameters considered were also calculated for each plot. Using basic allometric principles (Gould 1966; King 1996; Picard, Saint-André, and Henry 2012; Chave et al. 2014; Ngomanda et al. 2014), field-based variables were compared to remotely sensed information to analyze their relationships that supported the AGB model development process. Before developing the AGB models, a preliminary dispersion analysis on field data (H_T, D, AGB) was performed in order to have insights on their distributions. Outliers were analyzed in order to identify potential sources of field errors related to measurement records and calculations. Spatial autocorrelation analysis was performed to characterize the existing spatial relationships between the different AGB sample plots. Both global Moran's I (Moran 1950) and Anselin local Moran's I (Anselin 2010; Ou et al. 2019) statistics were employed in this investigation. Global Moran I index evaluates the global autocorrelation at fixed distance bandwidth. It indicated the spatial autocorrelation over the whole study area. Anselin local Moran Index was employed to identify the statistically significant clusters and outliers, and to describe the local spatial autocorrelation between the AGB sample plots. Typically, two potential AGB clusters (High-High (HH), Low-Low (LL)) and two potential outliers (High-Low (HL), Low-High (LH)) could be identified from the analysis. Moran's local (or Global) index values vary between -1 and +1. Positive value indicates a strong correlation and a significant clustered pattern over the AGB sample plots. A negative index shows negative correlation between neighboring AGB and a grouping of dissimilar values. Index value near or equal to zero indicates an absence of correlation and clustering. In this study, P-value (statistical

significance at 95% confidence level) were used to interpret the calculated spatial statistics and determine the presence or absence of autocorrelation in the AGB sample plots data (Bouayad Agha and Bellefon, 2018; Baloloy et al. 2018; Ou et al. 2019). As in the work of Ou et al. (2019), the spatial autocorrelation was analyzed using different distance bandwidths. Here, the minimum, mean, and the maximum distances between neighboring sample plots were 28 m, 4073 m and 12,515 m, respectively. A bandwidth of 12,000 m was fixed initially for local autocorrelation analysis.

7.3.3.2.2 AGB models development and validation

Following the autocorrelation analysis, 62 out of the 75 available sample plots were used in the development and validation of the AGB models. Among these, 45 plots were randomly selected to train the models. Different statistical metrics (correlation, P-value, etc.) were used to analyze the strength of the modeled relationship. The remaining 17 plots were used to validate the models and compare the estimated AGBs with the existing AGB maps. The data values of these sample plots are presented in Appendices 7.1 and 7.2.

Models linking ground-based AGB to remotely sensed variables were established with the MARS algorithm (Friedman 1991). The choice of this approach is based on the fact that it considers the non-linearities and multi-dimensionality, while remaining simple in terms of its formulation and interpretation. In order to achieve this, MARS employs a sum of basis functions, the general form of which is given as follows (e.g. López-Serrano et al. 2016):

$$f(x) = \beta_0 + \sum_{m=1}^M \beta_m K_m(x) \quad (7.3)$$

where β_0 is the model constant, $K_m(x)$ is one of the basis functions, B_m is one of the coefficients of the basis function, and M is the number of basis functions in the model. Using the lowest value of the Generalized Cross Validation Criterion (GCV), MARS excludes the less significant and redundant basis functions to produce the final model. GCV can be calculated, according to López-Serrano et al. (2016) as follows:

$$GCV(M) = \frac{\sum_{i=1}^n (y_i - f_M(x_i))^2}{n_1(1 - \frac{P_M}{n_1})^2} \quad (7.4)$$

where y_i are the observed values of the independent variable, n_1 is the number of observations, $f_M(x_i)$ is the MARS model with basis functions M , x are the observed values of the predictors that are included in the MARS model, and P_M is the number of parameters in the MARS model. In this research, several well-known statistical metrics are used to evaluate and validate the models that were developed. These include the coefficient of determination (R^2), the P -value, root-mean-square error (RMSE) and relative error (RE).

More details on these metrics can be found in Ngomanda et al. (2014), Yang et al. 2017 and Migolet et al. 2020.

7.4. Results

The major results are summarized in this section, which includes the development of models based on the MARS approach and their validation. Even if the various texture indices were used during the process of developing the AGB models, only FOTO indices are explicitly explained here for the sake of brevity. Since the GLCM parameters are well-known in the literature, they are not presented. Furthermore, the results of the comparison between the best model developed here and the existing AGB maps are not shown, but are discussed in Section IV.

7.4.1 Characterization of FOTO indices

The r-spectra for each of the five analysis windows (75, 100, 125, 150, and 175 m) were generated following the application of the FOTO method (Section 7.2.3.1). The values were initially highest with the smallest window, and they decreased progressively with increasing window size, particularly for wave number less than 4 (Figure 7.3 (a)), and for spatial frequencies lower than 30 km^{-1} cycles (Figure 7.3 (b)). The highest proportion of explained variance (86%) was obtained with the 175 m window size (Figure 7.3 (c)), which captures more information in the r-spectra. Scatter analysis of the PC1 and PC2 scores from PCA of the r-spectra allowed four types of forest textures to be distinguished for each window size (Figure 7.4). The 175 m window size displays the greatest dispersion, starting from the origin of the orthogonal plane, which meant greater discrimination between textures (Figure 7.4 (e)). Thus, the 175 m window size was chosen, considering the best-explained variance proportion that it achieved and the dispersion of its PCA scores. Figure 7.5 illustrates the different texture types of the study area generated at the 175 m window size. Red represents a fine and closed texture. This texture is more consistent with the young-adult or floodable secondary forests (according to the field observations). Green indicates coarse and open texture, which corresponds best to the mature forests. Blue highlights coarse and closed texture, *i.e.* the old-growth secondary forests. Yellow indicates fine and open texture, which is associated with mature and secondary young-adult or floodable forests over the study area. A closed texture indicates the absence of gaps in the forest stand, which is not the case with open texture. This presence or absence of gaps in the canopy also indicates the existence or nonexistence of AGB on the ground. The closed or open texture is an indicator of the continuous presence or absence of AGB.

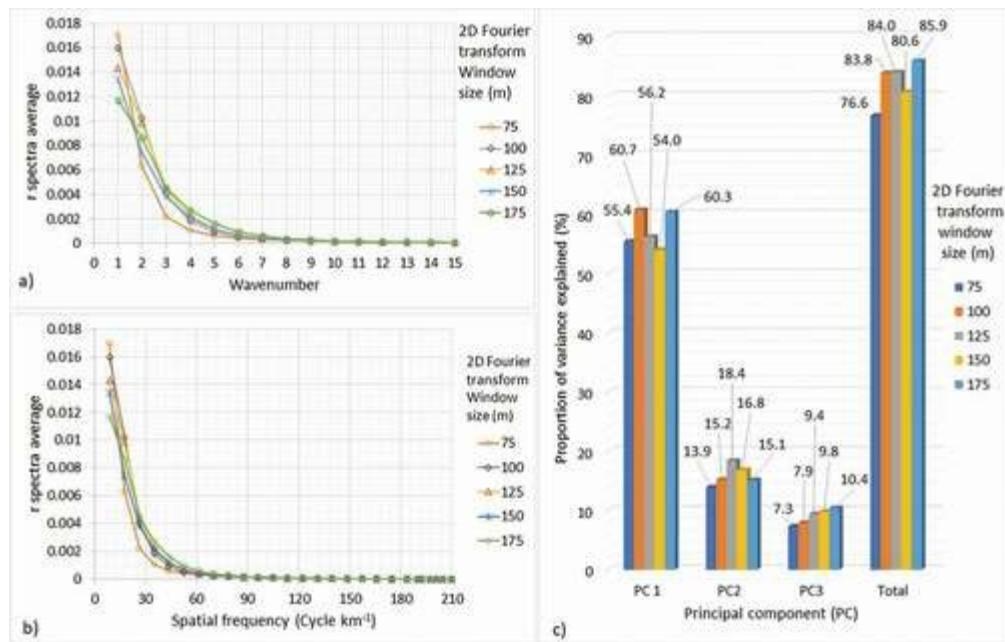


Figure 7.3. Relationship between the r-spectra of the 2D Fourier transform with the wave numbers by (a) window size, (b) spatial frequencies, and (c) proportions of variance explained from the principal component analysis of the r-spectra.

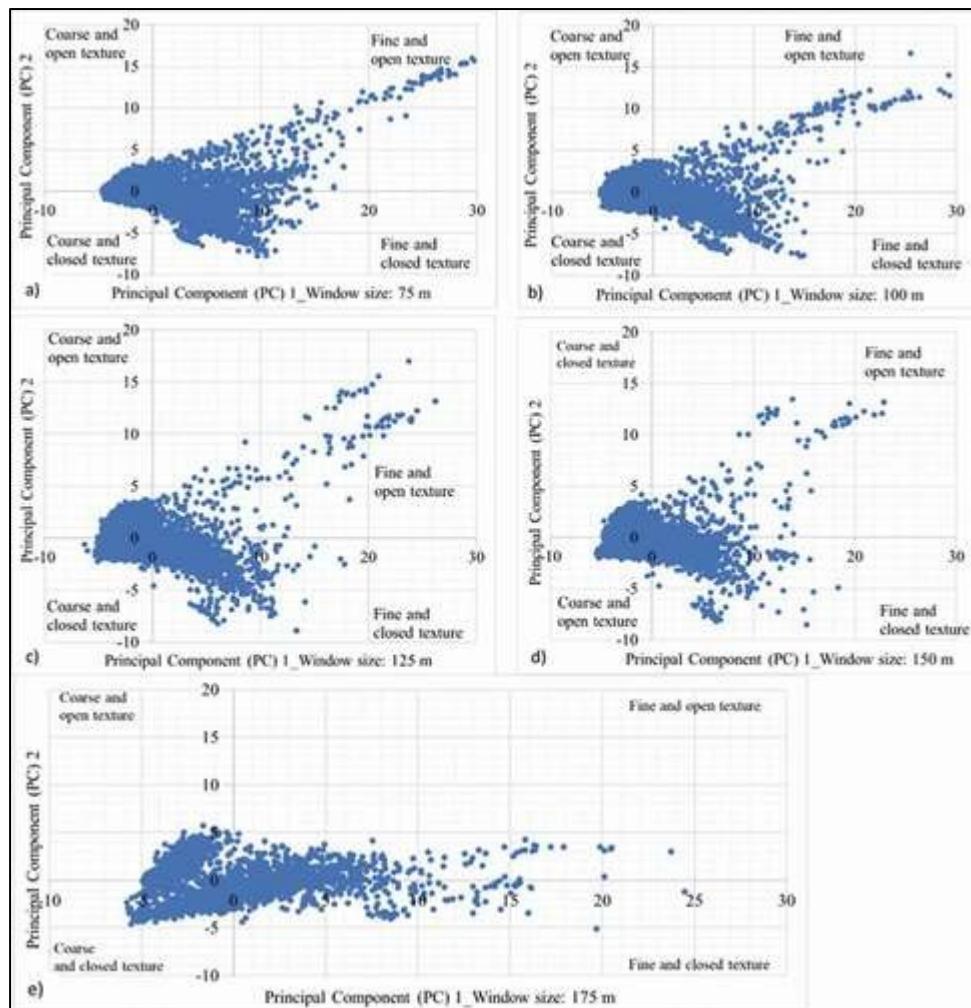


Figure 7.3. Distribution of texture types in the study area according to PC1 and PC2 scores of the r-spectra for the different window sizes: (a) 75 m, (b) 100 m, (c) 125 m, (d) 150 m, and (e) 175 m.

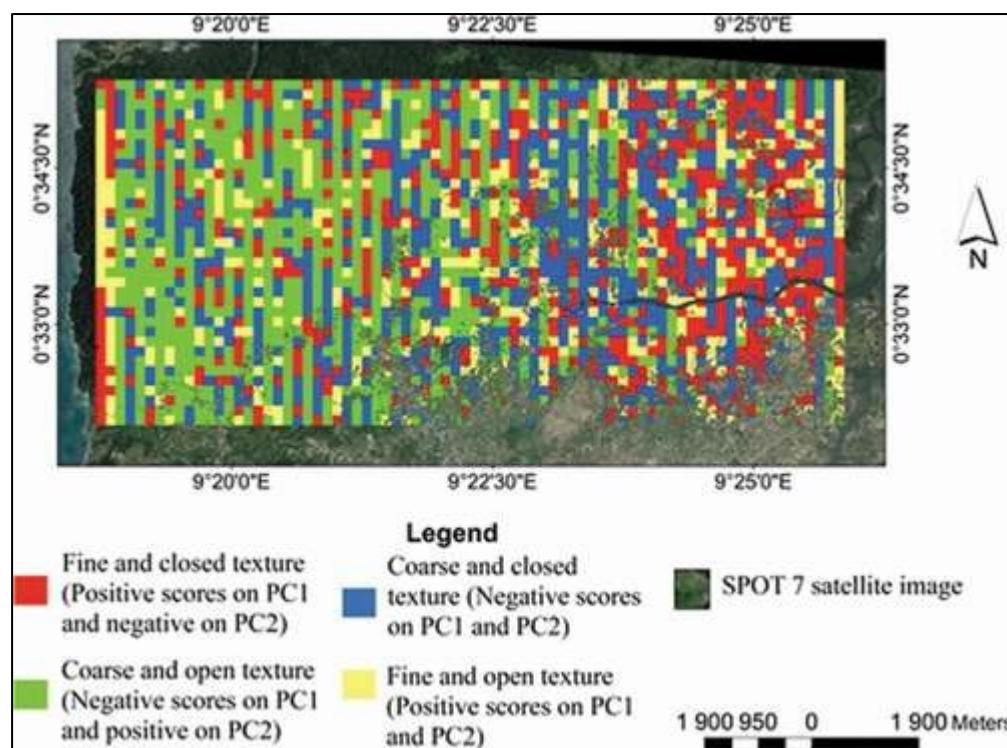


Figure 7.4. Textural variation over the study area.

7.4.2 MARS-based AGB models

7.4.2.1 Autocorrelation analysis of AGB sample plots

Figure 7.6 illustrates the results of autocorrelation according to Anselin local Moran's index. The quantitative results are indicated in Table 7.3, including P-values (P). Around 2/3rd (61.3%), i.e. 46 of the 75 AGB sample plots indicated no spatial autocorrelation ($P > 0.05$). The results also show two significant clusters (P between 0.002 and 0.05), including a LL cluster (28% of the data) and HH cluster (about 9% of the data). One main LH outlier group is also found in the data with 21 AGB sample plots (P between 0.002 and 0.05). The results of the global Moran I index (shown in Table 7.4) indicates a global positive spatial autocorrelation of AGB data over the study area. In order to ensure that the autocorrelations are not sensitive to the approach used to derive sample plots from AfriSAR, we conducted the same analysis over the original AfriSAR campaign plots. Both Anselin local Moran I and global Moran I were calculated and analyzed. According to the results (Figure 7.7, Table 7.4), 66.7% of the original AfriSAR AGB sample plots indicated no autocorrelation. However, two clusters were observed that included a HH cluster containing 8.3% of the data and a LL cluster with 25% of the plots. As in our case, the global Moran I indicated a positive global autocorrelation over the study area. In summary, the spatial autocorrelations in the original AfriSAR AGB data is quite similar to the ones observed over the 75 sample plots used in this study. There is no spatial autocorrelation in the

majority of the data considered. Accordingly, we used them in conjunction with the remotely sensed data to develop and validate the AGB models.

Table 7.3. Statistics of spatial over 75 AGB sample plots of the study using Anselin local Moran I and global Moran I. P is P-value. NS indicates samples with no autocorrelation. HH is for High-High cluster, LL is for Low-Low cluster, LH and HL are respectively Low-High and High-Low outliers.

Cluster type	NS	LL	HH	LH	HL	Summary	
						Anselin local	Global
Number of sample plots	46	21	7	1	0	75	75
Pourcentage (%)	61.33	28.00	9.33	1.33	0	100	100
P-value range	0.052 -0.49	0.002- 0.05	0.002-0.034	0.04	-	0.002-0.49	0.0001

Table 7.4. Statistics of spatial autocorrelation in the sample plots extracted from AfriSAR field campaign using Anselin local Moran I and global Moran I. NS indicates samples with no autocorrelation. HH is for High-High cluster, LL is for Low-Low cluster, LH and HL are respectively Low-High and High-Low outliers.

Cluster type	NS	LL	HH	LH	HL	Summary	
						Anselin local	Global
Number of sample plots	32	12	4	0	0	48	48
Pourcentage (%)	66.67	25.00	8.33	0	0	100	100
P-value range	0.054-0.49	0.002-0.046	0.004-0.046	-	-	0.002-0.49	0.0000

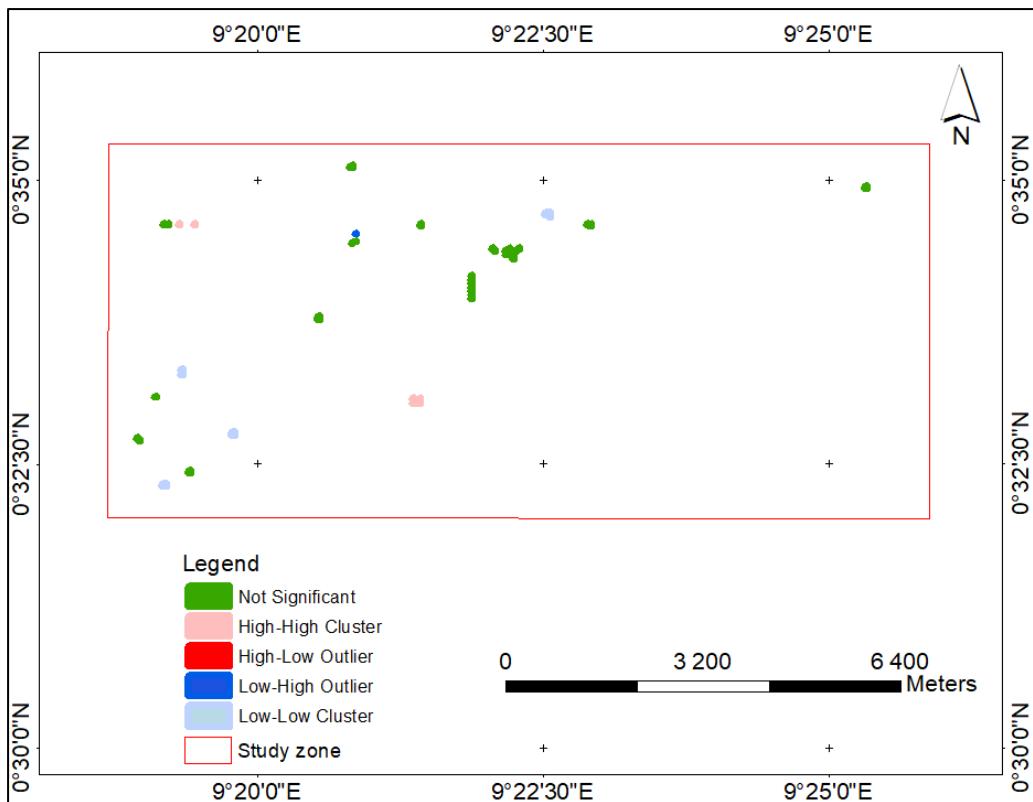


Figure 7.5. Spatial distribution of clusters based on Anselin local Moran I for the 75 AGB sample plots in the study

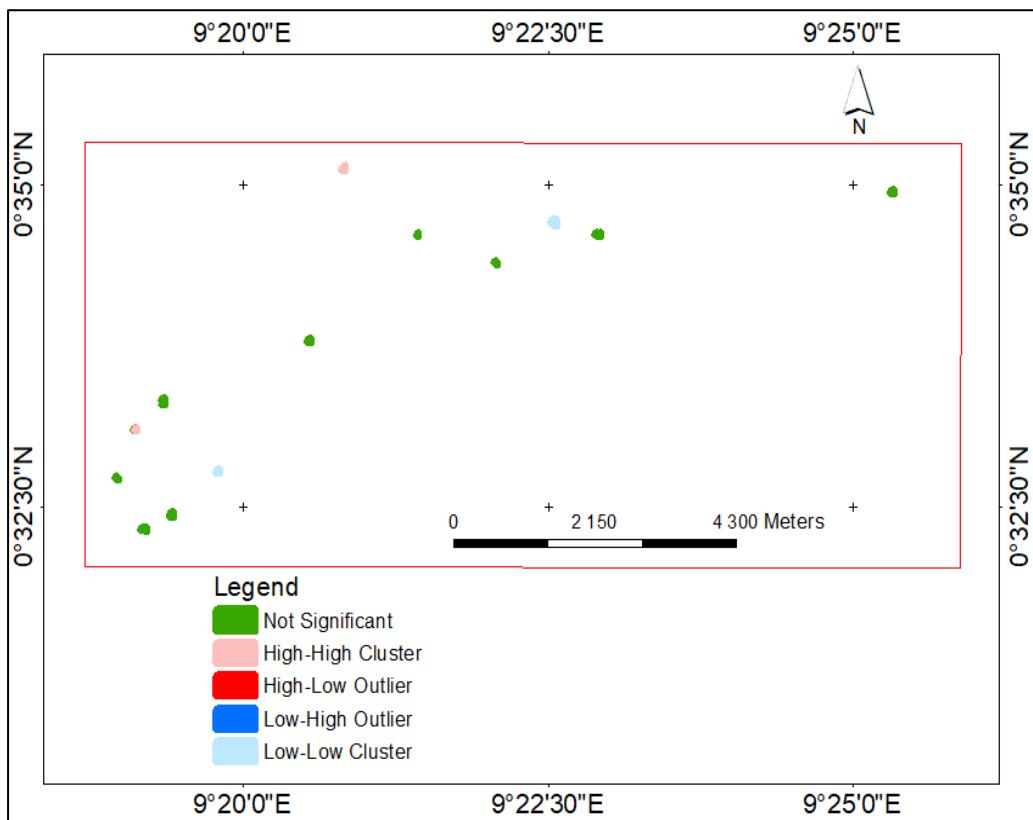


Figure 7.6. Spatial distribution of clusters based on Anselin local Moran I for the original AGB sample plots of AfriSAR field campaign

7.4.2.2 Developed AGB models

Before the development of the AGB models, the correlations and P-values at 95% confidence level were first computed between the different variables under study (Table 7.5). This analysis identified the remote sensing variables that could contribute the most to the AGB estimates, as well as highlighting co-linearities among predictors. AGB is significantly correlated with RH50 height of LiDAR ($R^2 = 0.77$, $P < 0.0001$) to a larger degree than to any other remotely sensed variables. The importance of the FOTO analysis was also demonstrated; after RH50 of the LiDAR, the FOTO PC2 index is the second most strongly correlated variable with AGB ($R^2 = 0.54$, $P < 0.0001$). The two indicators from the L-Band PolInSAR dataset (σ^0 and H_R) follow, with similar R^2 ranging between 0.45 and 0.47. Overall, the GLCM texture indices exhibited weaker correlations with AGB (the four most significant are shown in Table 7.5). Therefore, for the rest of the study, we retained only two GLCM indices, *i.e.* the mean and the contrast, which indicated correlations of $R^2 = 0.22$ and 0.13 with AGB respectively. Appendix 7.3 presents the scatter plots of the relationships between AGB and the different biomass-sensitive variables considered for this investigation (RH50, FOTO PC2 index, σ^0 , and GLCM mean texture index).

AGB models were developed following the correlation analysis summarized in Table 7.5 and Appendix 7.3. The models with the highest estimation performance are tabulated in Table 7.6. They are classified into two categories. The first category presents the set of seven models that were developed using the individual or combined variables from either the SPOT-7 optical image, or from radar, or LiDAR. The second category contains the seven models developed by combining the variables from the different sources of remotely sensed data.

Table 7.5. Correlations between total dry aboveground biomass (AGB) and its explanatory variables of the 45 training sample plots of the study.

PC1_175 m, PC2_175 m and PC3_175 m correspond respectively to principal components 1, 2 and 3 of the Fourier transform by textural ordination (FOTO) of the SPOT-7 near-infrared spectral band for the 175 m window size.

Variable	PC1 175 m		PC2 175 m		PC3 175 m		H _R		σ ⁰		RH50		Mean		Entropy		Correlation		Contrast	
	R ²	P	R ²	P	R ²	P	R ²	P	R ²	P	R ²	P	R ²	P	R ²	P	R ²	P	R ²	P
PC1_175 m	1	-																		
PC2_175 m	0.095	0.040	1	-																
PC3_175 m	0.052	0.131	0.172	0.005	1	-														
H _R	0.032	0.240	0.578	<0.0001	0.089	0.046	1	-												
σ ⁰	0.049	0.144	0.368	<0.0001	0.074	0.070	0.315	<0.0001	1	-										
RH50	0.020	0.350	0.537	<0.0001	0.075	0.069	0.528	<0.0001	0.339	<0.0001	1	-								
Mean	0.085	0.052	0.251	0.0005	0.012	0.476	0.385	<0.0001	0.458	<0.0001	0.193	0.003	1	-						
Entropy	0.055	0.120	0.143	0.010	0.003	0.718	0.174	0.004	0.208	0.002	0.041	0.181	0.597	<0.0001	1	-				
Correlation	0.019	0.367	0.083	0.054	0.0002	0.920	0.119	0.020	0.261	0.0003	0.094	0.040	0.693	<0.0001	0.550	<0.0001	1	-		
Contrast	0.010	0.520	0.073	0.073	0.002	0.797	0.111	0.025	0.159	0.007	0.190	0.003	0.338	<0.0001	0.069	0.082	0.558	<0.0001	1	-
H _T	0.002	0.765	0.531	<0.0001	0.073	0.073	0.628	<0.0001	0.394	<0.0001	0.688	<0.0001	0.241	0.001	0.078	0.063	0.084	0.053	0.126	0.017
D	0.015	0.419	0.649	<0.0001	0.079	0.061	0.683	<0.0001	0.382	<0.0001	0.785	<0.0001	0.220	0.001	0.078	0.064	0.075	0.070	0.106	0.029
AGB	0.009	0.541	0.538	<0.0001	0.077	0.065	0.471	<0.0001	0.448	<0.0001	0.772	<0.0001	0.220	0.001	0.101	0.034	0.116	0.022	0.126	0.017

Table 7.6. Models developed based on MARS approach

MARS Model	Description of models
Equations using variables from the same category of remotely sensed data	
$\begin{aligned} \text{Model 1 : } AGB &= 26.57 + 142.04 \times \max(0; \text{Contrast} - 5.59) \\ &\quad + 55.80 \times \max(0; 5.59 - \text{Contrast}) \\ &\quad - 122.14 \times \max(0; \text{Contrast} - 6.35) \end{aligned}$	Equation developed from the GLCM contrast texture index
$\begin{aligned} \text{Model 2 : } AGB &= 134.71 - 38.68 \times \max(0; \text{Mean} - 12.11) \\ &\quad + 7.70 \times \max(0; 12.11 - \text{Mean}) + 5.64 \times \max(0; \text{Mean} - 7.08) \end{aligned}$	Equation developed from the GLCM mean texture index
$\begin{aligned} \text{Model 3 : } AGB &= 26.33 + 74.08 \times \max(0; \sigma^0 + 14.44) \\ &\quad - 5.66 \times \max(0; -14.44 - \sigma^0) + 41.66 \times \max(0; \sigma^0 + 12.67) \\ &\quad - 29.84 \times \max(0; \sigma^0 + 13.21) \end{aligned}$	Equation based only on PolInSAR backscatter coefficient (σ^0)
$\begin{aligned} \text{Model 4 : } AGB &= 197.13 + 50.80 \times \max(0; H_R - 26.18) \\ &\quad - 11.01 \times \max(0; 26.18 - H_R) - 36.23 \times \max(0; H_R - 23.80) \end{aligned}$	Equation using PolInSAR canopy height (H_R)
$\begin{aligned} \text{Model 5 : } AGB &= 45.49 + 32.81 \times \max(0; PC2 + 0.87) \\ &\quad + 7.01 \times \max(0; PC2 + 0.87) \times \max(0; PC1 + 4.01) \\ &\quad + 98.65 \times \max(0; PC2 + 0.87) \times \max(0; PC3 - 0.12) \\ &\quad + 27.19 \times \max(0; PC2 + 0.87) \times \max(0; 0.12 - PC3) \\ &\quad - 125.81 \times \max(0; PC3 - 0.12) - 101.56 \times \max(0; 0.12 - PC3) \end{aligned}$	Equation using only FOTO indices (PC1, PC2 and PC3)
$\begin{aligned} \text{Model 6 : } AGB &= 74.19 + 27.52 \times \max(0; H_R - 26.19) - 5.29 \times \max(0; 26.18 - H_R) \\ &\quad + 17.02 \times \max(0; \sigma^0 + 12.67) + 5.85 \times \max(0; -12.67 - \sigma^0) \\ &\quad - 16.54 \times \max(0; H_R - 23.90) + 44.45 \times \max(0; \sigma^0 + 14.44) \end{aligned}$	Equation combining PolInSAR variables (σ^0 and H_R)
$\begin{aligned} \text{Model 7 : } AGB &= 143.64 + 3.55 \times \max(0; RH50 - 14.40) \\ &\quad - 8.76 \times \max(0; 14.40 - RH50) + 5.94 \times \max(0; RH50 - 10.44) \end{aligned}$	Equation considering only median height (RH50) derived from LiDAR data
Equations combining variables from two different categories of remotely sensed data	
$\begin{aligned} \text{Model 8 : } AGB &= -21.95 + 99.17 \times \max(0; PC2 + 0.87) \\ &\quad - 20.51 \times \max(0; \text{Mean} - 12.11) \times \max(0; PC2 + 0.87) \\ &\quad - 11.36 \times \max(0; 12.11 - \text{Mean}) \times \max(0; PC2 + 0.87) \\ &\quad + 2.73 \times \max(0; \text{Mean} - 9.80) \\ &\quad + 33.78 \times \max(0; 9.80 - \text{Mean}) \end{aligned}$	Equation integrating FOTO and GLCM indices
$\begin{aligned} \text{Model 9 : } AGB &= 132.22 + 4.98 \times \max(0; H_R - 26.18) \\ &\quad - 4.09 \times \max(0; 26.18 - H_R) + 63.62 \times \max(0; \sigma^0 + 12.67) \\ &\quad - 25.99 \times \max(0; -12.67 - \sigma^0) \\ &\quad + 4.02 \times \max(0; \text{Mean} - 7.71) \times \max(0; H_R - 26.18) \\ &\quad - 2.84 \times \max(0; 7.71 - \text{Mean}) \times \max(0; H_R - 26.18) \end{aligned}$	Equation combining σ^0 , H_R and the GLCM indices
$\begin{aligned} \text{Model 10 : } AGB &= 5.28 + 20.84 \times \max(0; PC2 - 0.87) + 50.04 \times \max(0; \sigma^0 + 14.44) - 4.14 \times \max(0; -14.44 - \sigma^0) - 2.11 \times \max(0; H_R - 26.18) \times \max(0; PC2 + 0.87) - 1.34 \times \max(0; 26.18 - H_R) \times \max(0; PC2 + 0.87) + 5.37 \times \max(0; H_R - 26.18) \times \max(0; \sigma^0 + 12.21) \times \max(0; PC2 + 0.87) + 9.67 \times \max(0; H_R - 26.18) \times \max(0; -12.21 - \sigma^0) \times \max(0; PC2 + 0.87) \end{aligned}$	Equation combining σ^0 , H_R and the FOTO indices
$\begin{aligned} \text{Model 11 : } AGB &= 135.41 + 10.81 \times \max(0; RH50 - 14.40) \\ &\quad - 9.25 \times \max(0; 14.40 - RH50) \\ &\quad + 16.26 \times \max(0; \text{Mean} - 7.08) \\ &\quad + 29.29 \times \max(0; 7.08 - \text{Mean}) \\ &\quad - 12.05 \times \max(0; \text{Contrast} - 6.35) \\ &\quad - 4.05 \times \max(0; 6.35 - \text{Contrast}) - 22.30 \times \max(0; \text{Mean} - 9.80) \end{aligned}$	Equation combining the variable RH50 and the GLCM texture indices

<i>Model 12 : AGB = 128.67 + 9.22 × max(0; RH50 – 14.40)</i> – 6.42 × max(0; 14.40 – RH50) + 51.06 × max(σ^0 + 12.67) – 12.43 × max(0; –12.67 – σ^0)	Equation associating the combined variables RH50 and σ^0
<i>Model 13 : AGB = 103.76 + 6.56 × max(0; RH50 – 14.40)</i> – 8.25 × max(0; 14.40 – RH50) + 45.50 × max(0; PC3 + 0.22) + 104.92 × max(0; –0.22 – PC3) + 181.86 × max(0; PC3 – 0.33) + 9.29 × max(0; PC2 + 0.87) – 115.49 × max(0; PC3 – 0.12) + 2.24 × max(0; RH50 – 7.41)	Equation taking into account both RH50 and FOTO indices
<i>Model 14 : AGB = 119.26 + 8.51 × max(0; RH50 – 14.40)</i> – 5.67 × max(0; 14.40 – RH50) + 54.57 × max(0; σ^0 + 12.67) – 6.60 × max(0; –12.67 – σ^0) + 7.59 × max(0; PC2 + 0.87) – 4.88 × max(0; Mean – 12.11) – 2.71 × max(0; 12.11 – Mean)	Equation combining all variables (RH50, σ^0 and the FOTO and GLCM indices)

The statistical metrics associated with each model are summarized in Table 7.7 Models (1 and 2) using only the individual GLCM texture indices (contrast or mean) yielded the lowest, albeit significant, results. The errors associated with these models are very large (RMSE > 84%). The use of the individual variables extracted from the radar data (σ^0 and H_R) in Models 3 and 4 yielded improved results compared to those of the texture indices. Nevertheless, the errors on AGB remained large (R^2 : 0.47 to 0.51; RMSE: 69% to 72%). Model 5 combined the FOTO indices (PC1, PC2, and PC3), and Model 6 was based upon the radar variables σ^0 and H_R . The two models yielded comparable performances (R^2 : 0.60 to 0.64; RMSE: 60% to 63%). The results thus obtained surpassed those of the aforementioned single-variable models, but the errors were still high. Model 7 was developed using only the RH50 height of the airborne LiDAR. It produced significantly better results than Models 1 to 6, which were based upon either the optical image or PolInSAR data (R^2 = 0.77; RMSE = 47%).

Table 7.7. Model performance metrics. R^2 is the coefficient of determination; RMSE (in t ha⁻¹) is the root-mean-square error, and RMSE (%)

MARS Model	R^2	P	RMSE	percent RMSE
<i>Model 1</i>	0.19	0.003	121.95	89.33
<i>Model 2</i>	0.28	0.0002	114.93	84.19
<i>Model 3</i>	0.47	< 0.0001	98.25	71.97
<i>Model 4</i>	0.51	< 0.0001	94.72	69.38
<i>Model 5</i>	0.60	< 0.0001	85.93	62.95
<i>Model 6</i>	0.64	< 0.0001	81.20	59.48
<i>Model 7</i>	0.77	< 0.0001	64.29	47.09
<i>Model 8</i>	0.67	< 0.0001	77.35	56.66

<i>Model 9</i>	0.76	< 0.0001	66.86	48.97
<i>Model 10</i>	0.77	< 0.0001	65.54	48.01
<i>Model 11</i>	0.82	< 0.0001	57.72	42.28
<i>Model 12</i>	0.83	< 0.0001	56.20	41.17
<i>Model 13</i>	0.83	< 0.0001	55.85	40.91
<i>Model 14</i>	0.83	< 0.0001	55.04	40.32

Regardless of the combinations used, optical data alone always produced substantial errors. The best model that was based solely on the optical image is Model 8, which combined FOTO PC2 and PC3 indices with the GLCM mean texture index ($R^2 = 0.67$; RMSE = 57%). The results are greatly improved when the radar indices (σ^0 and H_R) are combined with either the GLCM texture indices (Model 9) or the FOTO indices (Model 10). These two models yielded the same error levels ($R^2 \sim 0.76$; RMSE $\sim 49\%$), which is comparable to the error produced by the RH50-based Model 7. Finally, our results indicated that the introduction of LiDAR RH50 into any combination produced the best results, regardless of the combination considered, *i.e.* with GLCM parameters (Model 11), FOTO indices (Model 13), PolInSAR (Model 12), or with a combination of optical and PolInSAR data (Model 14). These four models (11 to 14) were the most efficient ones. They yielded almost similar metrics (R^2 : 0.82 to 0.83; RMSE: 40 to 43%).

7.4.3. Biomass model validation

In order to validate the AGB models, the estimated values were compared to the AGBs of the independent sample plots set aside for validation purposes. The results reported in Table 7.8 confirmed that models based solely on the GLCM texture indices (Models 1 and 2) produced large errors (RMSE > 59%). Model 3 and 4, which are based on the radar indices σ^0 and H_R respectively, yielded significantly better results, with much lower errors than those observed during the development phase (RMSE = 50 to 53%). Moreover, the combination of the two variables (σ^0 and H_R) in the same equation (Model 6) reduced the error by more than 10% compared to Models 3 and 4. Model 5, based solely on FOTO indices, yielded higher errors during the validation process (RMSE about 74% versus 63% in the training). Overall, the validation phase confirmed that the best single-variable model for estimating AGB is Model 7, which employed the RH50 of LiDAR ($R^2 = 0.84$; RMSE = 28%).

Table 7.8. Validation performance metrics of the AGB models

MARS Model	R^2	P	RE	percent RE	RMSE	percent RMSE
Model 1	0.04	0.44	0.93	93.80	134.95	82.81
Model 2	0.26	0.04	0.49	49.46	96.86	59.43
Model 3	0.42	0.005	0.83	83.24	86.70	53.20
Model 4	0.47	0.002	0.71	71.11	82.21	50.45
Model 5	0.12	0.17	2.06	206.98	120.42	73.89
Model 6	0.69	< 0.0001	0.61	61.81	64.81	39.77
Model 7	0.84	< 0.0001	0.39	39.12	45.23	27.76
Model 8	0.38	0.009	0.75	75.29	92.94	57.03
Model 9	0.44	0.004	0.19	19.12	88.89	54.54
Model 10	0.59	0.0003	0.65	65.18	87.64	53.77
Model 11	0.86	<0.0001	0.34	34.78	52.61	32.28
Model 12	0.90	<0.0001	0.40	40.94	39.22	24.07
Model 13	0.88	<0.0001	0.44	44.32	39.39	24.17
Model 14	0.89	< 0.0001	-0.09	-9.08	38.62	23.70

Examination of the results of variable associations (Table 7.8) revealed that the combination of texture indices derived solely from the optical image (FOTO and GLCM indices) in the same equation did not improve the AGB estimates (Model 8). However, a complementarity was observed between optical and PolInSAR data. The results improved significantly when radar indices were combined with GLCM texture indices or with FOTO indices (Models 9 and 10: $R^2 = 0.44$ to 0.59 ; $P \leq 0.004$; RMSE = 55% to 54%). This improvement was also observed during the development phase. Finally, the validation result in Table 7.8 indicate that any combination involving the LiDAR variable RH50 (Models 11 to 14) allowed for a better retrieval of the AGB. This is particularly noticeable for the combination of RH50 and radar indices (Model 12: $R^2 = 0.90$; RMSE = 24.1%), the FOTO indices of the optical image (Model 13: $R^2 = 0.88$; RMSE = 24.2%), and the combination of RH50 with all other variables (Model 14: $R^2 = 0.89$; RMSE = 23.7%). The combinations employing the FOTO texture indices (Models 10 and 13) gave better results than those integrating the GLCM indices (Models 9 and 11). The scatterplots of the observed and the estimated AGBs with the four models are presented in Appendix 7.4. The results from Models 12 and 13 are quite close to those of Model 14.

Considering both training and validation phases, Model 14 emerged as the most successful predictor of AGB in this investigation. This model was employed to produce AGB maps at a spatial resolution of 30.8×30.8 m as can be observed in Figure 7.8. AGB is shown in four-color ranges (Figure 8 (a)), while the locations of the sample plots are illustrated on SPOT-7 true color composite image (Figure 7.8 (b)). The maximum estimated

AGB values in the area attained values as high as 585 t ha^{-1} . Areas with the highest AGB values ($\geq 240 \text{ t ha}^{-1}$) are more prevalent in the northwest and north-central part of the study site (dark-green color, Figure 7.8 (a)). They correspond to areas covered mostly by mature forests that are under conservation and are included in the Raponda Walker Arboretum. In the same areas, there are old secondary forests with biomass values between 146 and 240 t ha^{-1} (medium-light green color, Figure 7.8 (a)). Young-adult or floodplain secondary forests (medium-dark green color, Figure 7.8 (a)) are scattered over much of the area, with biomass values ranging from 52 to 146 t ha^{-1} . Finally, the lowest AGB ($< 52 \text{ t ha}^{-1}$) coincided with bare soils or forest regrowth (light-yellow color, Figure 7.8 (a)). These areas are generally concentrated outside the conservation zone to the south, east, and northeast.

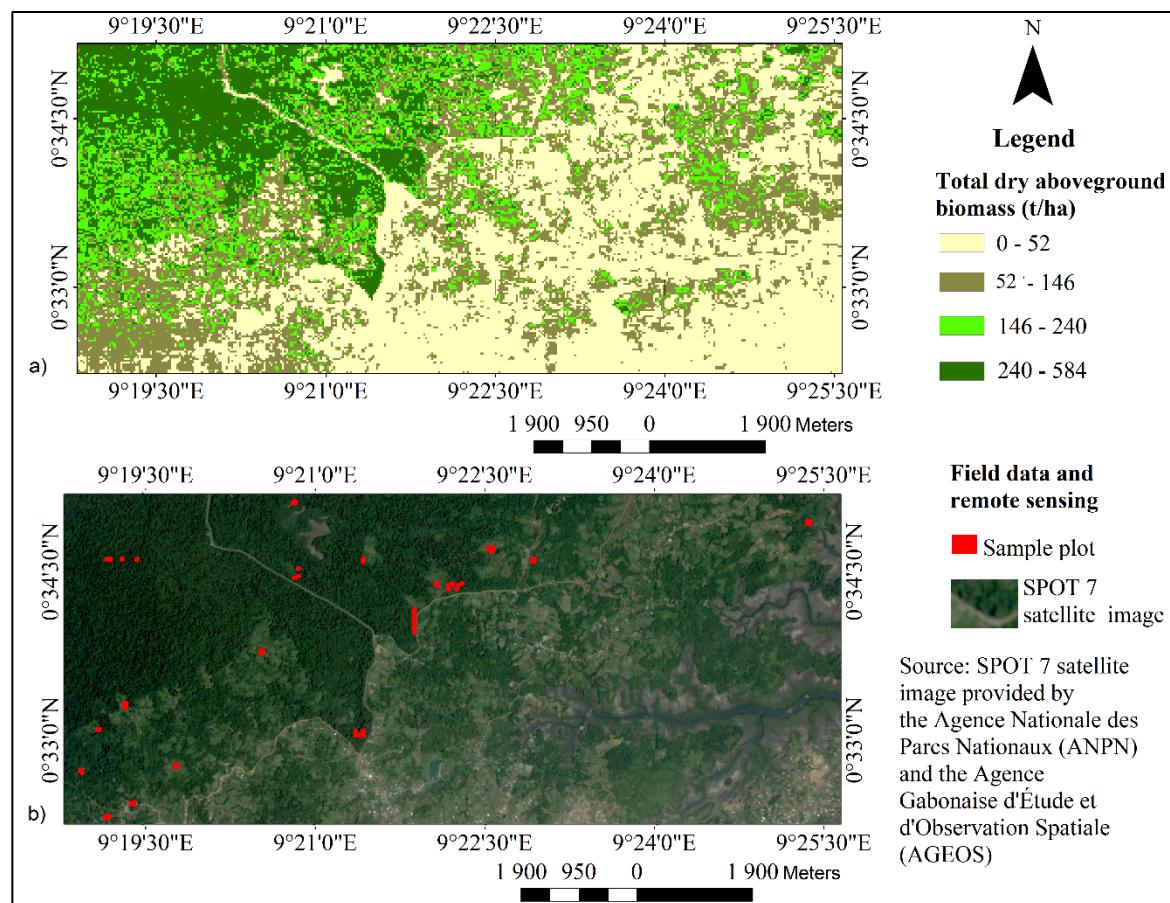


Figure 7.7. (a) Map of total dry aboveground forest biomass (b) SPOT-7 pan-sharpened color-composite of the study area

7.5. Discussion

This investigation combined a set of new and past datasets (from the AfriSAR campaign) acquired over the tropical forests (both in-situ and various remote sensing measurements) in the Congo Basin. The MARS-based methodology proposed in this work

demonstrates the potential to combine multi-source remotely sensed variables to improve the AGB estimation. The study also explored combinations of different derived information like texture (FOTO and GLCM indices), forest height, and radar backscattering coefficients. The overall statistics indicated that the AGB estimation error remained high ($\geq 23\%$, Table 8), which can be attributed to uncertainties that may be contributed by different sources like quality of the in-situ measurements and sensitivity of the remotely sensed data. For instance, Chave et al. (2009) reported mean errors of about 27% on wood density measurements in the tropical forests and Ikati Lisongi (2011), reported the uncertainty on tree diameter measurement to be approximately 18% in the Congo basin. Similarly, the errors on maximum-modeled height (Equation 7.1) in the Mondah forest were estimated to about 23% (Labriere et al. 2018).

In this study, standard residual errors between modeled forest height (H_T , Equation 7.1) and corresponding heights derived from LiDAR and PolInSAR are 2.6 m (17.0%) and 3.07 m (20.3%), respectively. All these factors are critical in the computation of AGB using Equation 7.2. Moreover, the difficulties related to data collection in tropical forests may influence the sampling framework in the field, as well as the scale and representativity of the datasets. The analysis of Moran's Global index (Table 7.3) computed over sample plots (30.8 x 30.8 m) at the study site and those from the AfriSAR campaign at 1 ha (Table 7.4) reveals the existence of spatial autocorrelation in the AGB data. This global index characterizes the overall distribution and spatial structure of AGB in the whole study area. Spatial autocorrelation and heterogeneity are rather frequent phenomena in forests (Réjou-Méchain et al. 2014; Méthot et al. 2014; Ou et al. 2019). In contrast, the use of local Anselin Moran's I to evaluate autocorrelation at local scales shows no spatial autocorrelation for 61% of AGB samples (from sample plots) used in this study (Table 7.3), and for about 67% of the data in the AfriSAR campaign (Table 7.4). Therefore, the strategy employed here to derive sample plots from the existing AfriSAR samples (1 ha plots) did not introduce unexpected spatial autocorrelations. The level of observed autocorrelation is comparable to several other investigations reporting the development of the AGB models (Ou et al. 2019; Ploton et al. 2020).

The GLCM texture indices indicated low to moderate correlations with biomass, compared to other indicators (e.g. FOTO PC2, H_R , σ^0 or RH50, see Table 7.5). In the past investigations, these indices have often yielded mixed results, depending upon several factors such as image type, window size, inter-pixel distances, or sampling directions (Coulibaly and Gwyn 2005; Nichol and Sarker 2011; Alberto et al. 2012; Kelsey and Neff 2014; Pandit, Tsuyuki, and Dube 2020). In this study, we did not test several inter-

pixel distances while estimating the indices. Only one fixed value was used. This may explain the relatively poor performance of the GLCM. Unlike the GLCM parameters, the results obtained with FOTO indices represented the vegetation better. The FOTO PC2 index described the forest structure better, which is also supported by the strong correlation with stand diameters (Table 7.5). However, this result differed from those reported in the previous studies, where the strongest correlations were found with the FOTO PC1 (Proisy, Couteron, and Fromard [2007](#); Singh et al. [2015](#); Migolet and Kalifa [2020](#)). In this investigation, FOTO PC1 best described young-adult or flood-prone secondary forests (notably mangroves). Unfortunately, the limited number of sample plots over these stands did not permit further investigation.

The strong link observed between PC2 and AGB enabled the development of relatively efficient MARS models, using only the SPOT-7 optical image (see Table 7.7, Model 5: $R^2 = 0.60$; $P < 0.0001$; RMSE = 63%). This was favored certainly by the fine spatial resolution of the pan-sharpened SPOT-7 image ($1.5 \text{ m} \times 1.5 \text{ m}$), which allows better discrimination of the tree crowns. Moreover, the choice of the window size to derive the r-spectra is also crucial. Here, a window size of $175 \times 175 \text{ m}$ showed better distinctions between fine and coarse textures in closed and open forest canopies. Although, increasing the window size tend to improve the discrimination of fine and coarse textures, it could reduce the scoring for each principal component (Couteron, Barbier, and Gautier [2006](#); Proisy, Couteron, and Fromard [2007](#); Ploton et al. [2012](#); Barbier and Couteron [2015](#); Migolet and Kalifa [2020](#)). In agreement with the previous investigations, this work also indicated the strong potential of L-band PolInSAR variables for estimating AGB in tropical forests. The sensitivity of the HV polarization channel to forest cover and volume scattering can explain this behavior (Ho Tong Minh et al. [2018](#); El Hajj et al. [2019](#)). The backscatter coefficient σ^0 also appeared to be significantly related to the forest parameters (diameter and height) and AGB (Table 7.5). This permitted the development of Models 3, 4 and 6 (Tables 7.8 and 7.9) using the MARS approach with only L-band PolInSAR data. Validation results (Table 8) indicated that combining σ^0 and HR reduced the error by at least 10%.

The limitations on using the L-band data may arise from possible saturation effects in very dense forest areas, such as the north-western part of the study area. The introduction of texture information to the radar backscattering (Models 9 and 10) does not improve the AGB estimation errors. Among the individual variables that were considered, the LiDAR derived median canopy height (RH50) demonstrated the greatest potential for estimating forest AGB with low validation errors (Table 7.8, Model 7: $R^2 = 0.84$; $P < 0.0001$;

RMSE = 28%). This result is consistent with previous studies (Labriere et al. [2018](#); Saatchi et al. [2019](#)). Leitold et al. ([2015](#)) emphasized the importance of the density of LiDAR point cloud measurements in improving the accuracy of height estimates from LiDAR and AGB data. However, the density of 2.3 LiDAR points per square meters did not seem to be a limiting factor in this investigation. The results obtained solely with the RH50 height are quite interesting and significant, but our analysis indicated that they can be substantially improved by introducing additional variables extracted from radar or optical data. The best performance was actually observed for Models 11 to 14 that included LiDAR derived heights (Tables 7.8, 7.9). The combinations with the radar σ^0 (Model 12) or with the FOTO indices (Model 13) proved to be particularly efficient, with RMSE errors of the order of 41% in the training phase (Table 7.7) and 24% in the validation phase (Table 7.8). Radar and optical data provide complementary information on the spatial structure of the forest (volume, crown, and density), thereby favoring better estimation of the AGB. Previous investigations also reported improvement in the results after combining multi-source variables (Sun et al. [2011](#); Zhang et al. [2014](#); Kumar et al. [2015](#); Almeida et al. [2019b](#); Li, Zhou, and Wenbin [2021](#)).

Our research focused solely upon the use of the MARS approach in developing the AGB models. This was motivated by the fact that the approach has been seldom employed despite its potential being recognized by several investigations (Vaglio Laurin et al. 2016; Baloloy et al. [2018](#); Miglet and Kalifa [2020](#)). The ability of the MARS approach to take into account the non-linearities in modeling is particularly valuable in the context of modeling the tropical forests biomass. In most of the models that have been developed, MARS circumvents the necessity of including non-linearities by summing linear basis functions. Interaction terms among variables have been rarely used here, except with optical data, which have much more indirect relationships with AGB. The relatively low number of the training dataset used may also contribute to the absence of the interaction terms (Li, Bakshi, and Goel [2009](#)). In some cases, RMSE errors observed during the model validation appeared to be lower than those obtained during the training phase. The differences in the representativity of validation and the training dataset can probably explain this behavior (Zhang and Anthony [2016](#); López-Serrano et al. [2016](#); Vaglio-Laurin, 2015; Park et al. [2017](#); Li et al. [2019](#)). This calls for further validations of the developed AGB models with more detailed forest datasets.

To further investigate, we compared the results of Model 14 to existing AGB maps. The seventeen independent validation sample plots were used in the evaluation in each case. [Figure 7.9](#) indicates the comparison. Our model has a small bias and can reasonably

estimate both lowest (<250 tons per hectare) and highest AGB (>400 tons per hectare). In contrast, most existing models overestimate AGB when biomass approaches 250 tons per hectare. Overall, the results are better for all the maps produced using local models developed over the Mondah forest site, compared to the ones at country (El Hajj et al. 2019) or regional (Bouvet et al. 2018) scales. This is most likely due to the representativity of the in-situ measurements employed in different investigations. However, due to the limited number of samples used as well as the scale and spatial resolutions considered by various investigations, the comparisons should be interpreted with caution (Saatchi et al. 2011; Baccini et al. 2012; Ngomanda et al. 2014; Baccini et al. 2015; Baccini et al. 2017).

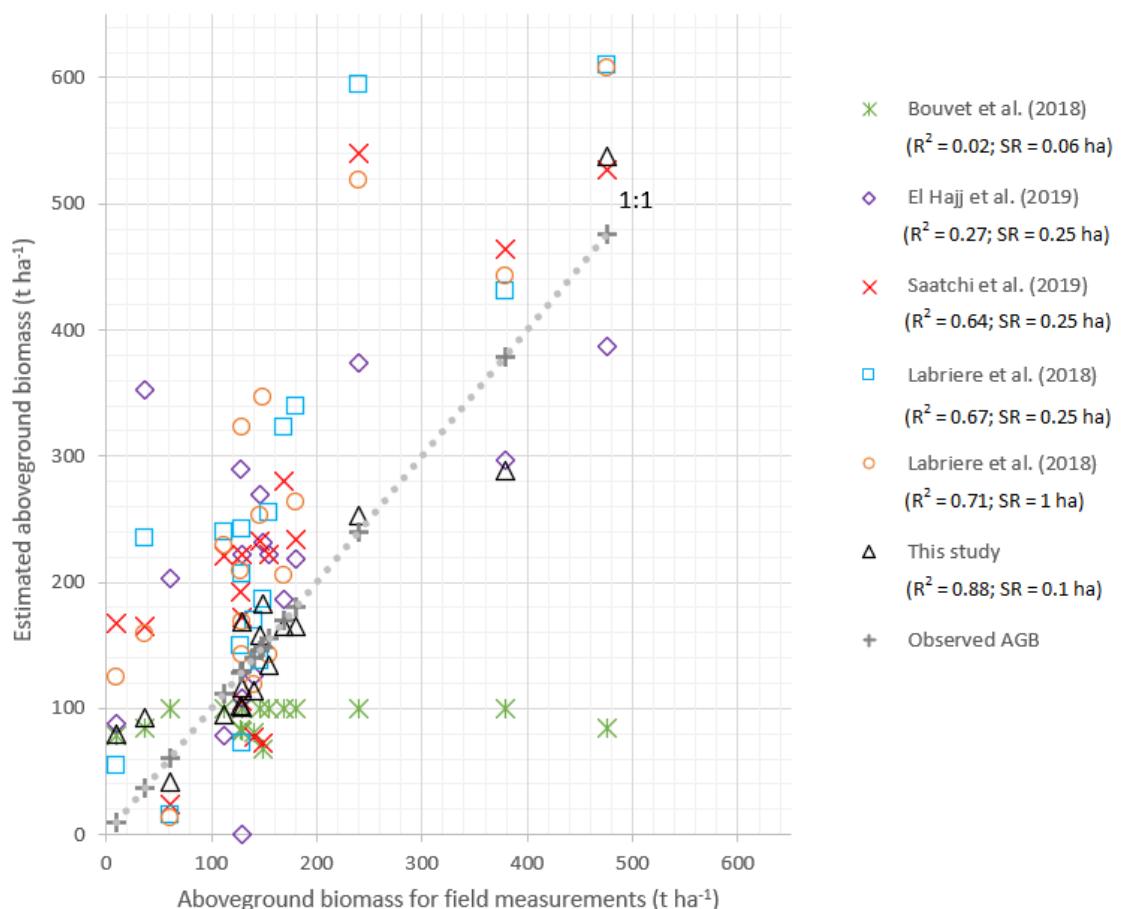


Figure 7.9. Comparison of AGB estimated using Model 14 with AGBs from existing maps. The dotted gray line represents the 1:1 correspondence line. SR corresponds to the original spatial resolution of the AGB maps. ** is for $P \leq 0.0001$; * for $P < 0.05$; no star indicates not significant at 95% confidence level. RMSE error is indicated in each case.

7.6. Conclusion

This investigation proposed the MARS-based modeling approach employing multi-source datasets to estimate aboveground biomass and demonstrated its utility over the tropical forests in the Congo Basin. The results indicated that the LiDAR derived median height is the most efficient predictor of AGB as compared to all other individual variables (RMSE = 28%). The performance of AGB estimation was enhanced when median height was combined with optical and radar observations (RMSE between 23% and 33%). The best model combined different variables extracted from the remotely sensed observations (LiDAR median height, PolInSAR target backscattering coefficient and canopy surface height, and Optical texture indices) to achieve a better performance (RMSE = 24%). This research demonstrated the efficiency of the MARS approach in estimating tropical forest AGB with or without the combination of different types of remotely sensed data. Compared to the results of the best model developed in this research, the errors in most existing AGB maps appear high. Future works will focus on further refinement and validation of the AGB models using extensive data precisely representing the vast majority of classes and tropical forest conditions.

Acknowledgements

The authors gratefully acknowledge the Programme canadien de bourses de la Francophonie (Government of Canada, Canadian Partnership Branch, Department of Foreign Affairs, Trade and Development) and NSERC (Natural Sciences and Engineering Research Council of Canada) for their financial support. We are also grateful to the following Gabonese government agencies and institutions that contributed substantially to the field data measurement campaign and the acquisition of satellite images that were used in this study: l'Agence Nationale des Parcs Nationaux (ANPN), l'Agence Gabonaise d'Études et d'Observation Spatiale (AGEOS), as well as the Projet de Développement d'un Système d'Inventaire des Ressources Forestières Nationales contributing to sustainable forest management (PDSIRFN), which is under the supervision of the Ministry in charge of Eaux et Forêts du Gabon. This research uses data that were acquired during the AfriSAR campaign by NASA and its partners (ESA, AGEOS), and greatly thanks all who contributed to the acquisition of these data. Many individuals contributed to various aspects of the study, including the experimental design of data collection and fieldwork at the study site in Cap-Estérias, which is 25 km north of Libreville, Gabon: Dr. Jean Paul Obame Engone, Jacques Mouloungou, Élie Patrick Koumba, Marius Kombila, Alain Moundounga, Freddy Makiloutila, Léandre Oyen Amoni, Steeve Arnault Mabicka Moussavou, Jean Paul Mondjo, Raoul Nyangadouma, Lucien Ligna, Davy

Ngueba Ikapi, Houli Mondjo, Paul Mbini, Parfait Ndzinga Ndzinga, Judicaël Anaclet Boulondo Nzengué and Ronny Bonhomme Yamangoyi Mingani.

Disclosure statement

No potential conflict of interest was reported by the author(s).

Highlights

1. MARS approach was used with multi-source remote sensing data to estimate AGB.
2. Median canopy height is better correlated to AGB as compared to other variables.
3. FOTO PC2 texture is better correlated to forest biomass as compared to GLCM.
4. Best AGB models were achieved by combining multi-source remote sensing variables.

Additional information

Funding

This work was supported by the Coir Board, Govt. of India [[No: CCRI/RES/CGT-CET/3/16/2011/0863]]; Canadian Network for Research and Innovation in Machining Technology, Natural Sciences and Engineering Research Council of Canada (CA) [RGPIN-2018-06101];

References

1. Agrawal, N. S. K., and V. A. Tolpekin. 2019. "PolInSAR Based Scattering Information Retrieval for Forest Aboveground Biomass Estimation." *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Vol. XLII-2-W13, 1913–1920. Copernicus GmbH. doi:<https://doi.org/10.5194/isprs-archives-XLII-2-W13-1913-2019>. [[Crossref](#)], [[Google Scholar](#)]
2. Al-Sudani, A., S. Q. Zainab, A. S. Salih, and Z. M. Yaseen. 2019. "Development of Multivariate Adaptive Regression Spline Integrated with Differential Evolution Model for Streamflow Simulation." *Journal of Hydrology* 573 (June): 1–12. doi:<https://doi.org/10.1016/J.JHYDROL.2019.03.004>. [[Crossref](#)], [[Google Scholar](#)]
3. Alberto, G.-C. J., J. A. Meave, E. J. González, E. E. Lebrija-Trejos, M. A. Romero-Romero, E. A. Pérez-García, R. Gallardo-Cruz, J. L. Hernández-Stefanoni, and C. Martorell. 2012. "Predicting Tropical Dry Forest Successional Attributes

- from Space: Is the Key Hidden in Image Texture?" *PLOS ONE* 7 (2): e30506. doi:<https://doi.org/10.1371/journal.pone.0030506>. Public Library of Science. [Crossref], [PubMed], [Web of Science ®], [Google Scholar]
4. Almeida, C. T. D., L. S. Galvão, L. E. D. O. Cruz E Aragão, J. P. H. Balbaud Ometto, A. D. Jacon, F. R. D. S. Pereira, L. Y. Sato, et al. 2019b. "Combining LiDAR and Hyperspectral Data for Aboveground Biomass Modeling in the Brazilian Amazon Using Different Regression Algorithms." *Remote Sensing of Environment* 232. doi:<https://doi.org/10.1016/j.rse.2019.111323>. [Crossref], [PubMed], [Web of Science ®], [Google Scholar]
 5. Anselin, L. 2010. "Local Indicators of Spatial Association—LISA." *Geographical Analysis* 27 (2): 93–115. doi:<https://doi.org/10.1111/j.1538-4632.1995.tb00338.x>. [Crossref], [Google Scholar]
 6. Aubert, M. 2012. "Caractérisation de L'état de Surface Des Sols Nus Agricoles Par Imagerie Radar TerraSAR-X." Phd thesis, AgroParisTech. <https://tel.archives-ouvertes.fr/tel-00764268>. [Google Scholar]
 7. Avitabile, V., G. B. Martin Herold, M. Heuvelink, S. L. Lewis, O. L. Phillips, G. P. Asner, J. Armston, et al. 2016. "An Integrated Pan-Tropical Biomass Map Using Multiple Reference Datasets." *Global Change Biology* 22 (4): 1406–1420. doi:<https://doi.org/10.1111/gcb.13139>. [Crossref], [PubMed], [Web of Science ®], [Google Scholar]
 8. Baccini, A., S. J. Goetz, W. S. Walker, N. T. Laporte, M. Sun, D. Sulla-Menashe, J. Hackler, et al. 2012. "Estimated Carbon Dioxide Emissions from Tropical Deforestation Improved by Carbon-Density Maps." *Nature Climate Change* 2 (March). Nature Publishing Group: 182–185. <https://doi.org/10.1038/nclimate1354> [Crossref], [Google Scholar]
 9. Baccini, A., N. Laporte, S. J. Goetz, M. Sun, and H. Dong. 2008. "A First Map of Tropical Africa's above-ground Biomass Derived from Satellite Imagery." *Environmental Research Letters* 3 (4): 45011. doi:<https://doi.org/10.1088/1748-9326/3/4/045011>. [Crossref], [Web of Science ®], [Google Scholar]
 10. Baccini, A., W. Walker, L. Carvalho, M. Farina, D. Sulla-Menashe, and R. A. Houghton. 2017. "Tropical Forests are a Net Carbon Source Based on Aboveground Measurements of Gain and Loss." *Science (New York, N.Y.)* 358 (6360): 230–234.

- doi:<https://doi.org/10.1126/science.aam5962>. [Crossref], [PubMed], [Web of Science ®], [Google Scholar]
11. Baloloy, A. B., A. C. Blanco, C. G. Candido, R. J. Labadisos Argamosa, J. B. L. Caboboy Dumalag, L. L. Carandang Dimapilis, and E. C. Paringit. 2018. "Estimation of Mangrove Forest Aboveground Biomass Using Multispectral Bands, Vegetation Indices and Biophysical Variables Derived from Optical Satellite Imageries: Rapideye, PlanetScope and Sentinel-2." *ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences IV-3*:29–36. doi:<https://doi.org/10.5194/isprs-annals-IV-3-29-2018>. Copernicus GmbH. [Crossref], [Google Scholar]
12. Barbier, N., and P. Couteron. 2015. "Attenuating the Bidirectional Texture Variation of Satellite Images of Tropical Forest Canopies." *Remote Sensing of Environment* 171 (December): 245–260. doi:<https://doi.org/10.1016/j.rse.2015.10.007>. [Crossref], [Google Scholar]
13. Barbier, N., P. Couteron, J.-P. Gastelly-Etchegorry, and C. Proisy. 2012. "Linking Canopy Images to Forest Structural Parameters: Potential of a Modeling Framework." *Annals of Forest Science* 69 (2): 305–311. doi:<https://doi.org/10.1007/s13595-011-0116-9>. [Crossref], [Web of Science ®], [Google Scholar]
14. Bastin, J.-F., N. Barbier, P. Couteron, B. Adams, A. Shapiro, J. Bogaert, and D. C. Charles. 2014. "Aboveground Biomass Mapping of African Forest Mosaics Using Canopy Texture Analysis: Toward a Regional Approach." *Ecological Applications* 24 (8): 1984–2001. doi:<https://doi.org/10.1890/13-1574.1>. [Crossref], [PubMed], [Web of Science ®], [Google Scholar]
15. Blair, J. B., and M. Hofton. 2017. "AfriSAR LVIS L2 Geolocated Surface Elevation Product, Version 1." *NASA National Snow and Ice Data Center DAAC*. doi:<https://doi.org/10.5067/A0PMUXXVUYNH>. [Google Scholar]
16. Bouayad Agha, S., and M.-P. Bellefon. 2018. "Indices D'aucorrelations Spatiale." Chap 3." In *Cybergeo: European Journal of Geography*, edited by T. L. V. Feuillet, and M.-P. Bellefon. 2018, Manuel d'analyse spatiale. Théorie et mise en œuvre pratique avec R, Insee Méthodes n° 131, Insee, Eurostat, 392 p», 53–72. Paris, France: CNRS-UMR Géographie-cités 8504. <http://journals.openedition.org/cybergeo/29853> <https://doi.org/10.4000/cybergeo.29853>. [Google Scholar]

17. Bouvet, A., S. Mermoz, L. T. Thuy, L. Villard, R. Mathieu, L. Naidoo, and G. P. Asner. 2018. “An Above-Ground Biomass Map of African Savannahs and Woodlands at 25m Resolution Derived from ALOS PALSAR.” *Remote Sensing of Environment* 206 (March): 156–173.
doi:<https://doi.org/10.1016/j.rse.2017.12.030>. [Crossref], [Google Scholar]
18. Bréda, N., K. Soudani, and J.-C. Bergonzini. 2002. *Mesure de L’indice Foliaire En Forêt*. ECOFOR. <https://hal.inrae.fr/hal-02831614>. [Google Scholar]
19. Briottet, X. 2016. Physique de La Mesure Dans Le Domaine Optique. Chap. 1, 21–71, In N. Baghdadi, and M. Zribi (edited by) *Observations Des Surfaces Continentales Par Télédétection Optique: Techniques Et Méthodes*. London, UK: ISTE Editions . Vol. 1. <https://hal.duivre.com/livre/9781784051563-observation-des-surfaces-continentales-par-teledetection-optique-techniques-et-methodes-nicolas-baghdadi-mehrez-zribi/> [Google Scholar]
20. Cartus, O., and M. Santoro. 2019. “Exploring Combinations of Multi-Temporal and Multi-Frequency Radar Backscatter Observations to Estimate above-Ground Biomass of Tropical Forest.” *Remote Sensing of Environment* 232 (October): 111313.
doi:<https://doi.org/10.1016/j.rse.2019.111313>. [Crossref], [Google Scholar]
21. Cartus, O., M. Santoro, and J. Kellndorfer. 2012. “Mapping Forest Aboveground Biomass in the Northeastern United States with ALOS PALSAR Dual-Polarization L-Band.” *Remote Sensing of Environment* 124: 466–478.
doi:<https://doi.org/10.1016/j.rse.2012.05.029>. [Crossref], [Web of Science ®], [Google Scholar]
22. Chaparro, D., G. Duveiller, M. Piles, A. Cescatti, M. Vall-llossera, A. Camps, and D. Entekhabi. 2019. “Sensitivity of L-Band Vegetation Optical Depth to Carbon Stocks in Tropical Forests: A Comparison to Higher Frequencies and Optical Indices.” *Remote Sensing of Environment* 232 (October): 111303.
doi:<https://doi.org/10.1016/J.RSE.2019.111303>. [Crossref], [Google Scholar]
23. Chave, J., D. Coomes, S. Jansen, S. L. Lewis, N. G. Swenson, and A. E. Zanne. 2009. “Towards a Worldwide Wood Economics Spectrum.” *Ecology Letters* 12 (4): 351–366. doi:<https://doi.org/10.1111/j.1461-0248.2009.01285.x>. [Crossref], [PubMed], [Web of Science ®], [Google Scholar]
24. Chave, J., M. Réjou-Méchain, A. Bürquez, E. Chidumayo, M. S. Colgan, W. B. C. Delitti, A. Duque, et al. 2014. “Improved Allometric Models to Estimate the Aboveground Biomass of Tropical Trees.” *Global Change Biology* 20 (10): 3177–

3190. doi:<https://doi.org/10.1111/gcb.12629>. [Crossref], [PubMed], [Web of Science ®], [Google Scholar]
25. Chen, A., S. Peng, and S. Fei. 2019. "Mapping Global Forest Biomass and Its Changes over the First Decade of the 21st Century." *Science China Earth Sciences* 62 (3): 585–594. doi:<https://doi.org/10.1007/s11430-018-9277-6>. [Crossref], [Web of Science ®], [Google Scholar]
26. Chen, P., and F. Wang. 2020. "New Textural Indicators for Assessing Above-Ground Cotton Biomass Extracted from Optical Imagery Obtained via Unmanned Aerial Vehicle." *Remote Sensing* 12 (24): 4170. doi:<https://doi.org/10.3390/rs12244170>. Multidisciplinary Digital Publishing Institute. [Crossref], [Web of Science ®], [Google Scholar]
27. Chong, K. L., K. D. Kanniah, C. Pohl, and K. P. Tan. 2017. "A Review of Remote Sensing Applications for Oil Palm Studies." *Geo-Spatial Information Science* 20 (2): 184–200. doi:<https://doi.org/10.1080/10095020.2017.1337317>. Taylor and Francis Ltd. [Taylor & Francis Online], [Web of Science ®], [Google Scholar]
28. Coulibaly, L., and K. Goita. 2006. "Evaluation of the Potential of Various Spectral Indices and Textural Features Derived from Satellite Images for Surficial Deposits Mapping." *International Journal of Remote Sensing* 27 (October): 4567–4584. doi:<https://doi.org/10.1080/01431160600857394>. [Taylor & Francis Online], [Google Scholar]
29. Coulibaly, L., and Q. H. J. Gwyn. 2005. "Intégration de Données D'images Satellitaires Optiques Et Radars Et de Données Topographiques Pour La Cartographie Géomorphologique." *Canadian Journal of Remote Sensing* 31 (6): 439–449. doi:<https://doi.org/10.5589/m05-028>. Taylor & Francis. [Taylor & Francis Online], [Web of Science ®], [Google Scholar]
30. Coulibaly, L., P. Migolet, H. Adegbidi, R. Fournier, and E. Hervet. 2008. "Mapping Aboveground Forest Biomass from Ikonos Satellite Image and Multi-Source Geospatial Data Using Neural Networks and a Kriging Interpolation." *IGARSS 2008-2008 IEEE International Geoscience and Remote Sensing Symposium*. doi:<https://doi.org/10.1109/IGARSS.2008.4779342>. [Crossref], [Google Scholar]
31. Couteron, P., N. Barbier, and D. Gautier. 2006. "Textural Ordination Based on Fourier Spectral Decomposition: A Method to Analyze and Compare Landscape Patterns." *Landscape Ecology* 21 (4): 555–567.

- doi:<https://doi.org/10.1007/s10980-005-2166-6>. [Crossref], [Web of Science ®], [Google Scholar]
32. Couteron, P., E. A. N. Raphael Pelissier, and D. Paget. 2005. “Predicting Tropical Forest Stand Structure Parameters from Fourier Transform of Very High-Resolution Remotely Sensed Canopy Images.” *Journal of Applied Ecology* 42 (6): 1121–1128. doi:<https://doi.org/10.1111/j.1365-2664.2005.01097.x>. [Crossref], [Web of Science ®], [Google Scholar]
33. Cracknell, A. P. 2018. “The Development of Remote Sensing in the Last 40 Years.” *International Journal of Remote Sensing* 39 (23): 8387–8427. doi:<https://doi.org/10.1080/01431161.2018.1550919>. Taylor & Francis. [Taylor & Francis Online], [Web of Science ®], [Google Scholar]
34. Denbina, M., M. Simard, and B. Hawkins. 2018. “Forest Height Estimation Using Multibaseline PolInSAR and Sparse Lidar Data Fusion.” *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 11 (10): 3415–3433. doi:<https://doi.org/10.1109/JSTARS.2018.2841388>. [Crossref], [Web of Science ®], [Google Scholar]
35. Devineau, J.-L. 1990. “Propriétés Spectrales de La Végétation.” In *Images Satellite Et Milieux Terrestres En Régions Arides Et Tropicales*. edited by, M. Pouget, C. Mering, and H. Andrianasolo, 43–49. Paris: ORSTOM. Colloques et Séminaires. <http://www.documentation.ird.fr/hor/fdi:30003> [Google Scholar]
36. Domingues, G. F., V. P. Soares, H. G. Leite, A. S. Ferraz, C. A. A. Soares Ribeiro, A. S. Lorenzon, G. E. Marcatti, et al. 2020. “Artificial Neural Networks on Integrated Multispectral and SAR Data for High-Performance Prediction of Eucalyptus Biomass.” *Computers and Electronics in Agriculture* 168 (January): 105089. doi:<https://doi.org/10.1016/J.COMPAG.2019.105089>. [Crossref], [Google Scholar]
37. Donegan, E., G. Sola, Z. Cheng, L. Birigazzi, J. Gamarra, M. Henry, G. Vieilledent, and T. Chiti. 2014 , FAO. *GlobAllomeTree’s Wood Density Database*, Rome, Italie. [Google Scholar]
38. El Hajj, M., N. B. Baghdadi, N. Labriere, J.-S. Bailly, and L. Villard. 2019. “Mapping of Aboveground Biomass in Gabon.” *Comptes Rendus Geoscience* 351 (4): 321–331. doi:<https://doi.org/10.1016/J.CRTE.2019.01.001>. [Crossref], [Web of Science ®], [Google Scholar]

- 39.** Epple, C., S. García Rangel, M. Jenkins, and M. Guth. 2016. “Managing Ecosystems in the Context of Climate Change Mitigation: A Review of Current Knowledge and Recommendations to Support Ecosystem-Based Mitigation Actions that Look beyond Terrestrial Forests.” *CBD Technical Series*, no. No. 86. Convention on Biological Diversity. <https://www.cabdirect.org/cabdirect/abstract/20173021221>. [Google Scholar]
- 40.** Fatoyinbo, T., S. S. Saatchi, J. Armston, J. Poulsen, S. Marselis, N. Pinto, L. J. T. White, and K. Jeffery. 2018. “AfriSAR: Mondah Forest Tree Species, Biophysical, and Biomass Data, Gabon, 2016.” *ORNL Distributed Active Archive Center*. 1.100239 MB. doi:<https://doi.org/10.3334/ORNLDaac/1580>. [Google Scholar]
- 41.** Fayolle, A., A. Ngomanda, M. Mbasi, N. Barbier, Y. Bocko, F. Bosela, P. Couteron, et al. 2018. “A Regional Allometry for the Congo Basin Forests Based on the Largest Ever Destructive Sampling.” *Forest Ecology and Management* 430 (December): 228–240.
doi:<https://doi.org/10.1016/j.foreco.2018.07.030>. [Crossref], [Google Scholar]
- 42.** Friedman, J. H. 1991. “Multivariate Adaptive Regression Splines.” *The Annals of Statistics* 19 (1): 1–67.
doi:<https://doi.org/10.1214/aos/1176347963>. [Crossref], [Web of Science ®], [Google Scholar]
- 43.** Fung, A. K. 1994. *Microwave Scattering and Emission Models and Their Applications*. Boston: Artech House Publishers. [Google Scholar]
- 44.** García Nieto, P. J., E. García-Gonzalo, F. Sánchez Lasheras, J. P. Paredes-Sánchez, and P. Riesgo Fernández. 2019. “Forecast of the Higher Heating Value in Biomass Torrefaction by Means of Machine Learning Techniques.” *Journal of Computational and Applied Mathematics* 357 (September): 284–301.
doi:<https://doi.org/10.1016/J.CAM.2019.03.009>. North-Holland. [Crossref], [Google Scholar]
- 45.** García, M., S. Saatchi, S. Ustin, and H. Balzter. 2018. “Modelling Forest Canopy Height by Integrating Airborne LiDAR Samples with Satellite Radar and Multispectral Imagery.” *International Journal of Applied Earth Observation and Geoinformation* 66 (April): 159–173.
doi:<https://doi.org/10.1016/j.jag.2017.11.017>. [Crossref], [Google Scholar]

46. Goïta, K., J. Mouloungou, and B. Goze. 2017. “Estimation of Aboveground Biomass and Carbon in a Tropical Rain Forest in Gabon Using Remote Sensing and GPS Data.” *Geocarto International* 34 (October): 1–38. doi:<https://doi.org/10.1080/10106049.2017.1386720>. [Google Scholar]
47. Gonçalves, A. C., I. Malico, and A. M. O. Sousa. 2018. Eduardo, Jacob-Lopes, and Leila, Queiroz Zepka. *Solid Biomass from Forest Trees to Energy: A Review. Renewable Resources and Biorefineries*. Santa María, Brazil: IntechOpen. doi:<https://doi.org/10.5772/intechopen.79303>. [Google Scholar]
48. Gopalakrishnan, R., V. Thomas, J. Coulston, and R. Wynne. 2015. “Prediction of Canopy Heights over a Large Region Using Heterogeneous Lidar Datasets: Efficacy and Challenges.” *Remote Sensing* 7 (9): 11036–11060. doi:<https://doi.org/10.3390/rs70911036>. [Crossref], [Web of Science ®], [Google Scholar]
49. Gould, S. J. 1966. “Allometry and Size in Ontogeny and Phylogeny.” *Biological Reviews* 41 (4): 587–638. doi:<https://doi.org/10.1111/j.1469-185X.1966.tb01624.x>. [Crossref], [PubMed], [Web of Science ®], [Google Scholar]
50. Hansen, M. C., P. Potapov, and A. Tyukavina. 2019. “Comment on ‘Tropical Forests are a Net Carbon Source Based on Aboveground Measurements of Gain and Loss.’” *Science* 363(6423). American Association for the Advancement of Science. doi:<https://doi.org/10.1126/science.aar3629>. [Crossref], [PubMed], [Web of Science ®], [Google Scholar]
51. Haralick, R. 1979. “Statistical and Structural Approaches to Texture.” *Proceedings of the IEEE* 67: 786–804. doi: <https://doi.org/10.1109/PROC.1979.11328>. [Crossref], [Web of Science ®], [Google Scholar]
52. Hiatshwayo, S. T., R. T. Onisimo Mutanga, Z. K. Lottering, and R. Ismail. 2019. “Mapping Forest Aboveground Biomass in the Reforested Buffelsdraai Landfill Site Using Texture Combinations Computed from SPOT-6 Pan-Sharpened Imagery.” *International Journal of Applied Earth Observation and Geoinformation* 74 (February): 65–77. doi:<https://doi.org/10.1016/j.jag.2018.09.005>. [Crossref], [Google Scholar]
53. Ikati Lisongi, B. 2011. “Analyse Comparative Des Techniques de Mesure de Diamètre Des Arbres: CasDu Compas Forestier Et Du Ruban Circonférentiel.” *Université de Kinshasa, Kinshasa*, Kinshasa,

- RDC. <https://www.memoireonline.com/03/12/5585/Analyse-comparative-des-techniques-de-mesure-de-diametre-des-arbrescas-du-compas-forestier-et-du-r.html>. [Google Scholar]
54. Jones, I. L., S. J. DeWalt, O. R. Lopez, L. Bunnefeld, Z. Pattison, and D. H. Dent. 2019. “Above- and Belowground Carbon Stocks are Decoupled in Secondary Tropical Forests and are Positively Related to Forest Age and Soil Nutrients Respectively.” *Science of the Total Environment* 697. doi:<https://doi.org/10.1016/j.scitotenv.2019.133987>. [Web of Science ®], [Google Scholar]
55. Kamir, E., F. Waldner, and Z. Hochman. 2020. “Estimating Wheat Yields in Australia Using Climate Records, Satellite Image Time Series and Machine Learning Methods.” *ISPRS Journal of Photogrammetry and Remote Sensing* 160 (February): 124–135. doi:<https://doi.org/10.1016/J.ISPRSJPRS.2019.11.008>. [Crossref], [Google Scholar]
56. Kelsey, K., and J. Neff. 2014. “Estimates of Aboveground Biomass from Texture Analysis of Landsat Imagery.” *Remote Sensing* 6 (7): 6407–6422. doi:<https://doi.org/10.3390/rs6076407>. [Crossref], [Web of Science ®], [Google Scholar]
57. King, D. A. 1996. “Allometry and Life History of Tropical Trees.” *Journal of Tropical Ecology* 12 (1): 25–44. doi:<https://doi.org/10.1017/S0266467400009299>. Cambridge University Press. [Crossref], [Google Scholar]
58. Knapp, N., R. Fischer, V. Cazcarra-Bes, and A. Huth. 2020. “Structure Metrics to Generalize Biomass Estimation from Lidar across Forest Types from Different Continents.” *Remote Sensing of Environment* 237. doi:<https://doi.org/10.1016/j.rse.2019.111597>. [Web of Science ®], [Google Scholar]
59. Ku, N.-W., and S. C. Popescu. 2019. “A Comparison of Multiple Methods for Mapping Local-Scale Mesquite Tree Aboveground Biomass with Remotely Sensed Data.” *Biomass & Bioenergy* 122 (March): 270–279. doi:<https://doi.org/10.1016/J.BIOMBIOE.2019.01.045>. [Crossref], [Google Scholar]
60. Kumar, L., P. Sinha, S. Taylor, and A. F. Alqurashi. 2015. “Review of the Use of Remote Sensing for Biomass Estimation to Support Renewable Energy

- Generation.” *Journal of Applied Remote Sensing* 9 (1): 097696. doi:<https://doi.org/10.11117/1.JRS.9.097696>. [Crossref], [Google Scholar]
61. Labriere, N., S. Tao, J. Chave, K. Scipal, T. T. L. Katharine Abernethy, A. Alonso, et al. 2018. “In Situ Reference Datasets from the TropiSAR and AfriSAR Campaigns in Support of Upcoming Spaceborne Biomass Missions.” *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 11 (10): 3617–3627.
doi:<https://doi.org/10.1109/JSTARS.2018.2851606>. [Crossref], [Web of Science ®], [Google Scholar]
62. Lavalle, M., B. V. Riel, G. Shiroma, and B. P. Hawkins. 2018. “AfriSAR: Canopy Structure Derived from PolInSAR and Coherence TomoSAR NISAR Tools.” *ORNL DAAC*. doi:<https://doi.org/10.3334/ORNLDaac/1601>. [Google Scholar]
63. Lefsky, M. A., D. J. Harding, M. Keller, W. B. Cohen, C. C. Carabajal, F. Del Bom, M. O. Hunter, and R. de Oliveira Jr. 2005. “Estimates of Forest Canopy Height and Aboveground Biomass Using ICESat.” *Geophysical Research Letters* 32 (22): 1–4. doi:<https://doi.org/10.1029/2005GL023971>. [Crossref], [Web of Science ®], [Google Scholar]
64. Leitold, V., M. Keller, D. C. Morton, B. D. Cook, and Y. E. Shimabukuro. 2015. “Airborne Lidar-Based Estimates of Tropical Forest Structure in Complex Terrain: Opportunities and Trade-Offs for REDD+.” *Carbon Balance and Management* 10 (1): 3. doi:<https://doi.org/10.1186/s13021-015-0013-x>. [Crossref], [PubMed], [Google Scholar]
65. Li, B., B. R. Bakshi, and P. K. Goel. 2009. “3.13 - Other Methods in Nonlinear Regression.” In *Comprehensive Chemometrics*, edited by S. D. Brown, R. Tauler, and B. Walczak, 463–476. Oxford: Elsevier. doi:<https://doi.org/10.1016/B978-044452701-1.00062-4>. [Crossref], [Google Scholar]
66. Li, D. H. W., W. Chen, L. Shuyang, and S. Lou. 2019. “Estimation of Hourly Global Solar Radiation Using Multivariate Adaptive Regression Spline (MARS) – A Case Study of Hong Kong.” *Energy* 186 (November): 115857. doi:<https://doi.org/10.1016/J.ENERGY.2019.115857>. [Crossref], [Google Scholar]
67. Li, W., P. Ciais, S. Peng, C. Yue, Y. Wang, M. Thurner, S. S. Saatchi, et al. 2017. “Land-Use and Land-Cover Change Carbon Emissions between 1901 and 2012 Constrained by Biomass Observations.” *Biogeosciences* 14 (22): 5053–5067.

- doi:<https://doi.org/10.5194/bg-14-5053-2017>. Copernicus GmbH. [\[Crossref\]](#), [\[Web of Science ®\]](#), [\[Google Scholar\]](#)
68. Li, C., L. Zhou, and X. Wenbin. 2021. “Estimating Aboveground Biomass Using Sentinel-2 MSI Data and Ensemble Algorithms for Grassland in the Shengjin Lake Wetland, China.” *Remote Sensing* 13 (8): 1595. doi:<https://doi.org/10.3390/rs13081595>. Multidisciplinary Digital Publishing Institute. [\[Crossref\]](#), [\[Web of Science ®\]](#), [\[Google Scholar\]](#)
69. Liao, Z., H. Binbin, A. I. Xingwen Quan, J. M. van Dijk, S. Qiu, and C. Yin. 2019. “Biomass Estimation in Dense Tropical Forest Using Multiple Information from Single-Baseline P-Band PolInSAR Data.” *Remote Sensing of Environment* 221 (February): 489–507. doi:<https://doi.org/10.1016/j.rse.2018.11.027>. [\[Crossref\]](#), [\[Google Scholar\]](#)
70. López-Serrano, P. M., J. J. Corral-Rivas, R. A. Díaz-Varela, J. G. Álvarez-González, and C. A. López-Sánchez. 2016. “Evaluation of Radiometric and Atmospheric Correction Algorithms for Aboveground Forest Biomass Estimation Using Landsat 5 TM Data.” *Remote Sensing* 8 (5): 369. doi:<https://doi.org/10.3390/rs8050369>. Multidisciplinary Digital Publishing Institute. [\[Crossref\]](#), [\[Web of Science ®\]](#), [\[Google Scholar\]](#)
71. Marselis, S. M., H. Tang, J. D. Armston, K. Calders, N. Labriere, and R. Dubayah. 2018. “Distinguishing Vegetation Types with Airborne Waveform Lidar Data in A Tropical Forest-Savanna Mosaic: A Case Study in Lopé National Park, Gabon.” *Remote Sensing of Environment* 216 (October): 626–634. doi:<https://doi.org/10.1016/J.RSE.2018.07.023>. [\[Crossref\]](#), [\[Google Scholar\]](#)
72. Mermoz, S., M. Réjou-Méchain, L. Villard, L. T. Thuy, V. Rossi, and S. Gourlet-Fleury. 2015. “Decrease of L-Band SAR Backscatter with Biomass of Dense Forests.” *Remote Sensing of Environment* 159: 307–317. doi:<https://doi.org/10.1016/j.rse.2014.12.019>. [\[Crossref\]](#), [\[Web of Science ®\]](#), [\[Google Scholar\]](#)
73. Messier, N., F. Cavayas, and A. Pierre. 2001. “Cartographie de L’occupation Du Sol En Milieu Urbain À Partir D’images Satellites de Haute Résolution Spatiale, Le Cas de Beijing (Chine).” Conference: Proc. 23th Can. Symp. Remote Sensing, p. 829–834. At: Ste-Foy, Québec, Canada. [\[Google Scholar\]](#)
74. Méthot, S., L. Blais, J. Gravel, I. Latrémouille, S. St-Pierre, and S. Vézeau. 2014. “Guide D’inventaire Et D’échantillonnage En Milieu Forestier.” Québec,

- gouvernement du Québec, Direction de l'aménagement et de l'environnement forestiers, 251. [\[Google Scholar\]](#)
75. Migolet, P., L. Coulibaly, H. Adegbidi, and E. Hervet. 2007. "Utilization of Neural Networks for the Estimation of Aboveground Forest Biomass from Ikonos Satellite Image and Multi-Source Geo-Scientific Data." *International Geoscience and Remote Sensing Symposium (IGARSS)*. doi:<https://doi.org/10.1109/IGARSS.2007.4423812>. [\[Google Scholar\]](#)
76. Migolet, P., K. Goïta, A. Ngomanda, and A. P. Mekui Biyogo. 2020. "Estimation of Aboveground Oil Palm Biomass in a Mature Plantation in the Congo Basin." *Forests* 11 (5): 544. doi:<https://doi.org/10.3390/f11050544>. Multidisciplinary Digital Publishing Institute. [\[Crossref\]](#), [\[Web of Science ®\]](#), [\[Google Scholar\]](#)
77. Migolet, P., and G. Kalifa. 2020. "Evaluation of FORMOSAT-2 and PlanetScope Imagery for Aboveground Oil Palm Biomass Estimation in a Mature Plantation in the Congo Basin." *Remote Sensing* 12 (18): 2926. doi:<https://doi.org/10.3390/rs12182926>. Multidisciplinary Digital Publishing Institute. [\[Crossref\]](#), [\[Web of Science ®\]](#), [\[Google Scholar\]](#)
78. Minh, H. T., E. N. Dinh, G. Vieilledent, D. McKey, and N. Baghdadi. 2018. "Potential Value of Combining ALOS PALSAR and Landsat-Derived Tree Cover Data for Forest Biomass Retrieval in Madagascar." *Remote Sensing of Environment* 213 (August): 206–214. doi:<https://doi.org/10.1016/j.rse.2018.04.056>. [\[Crossref\]](#), [\[Google Scholar\]](#)
79. Mitchard, E. T. A., S. S. Saatchi, L. J. T. White, K. A. Abernethy, K. J. Jeffery, S. L. Lewis, M. Collins, et al. 2012. "Mapping Tropical Forest Biomass with Radar and Spaceborne LiDAR in Lopé National Park, Gabon: Overcoming Problems of High Biomass and Persistent Cloud." *Biogeosciences* 9 (1): 179–191. doi:<https://doi.org/10.5194/bg-9-179-2012>. Copernicus GmbH. [\[Crossref\]](#), [\[Web of Science ®\]](#), [\[Google Scholar\]](#)
80. Moran, P. A. 1950. "A Test for the Serial Independence of Residuals." *Biometrika* 37 (1–2): 178–181. doi:<https://doi.org/10.2307/2332162>. Oxford University Press, Biometrika Trust. [\[Crossref\]](#), [\[PubMed\]](#), [\[Web of Science ®\]](#), [\[Google Scholar\]](#)
81. Moya, L., H. Zakeri, F. Yamazaki, W. Liu, E. Mas, and S. Koshimura. 2019. "3D Gray Level Co-Occurrence Matrix and Its Application to Identifying Collapsed Buildings." *ISPRS Journal of Photogrammetry and Remote Sensing* 149

- (March): 14–28.
doi:<https://doi.org/10.1016/j.isprsjprs.2019.01.008>. [Crossref], [Google Scholar]
82. Mulongoy, K. J., and A. Cung. 2011. “Les Approches D’atténuation Et D’adaptation Aux Changements Climatiques Fondées Sur Les Écosystèmes.” *Revue Juridique de L’environnement N° Spécial* 36 (1): 29–34. doi:<https://doi.org/10.3406/rjenv.2011.5605>. [Crossref], [Google Scholar]
83. Neumann, M., A. Moreno, V. Mues, S. Härkönen, M. Mura, O. Bouriaud, M. Lang, et al. 2016. “Comparison of Carbon Estimation Methods for European Forests.” *Forest Ecology and Management* 361:397–420. doi:<https://doi.org/10.1016/j.foreco.2015.11.016>. [Crossref], [Web of Science ®], [Google Scholar]
84. Ngomanda, A., N. L. Engone Obiang, J. Lebamba, Q. M. Mavouroulou, H. Gomat, G. S. Mankou, J. Loumeto, et al. 2014. “Site-Specific versus Pantropical Allometric Equations: Which Option to Estimate the Biomass of a Moist Central African Forest?” *Forest Ecology and Management* 312:1–9. <https://doi.org/10.1016/j.foreco.2013.10.029>. Elsevier B.V. [Crossref], [Web of Science ®], [Google Scholar]
85. Nichol, J. E., and M. L. R. Sarker. 2011. “Improved Biomass Estimation Using the Texture Parameters of Two High-Resolution Optical Sensors.” *IEEE Transactions on Geoscience and Remote Sensing* 49 (3): 930–948. doi:<https://doi.org/10.1109/TGRS.2010.2068574>. [Crossref], [Web of Science ®], [Google Scholar]
86. Ou, G., L. Yanyu, X. Hui, and G. Wang. 2019. “Improving Forest Aboveground Biomass Estimation of Pinus Densata Forest in Yunnan of Southwest China by Spatial Regression Using Landsat 8 Images.” *Remote Sensing* 11 (23): 2750. doi:<https://doi.org/10.3390/rs11232750>. Multidisciplinary Digital Publishing Institute. [Crossref], [Web of Science ®], [Google Scholar]
87. Pandit, S., S. Tsuyuki, and T. Dube. 2020. “Exploring the Inclusion of Sentinel-2 MSI Texture Metrics in above-Ground Biomass Estimation in the Community Forest of Nepal.” *Geocarto International* 35 (16): 1832–1849. doi:<https://doi.org/10.1080/10106049.2019.1588390>. Taylor & Francis. [Taylor & Francis Online], [Web of Science ®], [Google Scholar]
88. Panzou, L., G. Jopaul, J.-L. Doucet, J.-J. Loumeto, A. Biwole, S. Bauwens, and A. Fayolle. 2016. “Biomasse Et Stocks de Carbone Des Forêts Tropicales

- Africaines (Synthèse Bibliographique)." *BASE*. doi:<https://doi.org/10.25518/1780-4507.13232>. [Crossref], [Google Scholar]
89. Papathanassiou, K. P., and S. R. Cloude. 2001. "Single-Baseline Polarimetric SAR Interferometry." *IEEE Transactions on Geoscience and Remote Sensing* 39 (11): 2352–2363. doi:<https://doi.org/10.1109/36.964971>. [Crossref], [Web of Science ®], [Google Scholar]
90. Park, S., S.-Y. Hamm, H.-T. Jeon, and J. Kim. 2017. "Evaluation of Logistic Regression and Multivariate Adaptive Regression Spline Models for Groundwater Potential Mapping Using R and GIS." *Sustainability* 9 (7): 1157. doi:<https://doi.org/10.3390/su9071157>. [Crossref], [Web of Science ®], [Google Scholar]
91. Picard, N., G. P. Javier, L. B. Gamarra, and A. Branthomme. 2018. "Plot-Level Variability in Biomass for Tropical Forest Inventory Designs." *Forest Ecology and Management* 430 (December): 10–20. doi:<https://doi.org/10.1016/J.FORECO.2018.07.052>. [Crossref], [Google Scholar]
92. Picard, N., L. Saint-André, and M. Henry. 2012. "Manuel de Construction D'équations Allométriques Pour L'estimation Du Volume Et La Biomasse Des Arbres/De La Mesure de Terrain À La Prédiction." https://www.google.com/search?q=FAO+biomasse+equation&rlz=1C1GCEB_enCA887CA887&oq=FAO+biomasse+equation&aqs=chrome.69i57j33i160.8955j0j7&sourceid=chrome;UTF-8. [Google Scholar]
93. Ploton, P., N. Barbier, P. Couteron, C. M. Antin, N. Ayyappan, N. Balachandran, N. Barathan, et al. 2017. "Toward a General Tropical Forest Biomass Prediction Model from Very High Resolution Optical Satellite Images." *Remote Sensing of Environment* 200 (October): 140–153. doi:<https://doi.org/10.1016/J.RSE.2017.08.001>. [Crossref], [Google Scholar]
94. Ploton, P., F. Mortier, M. Réjou-Méchain, N. Barbier, N. Picard, V. Rossi, C. Dormann, et al. 2020. "Spatial Validation Reveals Poor Predictive Performance of Large-Scale Ecological Mapping Models." *Nature Communications* 11 (1): 4540. doi:<https://doi.org/10.1038/s41467-020-18321-y>. [Crossref], [PubMed], [Web of Science ®], [Google Scholar]
95. Ploton, P., R. Pélassier, C. Proisy, T. Flavenot, N. Barbier, S. N. Rai, and P. Couteron. 2012. "Assessing Aboveground Tropical Forest Biomass Using Google Earth Canopy Images." *Ecological Applications: A Publication of the*

- Ecological Society of America.* doi:<https://doi.org/10.1890/11-1606.1>. [Crossref], [PubMed], [Web of Science ®], [Google Scholar]
96. Pourshamsi, M., M. Garcia, M. Lavalle, and H. Balzter. 2018. “A Machine-Learning Approach to PolInSAR and LiDAR Data Fusion for Improved Tropical Forest Canopy Height Estimation Using NASA AfriSAR Campaign Data.” *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 11 (10): 3453–3463.
 doi:<https://doi.org/10.1109/JSTARS.2018.2868119>. [Crossref], [Web of Science ®], [Google Scholar]
97. Pourshamsi, M., J. Xia, N. Yokoya, M. Garcia, M. Lavalle, E. Pottier, and H. Balzter. 2021. “Tropical Forest Canopy Height Estimation from Combined Polarimetric SAR and LiDAR Using Machine-Learning.” *ISPRS Journal of Photogrammetry and Remote Sensing* 172 (February): 79–94.
 doi:<https://doi.org/10.1016/j.isprsjprs.2020.11.008>. [Crossref], [Google Scholar]
98. Pramila, P. V., and V. Mahesh. 2015. “Comparison of Multivariate Adaptive Regression Splines and Random Forest Regression in Predicting Forced Expiratory Volume in One Second.” *International Journal of Bioengineering and Life Sciences* 9 (4): 338–342. [Google Scholar]
99. Proisy, C., P. Couteron, and F. Fromard. 2007. “Predicting and Mapping Mangrove Biomass from Canopy Grain Analysis Using Fourier-Based Textural Ordination of IKONOS Images.” *Remote Sensing of Environment* 109 (3): 379–392.
 doi:<https://doi.org/10.1016/j.rse.2007.01.009>. [Crossref], [Web of Science ®], [Google Scholar]
100. Reichstein, M., and N. Carvalhais. 2019. “Aspects of Forest Biomass in the Earth System: Its Role and Major Unknowns.” *Surveys in Geophysics* 40 (4): 693–707. doi:<https://doi.org/10.1007/s10712-019-09551-x>. [Crossref], [Web of Science ®], [Google Scholar]
101. Réjou-Méchain, M. H. C. M.-L., M. Detto, S. C. Thomas, T. Le Toan, S. S. Saatchi, J. S. Barreto-Silva, et al. 2014. “Local Spatial Structure of Forest Biomass and Its Consequences for Remote Sensing of Carbon Stocks.” *Biogeosciences* 11 (23): 6827–6840. doi:<https://doi.org/10.5194/bg-11-6827-2014>. Copernicus GmbH. [Crossref], [Web of Science ®], [Google Scholar]
102. Réjou-Méchain, M., B. Tymen, L. Blanc, T. R. Sophie Fauset, A. M. Feldpausch, O. L. Phillips, H. Richard, and J. Chave. 2015. “Using Repeated Small-Footprint LiDAR Acquisitions to Infer Spatial and Temporal Variations of a

- High-Biomass Neotropical Forest.” *Remote Sensing of Environment* 169: 93–101. doi:<https://doi.org/10.1016/j.rse.2015.08.001>. [Crossref], [Web of Science ®], [Google Scholar]
- 103.** Saatchi, S. S., J. Chave, N. Labriere, N. Barbier, M. Réjou-Méchan, A. Ferraz, and S. Tao. 2019. “AfriSAR: Aboveground Biomass for Lope, Mabounie, Mondah, and Rabi Sites, Gabon.” ORNL Distributed Active Archive Center, 0.575648 MB. doi:<https://doi.org/10.3334/ORNLDAAAC/1681>. [Google Scholar]
- 104.** Saatchi, S. S., N. L. Harris, S. Brown, M. Lefsky, E. T. A. Mitchard, W. Salas, B. R. Zutta, et al. 2011. “Benchmark Map of Forest Carbon Stocks in Tropical Regions across Three Continents.” *Proceedings of the National Academy of Sciences* 108 (24): 9899–9904. doi:<https://doi.org/10.1073/pnas.1019576108>. [Crossref], [PubMed], [Web of Science ®], [Google Scholar]
- 105.** Sannier, C., L.-V. Fichet, and K. M. Etienne Massard. 2014. “Using the Regression Estimator with Landsat Data to Estimate Proportion Forest Cover and Net Proportion Deforestation in Gabon.” *Remote Sensing of Environment* 151: 138–148. doi:<https://doi.org/10.1016/j.rse.2013.09.015>. [Crossref], [Web of Science ®], [Google Scholar]
- 106.** Scharlemann, J. P. W., E. V. J. Tanner, R. Hiederer, and V. Kapos. 2014. “Global Soil Carbon: Understanding and Managing the Largest Terrestrial Carbon Pool.” *Carbon Management* 5 (1): 81–91. doi:<https://doi.org/10.4155/cmt.13.77>. [Taylor & Francis Online], [Web of Science ®], [Google Scholar]
- 107.** Silva, B. L. B. D., E. Costa, F. F. D. S. Binotti, C. G. Sabin Benett, and A. G. Da Silva. 2018. “Growth and Quality of Garcinia Humilis Seedlings as a Function of Substrate and Shading Level.” *Pesquisa Agropecuária Tropical* 48 (4): 407–413. doi:<https://doi.org/10.1590/1983-40632018v48s3500>. [Crossref], [Web of Science ®], [Google Scholar]
- 108.** Singh, M., D. Evans, D. Friess, B. Tan, and C. Nin. 2015. “Mapping Above-Ground Biomass in a Tropical Forest in Cambodia Using Canopy Textures Derived from Google Earth.” *Remote Sensing* 7 (5): 5057–5076. doi:<https://doi.org/10.3390/rs70505057>. [Crossref], [Web of Science ®], [Google Scholar]

- 109.** Singh, M., Y. Malhi, and S. Bhagwat. 2014. “Evaluating Land Use and Aboveground Biomass Dynamics in an Oil Palm–Dominated Landscape in Borneo Using Optical Remote Sensing.” *Journal of Applied Remote Sensing* 8 (1): 083695. doi:<https://doi.org/10.1117/1.JRS.8.083695>. International Society for Optics and Photonics. [\[Crossref\]](#), [\[Google Scholar\]](#)
- 110.** Sinha, S., C. Jeganathan, L. K. Sharma, and M. S. Nathawat. 2015. “A Review of Radar Remote Sensing for Biomass Estimation.” *International Journal of Environmental Science and Technology* 12 (5): 1779–1792. doi:<https://doi.org/10.1007/s13762-015-0750-0>. [\[Crossref\]](#), [\[Web of Science ®\]](#), [\[Google Scholar\]](#)
- 111.** Sun, G. K., Z. Jon Ranson, G. Z. Zhang, P. Montesano, and D. Kimes. 2011. “Forest Biomass Mapping from Lidar and Radar Synergies.” *Remote Sensing of Environment* 115 (11): 2906–2916. doi:<https://doi.org/10.1016/j.rse.2011.03.021>. DESDynI VEG-3D Special Issue. [\[Crossref\]](#), [\[Web of Science ®\]](#), [\[Google Scholar\]](#)
- 112.** Tapamo, H., M. Blaise Ngonmang, P. Couteron, and O. Monga. 2014. “Linear Vs Non-Linear Learning Methods A Comparative Study for Forest above Ground Biomass, Estimation from Texture Analysis of Satellite Images.” *Arima* 13 (November): 114–131. [\[Google Scholar\]](#)
- 113.** Urbazaev, M., C. Thiel, F. Cremer, R. Dubayah, M. Migliavacca, M. Reichstein, and C. Schmullius. 2018. “Estimation of Forest Aboveground Biomass and Uncertainties by Integration of Field Measurements, Airborne LiDAR, and SAR and Optical Satellite Data in Mexico.” *Carbon Balance and Management* 13 (1): 5. doi:<https://doi.org/10.1186/s13021-018-0093-5>. [\[Crossref\]](#), [\[PubMed\]](#), [\[Google Scholar\]](#)
- 114.** Villard, L., T. L. Toan, D. H. T. Minh, S. Mermoz, and A. Bouvet. 2016. “Biomasse Des Forêts Par Télédétection Radar. Chap. 9.” In *Observation Des Surfaces Continentales Par Télédétection I; Agriculture Et Forêt*, edited by N. Baghdadi and M. Zribi, Vol. 1, 349–404. Londres: ISTE Editions . <https://halldulivre.com/livre/9781784051587-observation-des-surfaces-continentales-par-teledetection-i-agriculture-et-foret-nicolas-baghdadi-mehrez-zribi/>. [\[Google Scholar\]](#)
- 115.** Wade, A. M., D. D. Richter, V. P. Medjibe, A. R. Bacon, P. R. Heine, L. J. T. White, and J. R. Poulsen. 2019. “Estimates and Determinants of Stocks of Deep Soil Carbon in Gabon, Central Africa.” *Geoderma* 341 (May): 236–248.

doi:<https://doi.org/10.1016/J.GEODERMA.2019.01.004>. [Crossref], [Google Scholar]

- 116.** Xue, J., and B. Su. 2017. "Significant Remote Sensing Vegetation Indices: A Review of Developments and Applications." *Journal of Sensors* 2017: e1353691. doi:<https://doi.org/10.1155/2017/1353691>. [Crossref], [Web of Science ®], [Google Scholar]
- 117.** Yang, X., S. Blagodatsky, F. Liu, P. Beckschäfer, X. Jianchu, and G. Cadisch. 2017. "Rubber Tree Allometry, Biomass Partitioning and Carbon Stocks in Mountainous Landscapes of Sub-Tropical China." *Forest Ecology and Management* 404 (November): 84–99. doi:<https://doi.org/10.1016/J.FORECO.2017.08.013>. [Crossref], [Google Scholar]
- 118.** Zhang, W., and T. C. G. Anthony. 2016. "Multivariate Adaptive Regression Splines and Neural Network Models for Prediction of Pile Drivability." *Geoscience Frontiers* 7 (1): 45–52. doi:<https://doi.org/10.1016/j.gsf.2014.10.003>. [Crossref], [Web of Science ®], [Google Scholar]
- 119.** Zhang, G., R. Sangram Ganguly, M. A. Nemani, C. M. White, H. Hashimoto, W. Wang, S. Saatchi, Y. Yifan, and R. B. Myneni. 2014. "Estimation of Forest Aboveground Biomass in California Using Canopy Height and Leaf Area Index Estimated from Satellite Data." *Remote Sensing of Environment* 151 (August): 44–56. doi:<https://doi.org/10.1016/j.rse.2014.01.025>. [Crossref], [Google Scholar]
- 120.** Zolkos, S. G., S. J. Goetz, and R. Dubayah. 2013. "A Meta-Analysis of Terrestrial Aboveground Biomass Estimation Using Lidar Remote Sensing." *Remote Sensing of Environment* 128 (January): 289–298. doi:<https://doi.org/10.1016/j.rse.2012.10.017>. [Crossref], [Google Scholar]

Declaration of data availability

The data that support the conclusions of this study are freely available in

[4TU.ResearchData, à [http://doi.org/\[10.4121 / 14058188\]](http://doi.org/[10.4121 / 14058188])] or

<https://figshare.com/s/22d0972c7fb9547f277d>, Reference number [14058188].

Appendices 7

Appendix 7.1: Data used to train models created in the study

Sample plot number	Window size used to generate the FOTO indices (m) in the near-infrared band of SPOT-7								Window size used to produce the GLCM texture indices on the red-band of SPOT-7				Variable derived from radar data	Variable derived from LiDAR	Tree parameters in the field					
	100		125		175		5×5													
	PC1	PC2	PC	PC1	PC2	PC3	PC1	PC2	PC3	Mean	Entropy	Correlation	Contrast	Canopy surface height (H_R) (m)	Backscatter coefficient (σ^0) (dB)	Median canopy height (RH50) (m)	Modeled maximum height (H_T) (m)	D (cm)	Tree number (Na)	Total dry above-ground biomass (AGB) ($t \text{ ha}^{-1}$)
1	-3.74	0.37	-0.81	-1.13	1.20	2.56	-3.06	1.27	-0.06	4.32	2.26	0.57	12.88	26.18	-11.96	35.00	19.9	23.08	41.00	274.67
2	2.00	-0.83	1.72	-2.39	1.34	1.59	-1.16	4.31	-0.82	7.08	2.39	0.73	11.17	47.01	-11.79	34.85	22.9	28.93	35.00	252.91
3	-4.20	-0.31	1.72	-0.05	1.70	2.29	-1.16	4.31	-0.82	12.11	2.21	0.97	4.15	43.32	-11.25	45.10	24.6	37.17	34.00	578.96
4	-4.20	-0.31	-1.65	-0.05	1.70	2.29	-1.16	4.31	0.24	8.59	2.52	0.87	8.68	44.61	-11.47	38.98	24.4	33.48	37.00	422.75
5	-2.16	2.17	2.93	-0.37	-1.50	-1.44	-1.71	-0.08	-0.02	9.66	2.41	0.92	6.79	23.54	-12.50	20.06	20.8	23.47	39.00	215.71
6	-1.39	1.12	1.43	-3.21	0.32	-0.75	-3.30	3.12	0.12	8.86	2.42	0.92	6.86	21.14	-12.99	12.25	19.4	20.28	45.00	129.11
7	-3.21	1.79	2.98	-1.92	1.36	1.72	-2.08	3.29	-0.27	6.96	2.10	0.92	4.35	24.18	-12.30	18.50	19.4	20.42	59.00	154.38
8	3.11	-1.38	0.91	3.96	-1.29	0.55	-3.77	-0.23	0.05	8.08	2.31	0.92	5.55	27.82	-12.52	8.56	16.4	15.50	39.00	53.94
9	-1.11	0.62	1.70	3.17	-1.05	2.57	3.75	1.13	-0.98	8.29	2.30	0.91	6.49	31.38	-11.63	4.99	19.4	21.68	40.00	256.61
10	-0.14	-1.39	-0.25	3.17	-1.05	2.57	3.75	1.13	-0.98	7.10	2.36	0.80	8.37	35.97	-12.21	14.19	18.4	18.96	45.00	127.38
11	-3.54	1.35	0.30	1.65	-0.76	1.16	-2.87	1.89	0.12	9.80	2.45	0.93	6.53	22.94	-11.45	14.40	18.6	19.53	55.00	188.30
12	-2.50	0.23	0.18	-1.46	-0.77	-2.61	2.83	1.27	-0.06	4.41	2.14	0.72	6.80	34.15	-11.81	16.02	18.3	18.53	41.00	88.58

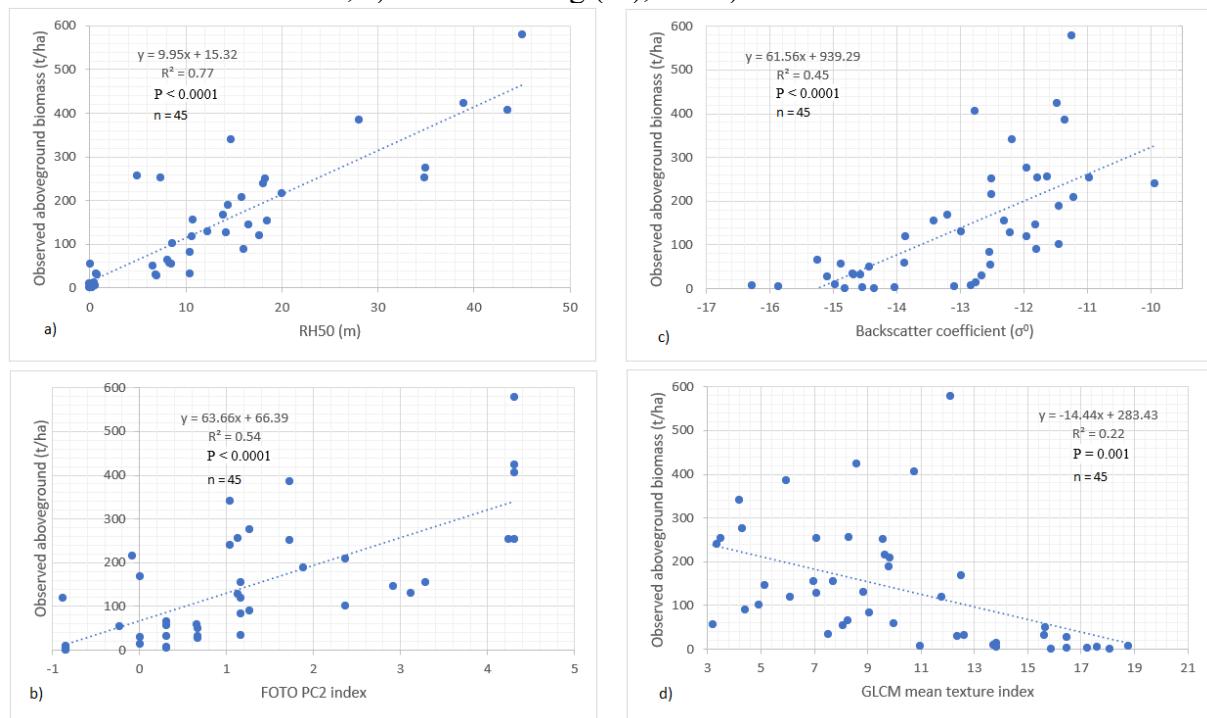
13	-2.67	1.55	1.33	2.75	-1.06	1.09	0.26	0.67	0.19	15.68	2.56	0.96	6.65	19.65	-14.44	6.54	13.7	16.36	26.00	49.80
14	-2.67	1.95	1.33	2.75	-1.06	1.09	0.26	0.67	-0.22	12.64	2.53	0.93	7.51	19.61	-14.67	6.84	11.9	11.71	48.00	30.50
15	-2.67	1.55	1.33	2.75	-1.06	1.09	0.26	0.67	-0.22	16.47	2.37	0.99	3.35	18.22	-15.09	7.01	12.8	13.55	27.00	27.75
16	-3.23	0.98	0.01	-0.82	1.03	2.57	-2.51	1.16	-0.20	9.08	2.43	0.90	7.73	31.02	-12.54	10.44	13.4	16.25	33.00	82.38
17	-3.23	0.98	0.01	-0.82	1.03	2.57	-2.51	1.16	-0.20	7.52	2.38	0.78	10.59	22.68	-14.69	10.40	12.7	13.93	35.00	32.78
18	-3.23	1.15	0.91	-0.82	1.03	2.57	-2.51	1.16	-0.20	7.71	2.19	0.91	6.93	27.49	-13.42	10.72	13.4	16.08	66.00	155.60
19	-3.23	1.15	0.91	-0.82	1.03	2.57	-2.51	1.16	-0.20	11.77	2.48	0.95	6.35	21.52	-13.86	10.65	13.7	17.21	34.00	117.71
20	-0.23	1.42	2.69	-1.33	-0.65	-1.08	-2.32	2.91	-0.74	5.15	2.16	0.72	7.28	25.16	-11.82	16.52	13.6	16.29	61.00	145.23
21	-1.02	2.10	2.02	-0.77	2.11	2.84	-3.40	0.32	0.80	13.83	2.40	0.95	6.02	13.14	-13.09	0.60	10.6	9.43	13.00	5.01
22	2.13	-0.70	1.47	-0.77	2.11	2.84	-3.40	0.32	0.80	15.61	2.51	0.97	4.78	18.06	-14.57	0.65	12.6	13.73	19.00	31.38
23	2.13	0.78	1.47	-1.77	1.31	0.99	-3.40	0.32	0.80	8.27	2.39	0.85	7.17	28.13	-15.25	8.07	12.4	13.89	38.00	64.50
24	-2.08	0.81	1.64	-1.77	1.31	0.99	-3.40	0.32	0.80	10.97	2.20	0.96	3.38	24.68	-12.83	0.19	10.5	9.40	19.00	7.64
25	-3.22	0.78	0.09	-1.77	1.31	0.99	-3.40	0.32	0.80	3.22	1.87	0.61	7.23	28.22	-14.88	0.06	11.3	11.96	31.00	55.00
26	12.23	7.40	-1.81	-2.21	2.36	0.62	-1.82	0.01	0.38	13.84	2.58	0.96	5.73	10.81	-12.75	0.48	11.1	10.42	22.00	12.43
27	12.23	7.40	0.94	-2.21	2.36	0.62	-1.82	0.01	0.38	12.52	2.60	0.96	4.98	13.07	-13.21	13.88	12.8	15.41	43.00	168.07
28	-0.87	0.52	-1.42	-2.13	2.01	1.08	2.41	-0.87	0.52	6.11	2.31	0.73	8.70	15.65	-11.95	17.68	12.8	14.36	82.00	119.38
29	-1.85	-0.93	0.10	-3.18	0.72	-0.78	-3.43	2.37	0.26	9.82	2.47	0.91	9.12	29.88	-11.22	15.80	13.5	15.62	115.00	207.38
30	1.87	-2.21	0.66	-2.79	0.80	-0.39	1.43	-0.85	-0.23	16.46	2.53	0.98	4.49	7.88	-14.54	0.26	9.1	6.65	10.00	1.24
31	2.40	-1.09	-0.86	-2.09	0.53	-0.01	1.43	-0.85	-0.23	17.24	2.53	0.98	5.85	7.71	-14.04	0.20	10.4	8.81	9.00	2.55
32	1.87	-2.21	0.66	-2.79	0.80	-0.39	1.43	-0.85	-0.23	17.61	2.63	0.98	7.01	7.23	-15.87	0.03	9.0	6.48	27.00	3.49
33	2.40	-1.09	-0.86	-2.09	0.53	-0.01	1.43	-0.85	0.45	18.78	2.50	0.99	4.72	8.08	-16.28	0.14	10.4	9.24	15.00	7.04
34	2.40	-1.09	-0.86	-2.09	0.53	-0.01	1.43	-0.85	0.45	15.90	2.53	0.98	4.97	8.00	-14.82	0.20	8.6	5.95	11.00	1.05
35	12.23	7.40	-1.81	-0.55	0.71	0.63	-1.82	0.01	0.38	12.38	2.67	0.95	5.59	15.02	-12.67	0.75	13.1	14.57	25.00	29.18
36	7.58	5.91	0.84	15.05	-0.77	-2.29	-3.49	0.66	0.37	9.98	2.21	0.93	5.89	27.76	-13.88	8.35	12.5	12.87	95.00	57.23
37	-1.41	-1.30	0.80	-2.44	1.94	0.72	-2.67	1.73	-0.16	9.59	2.52	0.92	6.36	25.52	-12.51	18.25	13.0	15.28	78.00	250.29
38	-1.41	-1.30	-1.60	-2.44	1.94	0.72	-2.67	1.73	-0.16	5.95	2.23	0.73	8.25	22.29	-11.35	28.05	13.2	15.84	88.00	384.82
39	-2.24	0.68	1.11	-2.96	0.88	-0.07	2.77	1.04	1.08	4.19	2.07	0.62	9.10	29.27	-12.18	14.75	19.7	22.12	52.00	340.59

40	-1.92	1.57	2.04	-0.64	1.17	2.68	-4.01	1.04	0.55	3.35	1.96	0.45	13.88	21.67	-9.94	18.09	18.2	19.43	50.00	239.56
41	2.40	-1.09	2.65	-2.09	0.53	-0.01	1.43	-0.85	0.79	13.73	2.50	0.93	8.31	8.96	-14.97	0.01	9.8	7.84	42.00	9.41
42	-2.79	0.94	0.76	4.56	-3.50	1.52	-1.16	4.31	0.33	10.74	2.37	0.92	8.45	37.00	-12.78	43.52	24.2	34.14	32.00	406.37
43	2.40	-1.09	-0.86	-2.09	0.53	-0.01	1.43	-0.85	-0.23	18.10	2.55	0.98	5.48	7.70	-14.36	0.00	8.8	6.19	8.00	0.71
44	-3.26	1.84	0.46	-1.99	1.28	0.95	-2.22	4.24	-1.09	3.51	1.91	0.61	8.07	23.90	-10.97	7.41	13.7	17.47	57.00	252.31
45	-1.85	1.97	-0.87	-3.18	0.72	-0.78	-3.43	2.37	0.26	4.93	2.00	0.71	6.23	25.40	-11.45	8.62	14.9	19.93	26.00	101.64

Appendix 7.2: Data used to validate the models developed and compare the AGB of the study versus the existing maps

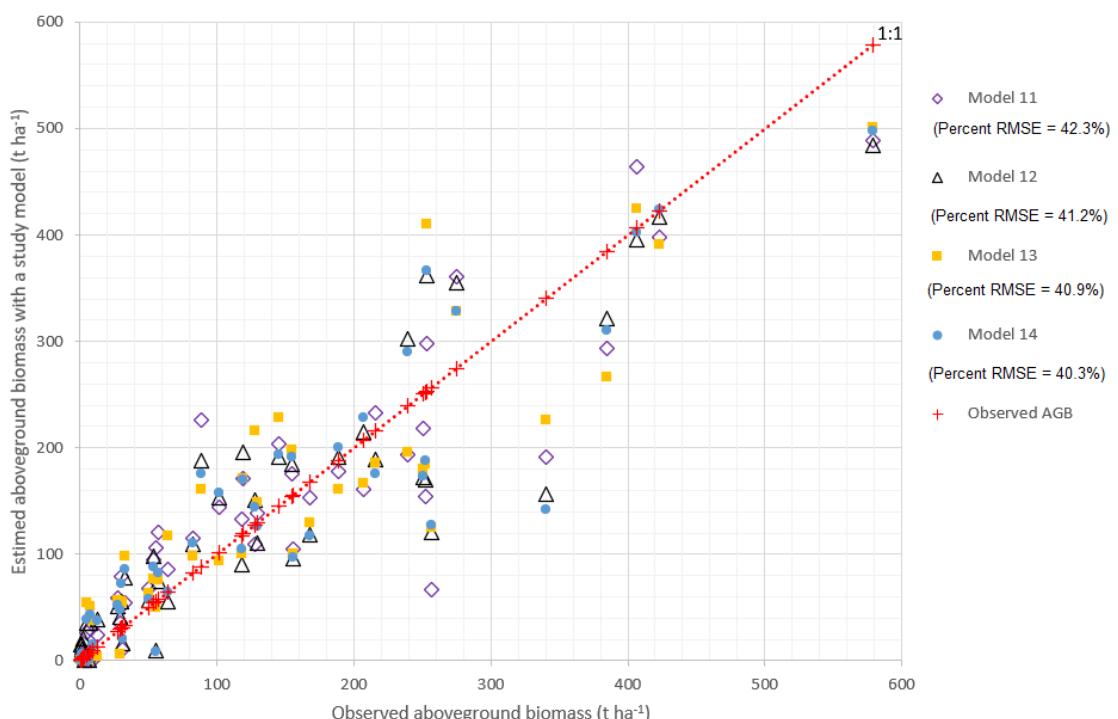
Sample plot number	Window size used to generate the FOTO indices (m) in the near-infrared band of SPOT-7									Window size used to produce the GLCM texture indices on the red-band of SPOT-7				Variable derived from radar data	Variable derived from LiDAR	Tree parameters in the field				
	100			125			175			5×5						Modeled maximum height (H_T) (m)		D (cm)	Tree number (Na)	Total dry above-ground biomass (AGB) (t ha ⁻¹)
	PC1	PC2	PC3	PC1	PC2	PC3	PC1	PC2	PC3	Mean	Entropy	Correlation	Contrast	Canopy surface height (H_R) (m)	Backscatter coefficient (σ^0) (dB)	Median canopy height (RH50) (m)				
46	-3.74	0.37	0.11	-1.13	1.20	2.56	-3.06	1.27	-0.06	3.76	1.92	0.65	7.73	32.75	-12.04	31.58	19.9	23.19	44.00	239.89
47	-2.06	2.49	1.98	9.80	-2.86	-0.45	-1.16	4.31	0.33	10.68	2.24	0.96	5.26	34.40	-10.22	43.36	22.9	35.07	35.00	475.68
48	-1.39	2.17	2.93	-0.37	-1.50	-1.44	-3.30	3.12	0.12	10.45	2.48	0.91	7.15	20.17	-11.82	6.07	24.6	20.46	57.00	129.34
49	-3.21	1.79	0.38	-3.21	0.32	-0.75	-3.30	3.12	0.12	7.74	2.32	0.88	7.53	19.08	-12.55	11.05	24.4	19.28	58.00	148.64
50	3.11	-1.38	0.91	-3.05	2.24	0.79	6.83	0.85	-0.63	4.56	1.89	0.53	11.70	31.41	-12.54	13.33	20.8	19.12	47.00	127.97
51	0.15	1.42	1.60	-2.82	2.31	0.59	-2.32	2.91	-0.74	9.31	2.13	0.88	5.77	21.60	-12.67	4.04	19.4	18.24	40.00	111.48
52	-1.85	-0.93	-0.87	-3.18	0.72	-0.78	-3.43	2.37	0.26	4.73	1.99	0.68	6.75	32.80	-12.11	10.06	19.4	20.10	37.00	129.54
53	-0.87	-1.07	-1.42	7.58	0.39	-0.45	-3.78	-0.10	0.52	14.92	2.51	0.98	5.01	10.28	-13.27	4.03	16.4	13.10	40.00	37.31
54	-3.25	0.79	-0.63	11.16	-6.19	0.34	-3.49	0.66	0.37	9.88	2.38	0.90	6.71	28.22	-12.59	17.74	18.4	22.78	36.00	155.09
55	13.92	5.91	-5.37	15.05	-0.77	-2.29	-3.49	0.66	0.37	8.84	2.13	0.92	7.39	32.52	-12.91	17.75	18.6	16.38	66.00	129.43
56	-1.41	-1.30	0.80	-2.44	1.94	0.72	-2.67	1.73	-0.16	5.67	2.14	0.60	13.34	26.73	-12.58	17.69	18.3	13.80	83.00	146.46
57	-2.26	1.80	1.36	-1.94	0.64	0.34	3.62	1.06	-0.52	3.07	1.64	0.58	6.73	50.47	-11.82	32.14	20.1	23.71	59.00	378.88
58	-2.84	0.62	1.70	3.96	-1.29	0.55	-3.77	-0.23	0.05	10.44	2.53	0.92	7.04	21.92	-11.51	1.63	16.6	16.45	33.00	60.84
59	-2.86	0.04	-0.38	-3.91	0.58	-1.02	0.83	-2.18	0.04	7.66	2.31	0.76	8.29	20.72	-12.09	17.53	12.9	14.75	82.00	180.69
60	-2.86	0.35	-0.38	-3.91	0.58	-1.02	0.83	-2.18	0.04	4.81	2.24	0.74	6.52	19.17	-10.47	14.08	14.0	18.14	40.00	169.42
61	12.23	7.40	0.94	-0.55	0.71	0.63	-1.82	0.01	0.38	12.07	2.52	0.93	7.48	14.62	-13.39	12.65	14.3	18.04	56.00	140.25
62	-3.13	1.95	0.80	2.75	-1.06	1.09	0.26	3.63	0.19	15.54	2.37	0.99	3.45	18.57	-13.67	6.17	11.7	11.69	18.00	9.57

Appendix 7.3. Scatter plots between observed AGB and explanatory variables a) RH50, b) FOTO PC2 index, c) Backscattering (σ^0), and d) GLCM mean texture index

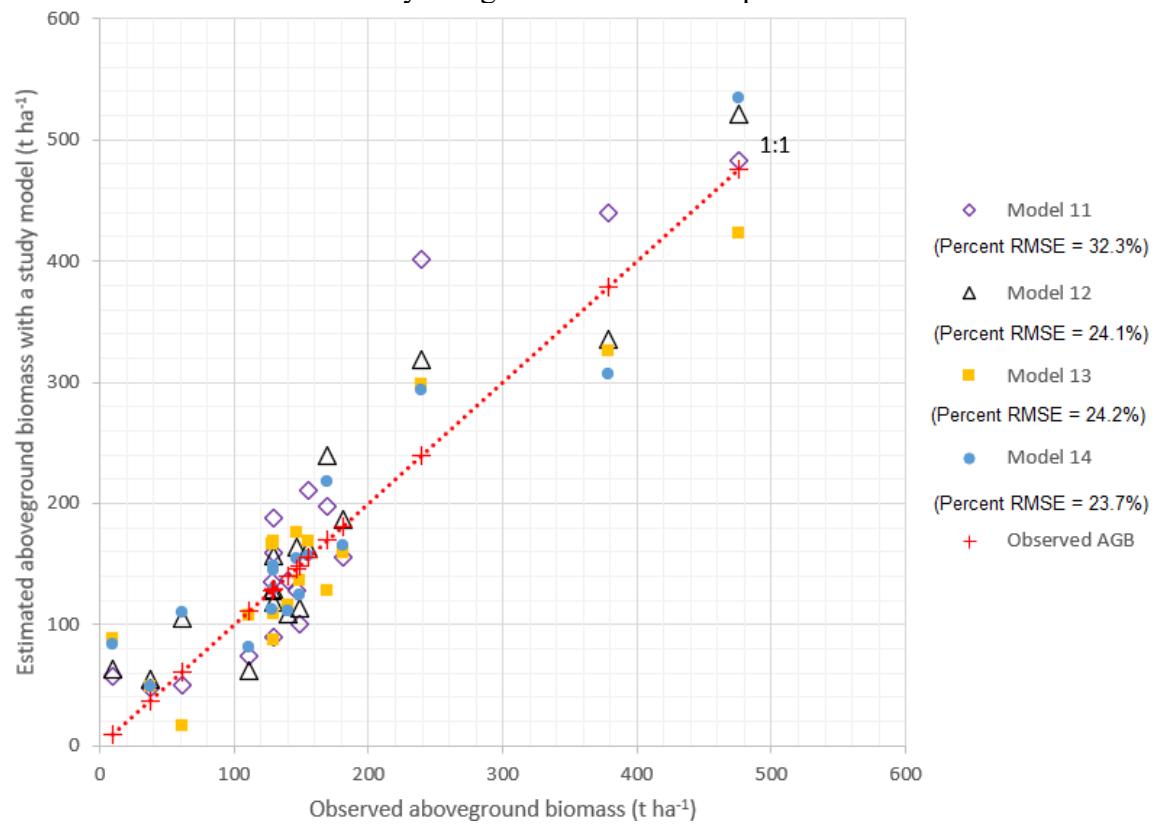


Appendix 7.4. Distributions of AGBs observed and estimated with some of the best models of the study

Appendix 7.4.1 Distributions of AGBs observed and estimated with 5 best models of the study using the data of the explanatory variables of the training sample plots. The dotted red line represents the 1:1 correspondence line.



Appendix 7.4.2. Distributions of the observed and estimated AGBs with the 5 best models of the study using the validation independent data



CHAPITRE 8. Analyse de la dynamique de la biomasse due au remplacement des forêts par les palmeraies

Les trois chapitres antérieurs traitent du développement et de la validation deux approches d'estimation de BA des forêts et des palmiers à huile. Elles estiment la BA 1) des palmeraies avec les équations de loi puissance à partir des données de terrain et 2) des forêts ou des palmiers à huile avec MARS à l'aide des données de télédétection (optique, LiDAR et/ou PolInSAR). Dans le présent chapitre, l'évaluation des pertes et des gains des BA dus au remplacement des forêts par les palmeraies du Bassin du Congo est présentée. Ce chapitre porte plus précisément sur le remplacement de plusieurs types de forêts (matures, secondaires, sols nus ou forêts en repousse) par des palmeraies de 35 ans (des terres fermes, inondables ou fermes et inondables). Les résultats des travaux de ce chapitre sont importants dans le Bassin du Congo pour comprendre l'influence potentielle que pourrait avoir le remplacement des forêts. Ils contribueront à la mise à disposition du public d'informations et d'un outil scientifique utile à une meilleure planification de l'utilisation de l'occupation des terres et à la lutte contre les changements climatiques.

8.1 Introduction

L'analyse de la dynamique de la biomasse aérienne sèche totale par le remplacement des forêts en palmeraies permet de connaître la localisation de zones à fortes et à faibles potentiels de BA pour une utilisation durable et harmonieuse de l'occupation des sols et pour une planification optimisée de la lutte contre les changements climatiques. L'évaluation de la dynamique des BA des arbres et des palmiers à huile repose sur les estimations des BA de ces deux végétaux chlorophylliens. Pour comparer les BA des arbres et des palmiers à huile, l'âge est un paramètre important. Certains types de forêts (ex : tropicales) dans le Bassin du Congo n'ont malheureusement pas souvent des âges bien connus en raison du manque de leur suivi régulier et de l'archivage des travaux de gestion forestière. Des références en lien avec les palmiers à huile (ex. la BA moyenne de leur durée de vie) sont alors usuellement utilisées. Les différentes formations végétales de ces deux végétaux sur le territoire étudié sont aussi nécessaires pour comparer leurs BA. Cette approche permet d'identifier les informations détaillées sur la dynamique de la BA de plusieurs formations végétales des forêts et des palmiers à huile. Ces informations sont souvent inconnues sur diverses forêts tropicales, notamment dans le Bassin du Congo (ex. au Gabon). La difficulté d'acquisition des données de terrain et de télédétection est l'une des raisons principales à la limitation de la production de ces informations. Celle-ci se justifie par diverses raisons techniques, humaines et financières. Les valeurs moyennes,

maximales et minimales des BA des cartes sont souvent utilisées pour comparer les BA des arbres et des palmiers à huile (Ramdani et Masateru, 2013; Kho et Rudbeck-Jepsen, 2015). La présente étude tire son originalité première de l'emploi des données des BA de palmiers et de arbres du Bassin du Congo obtenues par télédétection au cours des études de Migolet et Goïta, (2020) et Migolet *et al.*, 2021 (en révision dans la revue *GIScience and Remote Sensing*). Cette originalité repose aussi principalement sur le calcul des valeurs des pertes et des gains des BA dus aux remplacements des forêts par les palmeraies. Celle-ci s'appuie aussi sur la réalisation de la première carte de BA sur les sites de conversion et de non-conversion des forêts. Le présent chapitre est organisé selon le schéma classique. L'introduction est présentée à la section 8.1. La méthodologie proposée est mise en évidence à la section 8.2. Les résultats et la discussion sont mis en lumière à la section 8.3 et la conclusion est présentée à la section 8.4.

8.2 Méthode

L'approche de l'objectif 3 évalue la dynamique de la biomasse due aux remplacements des forêts par les palmeraies. Cette évaluation a reposé sur les cartes de BA des palmiers à huiles et des forêts produites avec les méthodologies mises en œuvre pour atteindre les objectifs 2 (section 4.1) et 3 (section 4.2) de la thèse. La carte de BA de la forêt a été rééchantillonnée à la même résolution spatiale que la carte de BA des forêts ($30,8\text{ m} \times 30,8\text{ m}$). Les différents types de cartes de BA des forêts et des palmiers à huile ont ensuite été produites. Ces cartes représentent les BA des types de forêt suivants : forêts matures, forêts secondaires vieilles, forêts secondaires jeunes-adultes ou inondables et sols nus ou des forêts en repousse. Elles représentent aussi les BA des palmiers à huile sur une terre ferme, sur une terre inondable et sur une terre ferme et inondable. Des valeurs moyennes, minimales et maximales des BA ont ensuite été déterminées par type de palmier à huile et de forêt à partir de chaque carte de BA. Les valeurs des BA des forêts ont par la suite été comparées aux valeurs des BA des palmeraies. Cette comparaison a permis de déterminer les pertes et les gains des BA des forêts dus aux remplacements des palmeraies. Pour déterminer ces pertes et ces gains, le taux de diminution ou d'augmentation de la biomasse par conversion des occupations des terres a été calculé par le rapport de la différence des BA des végétaux à installer (ex. palmiers) et à extraire (ex. arbres de forêt) sur la BA du végétal à extraire (ex. arbres de forêt), le tout multiplié par 100. Le taux d'augmentation de BA due à la conversion des forêts en palmeraies atteint 100 % lorsque les BA du végétal à installer (ex. palmier) sont $> 0\text{ t ha}^{-1}$ et les BA du végétal à extraire (ex. arbres de forêt) équivalent à 0 t ha^{-1} (Ramdani et Masateru, 2013; Kho et Rudbeck-Jepsen, 2015). Une carte des BA de conversion ou non des forêts en palmeraies a enfin été réalisée à la résolution

spatiale de 30,8 m × 30,8 m. Les valeurs des intervalles des pertes et de gains des BA obtenues au cours de cette analyse de la dynamique de la BA ont été considérées pour produire la carte de BA de conversion ou de non-conversion des forêts en palmeraies. Une discussion des résultats a enfin été menée.

8.3 Résultats et discussion

La section 8.3 présente la discussion des résultats de l'analyse de la dynamique des forêts et des palmiers à huile de l'étude. Cette section comporte 3 sous-sections, à savoir : 1) Pertes de BA dues au remplacement des arbres de forêts par les palmiers; 2) Gains de BA dues au remplacement des arbres de forêts par les palmiers; 3) Cartographie des BA pour la conversion ou non des arbres de forêts en palmiers.

8.3.1 Pertes de biomasses dues au remplacement des arbres de forêts par les palmiers

Les cartes de BA des forêts (Figure 7.9 du chapitre 7) et des palmiers à huile d'une plantation agro-industrielle mature du Gabon dans le Bassin du Congo (Figure 6.8 du chapitre 6) ont été réalisées dans la présente étude. Les valeurs maximales et minimales de BA des types de forêt et palmier à huile de ces cartes ont été reportées à la Figure 8.1. Les valeurs moyennes de ces BA sont illustrées à la Figure 8.2c. Les gains et les pertes de BA des remplacements des arbres de forêts en palmiers sont présentés à la Figure 8.2. Ces différentes valeurs ont été analysées pour comprendre la dynamique de la BA due aux conversions des forêts en palmeraies sur pied de 35 ans. Il existe toutefois une inconnue sur l'âge exact des peuplements des forêts pour les comparer aux plantations de palmiers à huile. La BA maximale des palmiers à huile matures de 35 ans de 72 t ha^{-1} a alors été considérée pour comparer les BA des arbres de forêts et des palmiers à huile.

En examinant les BA des forêts et des palmeraies, il ressort clairement que les BA maximales des forêts sont en général plus élevées que celles BA des palmeraies (Figure 8.1). Les BA faibles et minimales des forêts secondaires jeunes-adultes ou inondables ne le sont toutefois pas (Figure 8.1). De manière spécifique, les BA maximales des forêts matures (584 t ha^{-1}), secondaires vieilles (240 t ha^{-1}) et secondaires jeunes-adultes ou inondables (146 t ha^{-1}) demeurent plus élevées que les valeurs maximales des palmiers à huile (72 t ha^{-1}). En considérant ces valeurs, les taux de pertes de BA maximales lors des conversions des forêts en palmiers ont été évalués sur une durée de 35 ans à près de 88 % pour les forêts matures, à 70 % pour les forêts secondaires

vieilles et à 51 % pour les forêts secondaires jeunes-adultes ou inondables (Figure 8.2a). Les BA minimales (Figure 8.1) et moyennes (Figure 8.2c) suivent en général la même tendance que ceux des BA maximales. Il en est de même pour les taux de pertes de BA (Figure 8.2c). Les durées d'inexploitation ou de non-impact humain et de reconstitution à long terme des forêts matures et secondaires vieilles / jeunes et adultes contribuent aux valeurs élevées des BA de ces types de forêts (Helmer *et al.*, 2009; Becknell *et al.*, 2012). Certaines forêts matures peuvent correspondre à une reconstitution des forêts secondaires pendant une durée supérieure à 100 ans (Becknell *et al.*, 2012). Au Gabon, l'Okoumé a été exploité initialement en 1889. Les premières plantations artificielles de cette essence ont été introduites en 1944 (correspondant à 77 ans aujourd'hui) dans la forêt classée du Cap Estérias (Lasserre, 1955), incluant le site de la forêt de la présente étude. Kho et Rudbeck-Jepsen (2015) ont aussi montré que les biomasse moyennes des forêts primaires sur pied en Malaisie ($251,9 \pm 17,5 \text{ Mg C ha}^{-1}$) ont nettement été plus importantes que les BA des plantations de palmiers à huile de 5 à 28 ans (oscillant entre 15,1 et $59,5 \text{ Mg C ha}^{-1}$). Des taux de perte de BA de la présente étude ont été semblables à ceux de Kho et Rudbeck-Jepsen, (2015) pour des remplacements de forêts primaires (81 % à 88 %) et secondaires (77 %) par les plantations de palmiers à huile matures.

Les résultats obtenus au cours des travaux montrent clairement que le remplacement des forêts matures et secondaires vieilles, jeunes-adultes ou inondables par les plantations de palmiers de 35 ans est plus à l'origine de perte que de gains de BA (Figure 8.2). Au regard de ce constat, les palmiers à huile (avec BA maximale de 72 t ha^{-1}) ne devraient pas remplacer les zones des BA des forêts matures ($> 240 \text{ t ha}^{-1}$) et secondaires vieilles ($> 146 \text{ t ha}^{-1}$) ainsi que les sites à BA des forêts secondaires jeunes-adultes ou inondables ($> 72 \text{ t ha}^{-1}$). Ce non-replacement permettrait de conserver le fort potentiel de BA stockée dans les forêts matures et secondaires. Ce non-replacement permettrait aussi d'éviter des pertes ou des diminutions de près de 88 % de BA des forêts matures, de 70 % de forêt secondaires vieilles et de 51 % de forêts secondaires jeunes-adultes ou inondables (Figure 8.2a). Les forêts matures et secondaires vieilles, jeunes et adultes ou inondables (avec BA maximales ou à fort potentiel de BA) sont plus utiles pour les activités contribuant à leur maintien, notamment la gestion durable, l'écotourisme, la lutte mondiale contre les changements climatiques et le marché du carbone. Au-delà des résultats obtenus, des efforts devraient être faits dans la production de documents d'archivage des âges des parcelles des forêts du Bassin du Congo, notamment au Gabon, pour faciliter les études futures traitant du même sujet.

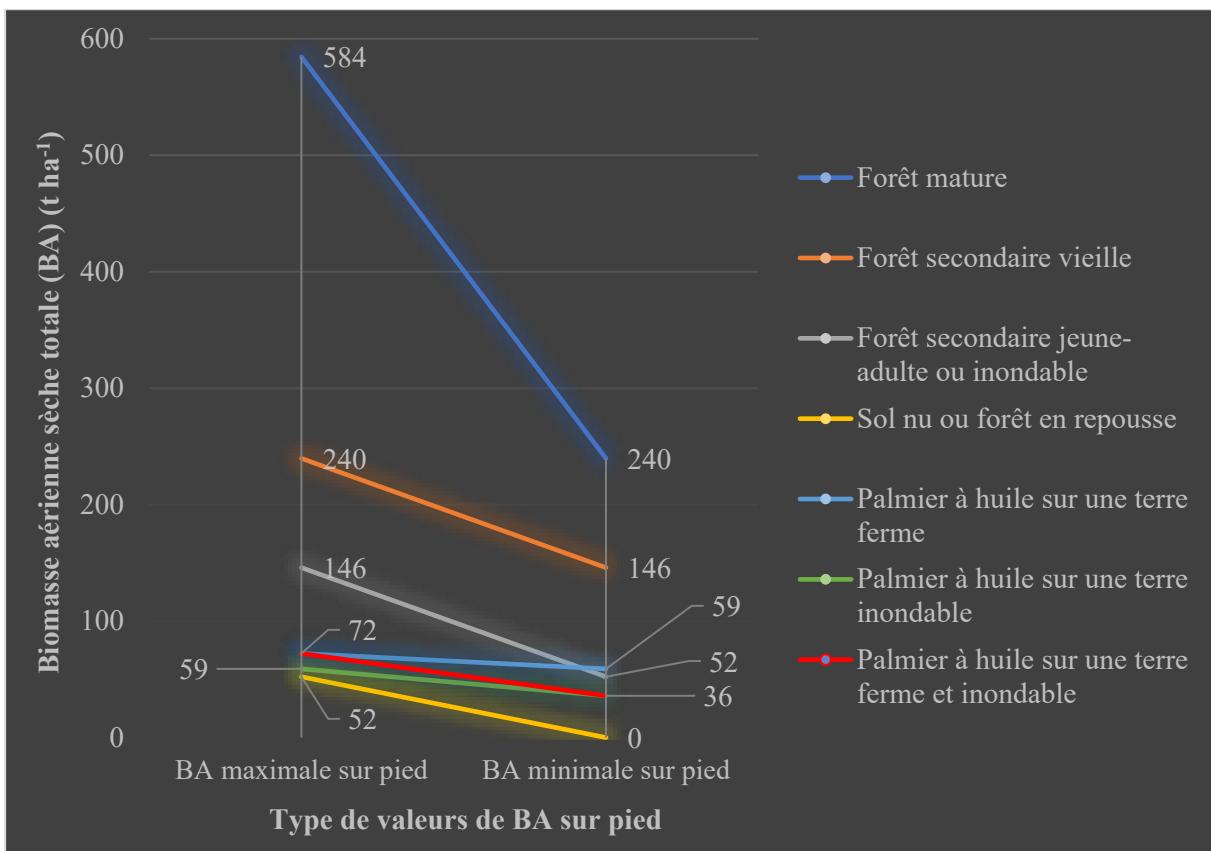


Figure 8.1. Valeurs des biomasses aériennes sèches totales des sites d'étude des forêts du Cap Estérias et des palmiers à huile de la plantation agro-industrielle mature à Makouké au Gabon dans le Bassin du Congo

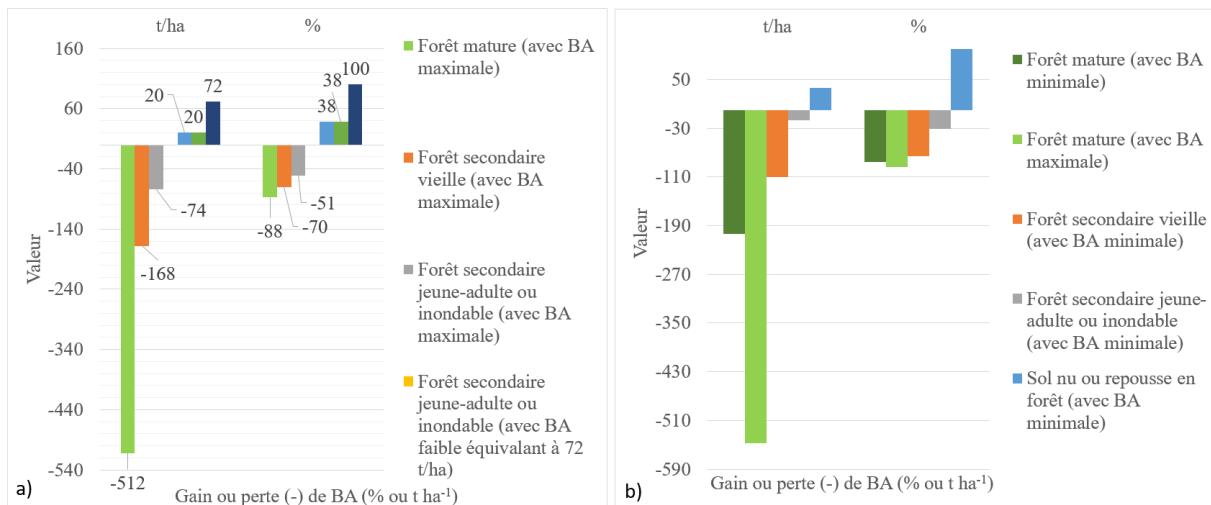


Figure 8.2. Gains ou pertes des biomasses aériennes sèches totales maximales (a), minimales (b) et moyennes (c) dus à la conversion des types d'occupation de terre du site d'étude de la forêt en plantation de palmiers à huile au Gabon dans le Bassin du Congo

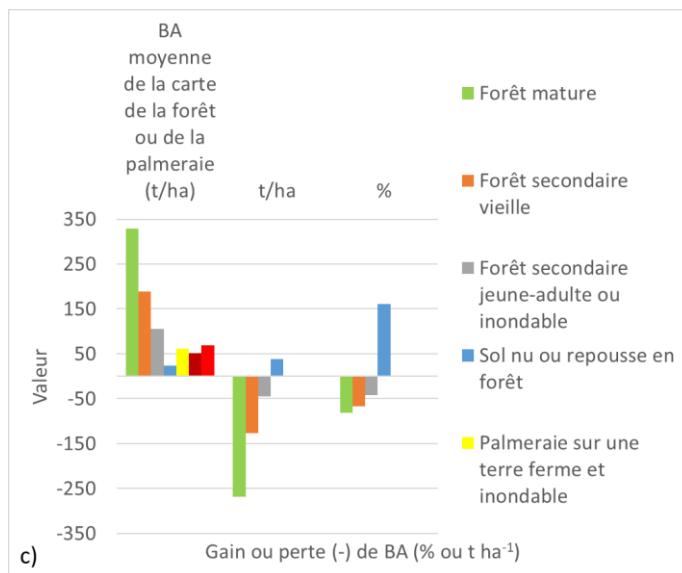


Figure 8.3 (suite). Gains ou pertes des biomasses aériennes sèches totales maximales (a), minimales (b) et moyennes (c) dus à la conversion des types d’occupation de terre du site d’étude de la forêt en plantation de palmiers à huile au Gabon dans le Bassin du Congo

8.3.2 Gains de biomasses dus au remplacement des forêts par les palmeraies

Dans la présente étude, les gains des BA des palmiers à huile de la plantation sont obtenus avec les forêts secondaires jeunes-adultes ou inondables (avec BA minimales = 52 t ha^{-1} ou faibles équivalant à 72 t ha^{-1}) et les sols nus ou forêts en repousse (avec BA comprises entre 0 et 52 t ha^{-1}) (Figure 8.1). Ces deux types de forêt sont utilisés tout au long de l'étude pour évaluer les gains de BA des palmiers à huile. Les BA des palmiers à huile sur une terre ferme ($59-72 \text{ t ha}^{-1}$) ont systématiquement été supérieures aux BA des palmiers à huile sur une terre inondable ($36-59 \text{ t ha}^{-1}$). Les BA des palmiers à huile sur une terre inondable demeurent aussi inférieures (59 t ha^{-1}) aux BA des forêts secondaires jeunes-adultes ou inondables (72 t ha^{-1}). Ainsi, les gains en BA maximales des palmiers huiles sur une terre ferme ont été plus élevés (compris entre 38 % à 100 % soit 20 à 72 t ha^{-1}) à ceux des palmiers à huile sur une terre inondable (compris entre 12 % à 100 % soit 7 à 59 t ha^{-1}) lors du remplacement des forêts en palmeraies. Il n'existe aucun gain de BA lors du remplacement des forêts secondaires jeunes-adultes par les palmeraies sur une terre inondable avec BA faibles de 72 t ha^{-1} . Ces résultats sont presque similaires à ceux des BA minimales et moyennes des palmeraies et des forêts (Figures 8.1 et 8.2). Les palmiers à huile sur une terre ferme sont implantés sur les sols favorables à leur bonne croissance alors que les palmiers à huile sur une terre inondable ont une croissance ralentie par la présence des eaux. Ces différents facteurs pourraient justifier le niveau de BA de ces deux types de palmiers à huile. Selon les travaux de Ngiye (2015), les palmiers à huile ne supportent pas les sols inondés de manière permanente et ils acceptent mieux les sols de terre ferme

inondable momentanément. Il serait alors plus opportun d'installer les palmiers à huile sur des terres fermes que sur des terres inondables pour une meilleure optimisation des gains de BA. Les palmiers à huile sur une terre ferme, pour leur fort potentiel de stockage de biomasse (72 t ha^{-1}), pourraient remplacer les forêts précitées (avec BA comprises entre $0\text{-}72 \text{ t ha}^{-1}$) sur une période de 35 ans. En considérant les valeurs de BA des forêts secondaires jeunes-adultes ou inondables avec BA faibles de 72 t ha^{-1} , ces forêts ne devraient toutefois pas être remplacées par les palmiers à huile pour leur permettre de continuer à lutter contre les changements climatiques futurs.

Les BA maximales des palmiers à huile sur terre ferme (72 t ha^{-1}) ont été supérieures aux BA minimales et faibles des forêts secondaires jeunes-adultes ou inondables ($\leq 72 \text{ t ha}^{-1}$) ou des BA des sols nus ($\leq 52 \text{ t ha}^{-1}$). Avec ces valeurs, les gains de BA ($\geq 38 \%$) sont déterminés lors des remplacements des forêts par les palmeraies. Spécifiquement, les BA maximales des palmiers à huile sur terres ferme (72 t ha^{-1}) sont plus élevées ou égales par rapport aux BA des forêts secondaires jeunes-adultes ou inondables ($52\text{-}72 \text{ t ha}^{-1}$) et des sols nus ou des forêts en repousse ($0\text{-}52 \text{ t ha}^{-1}$). En tenant compte de ces valeurs lors du remplacement des forêts en palmeraies, les sources essentielles de gains de BA des palmiers sont prioritairement les sols nus ou les forêts en repousse (38 % à 100 % soit $20 \text{ à } 72 \text{ t ha}^{-1}$) et ensuite les forêts secondaires jeunes-adultes ou inondables (0% à 38 % soit $0 \text{ à } 20 \text{ t ha}^{-1}$). Les résultats des BA minimales (Figure 8.2b) et moyennes (Figure 8.2c) de ces palmiers à huile suivent en général la même tendance que ceux des BA maximales lors du remplacement des forêts par les palmeraies. Les BA minimales et faibles (équivalant à 72 t ha^{-1}) des forêts secondaires jeunes-adultes ou inondables évoquées ici sont davantage caractérisées par des forêts d'arbres de petits diamètres et regorgeant de diverses perturbations récentes. Ces forêts possèdent de faibles durées de périodes de destruction et de reconstitution (Corlett, 1994; Becknell *et al.*, 2012; Bojórquez *et al.*, 2020). Les sols nus sont par ailleurs pourvus de petites forêts persemées et les forêts en repousse sont davantage constituées des recrus et de jachères forestières. Les différentes caractéristiques de ces forêts pourraient expliquer leurs faibles BA par rapport aux BA des palmiers à huile de 35 ans. En conformité avec les résultats de notre étude, Kho et Rudbeck-Jepsen (2015) ont attesté que les biomasses totales sur pied des palmiers matures de 5 à 28 ans (comprises entre $15,1$ et $59,5 \text{ Mg C ha}^{-1}$) de Malaisie avaient quasiment le double de celles des jachères sur pied ($27,6 \pm 6,3 \text{ Mg C ha}^{-1}$). Pour leurs gains en BA, les palmiers à huile matures sur une terre ferme pourraient remplacer sur une durée de 35 ans les sols nus ou forêts en repousse, tandis qu'ils ne pourraient pas le faire (ou que très accessoirement) pour les forêts

secondaires jeunes-adultes ou inondables (avec BA faibles équivalant à 72 t ha⁻¹). Cela participerait à une lutte optimisée contre les changements climatiques.

Les BA maximales des forêts (584 t ha⁻¹) sont largement supérieures aux BA maximales des palmiers à huile (72 t ha⁻¹). Les gains de BA des palmiers (72 t ha⁻¹ soit 100 %) suivent la même tendance que les pertes de BA des forêts (512 t ha⁻¹ soit 88 %) lors des conversions des forêts en palmeraies. Les différences de plusieurs facteurs (temps de reconstitution, milieu de croissance, caractéristiques physiques et physiologiques) propres aux arbres des forêts et des palmiers peuvent être à l'origine de fortes divergences des BA de gains et de pertes de BA lors du remplacement des forêts en palmeraies. Les conversions des forêts en plantations de palmiers sont très majoritairement des facteurs principaux de pertes de BA que de gains pour les forêts matures et secondaires. Kho et Rudbeck-Jepsen (2015) ont aussi trouvé des résultats similaires. La prise en compte des taux de pertes de BA contribuerait à réduire les forêts matures et secondaires et à limiter la lutte contre les changements climatiques. En revanche, la considération des gains de BA favoriserait le maintien sur pied des forêts matures et secondaires utiles à la lutte contre les changements climatiques et à extraire les forêts (ex. sols nus ou forêts en repousse) peu contributives à cette lutte. A l'égard de l'importance des enjeux des gains et pertes des BA, tout remplacement des forêts par les plantations de palmiers devrait être subordonné à une étude de l'analyse de la dynamique des BA des forêts et des palmeraies à l'aide de la télédétection. Cela permettrait une meilleure compréhension des contributions de chaque végétal à la lutte contre les changements climatiques et à l'affectation des terres. À défaut, les études existantes pourraient être considérées.

8.3.3 Cartographie des biomasses pour la conversion ou non des forêts en palmeraies

Une carte de BA d'aide à l'identification des sites de conversion ou de non-conversion des forêts en plantations de palmiers à huile (Figure 8.3) a été réalisée. Cette carte tient en général compte des potentiels gains de BA maximums de 100 % soit 72 t ha⁻¹ (Figures 8.1 et 8.2a) et des pertes de BA maximales de forêts matures de 88 % soit -512 t ha⁻¹ (Figure 8.1 et 8.2a) dus au remplacement des forêts par les palmeraies. Elles illustrent les zones de BA de forêts susceptibles d'être substituées par les plantations de palmiers à huile (couleur jaune clair). Sur cette carte, ces BA sont comprises entre 0-72 t ha⁻¹. Sur le terrain, elles correspondent à des forêts secondaires jeunes-adultes ou inondables (avec BA minimales et faible de 72 t ha⁻¹) et des sols nus ou des forêts en repousse (avec BA minimale et maximale). Cette même carte représente également les zones de BA entre 72 et 584 t ha⁻¹ pouvant occasionner les pertes de BA en effectuant le remplacement de forêts par les palmeraies. Sur le terrain, les BA de 72-146

t ha^{-1} correspondent aux forêts secondaires jeunes-matures ou inondables (couleur vert moyen, Figure 8.3). Les BA de 146-240 t ha^{-1} sont assimilées sur le terrain aux forêts secondaires vieilles (couleur vert clair, Figure 8.3). En revanche, les BA de 240-584 t ha^{-1} coïncident aux positions des forêts matures (couleur vert foncé, Figure 8.3). Les valeurs de BA perdues et gagnées ont correctement été reportées sur la carte de BA d'identification des zones de conversion ou non des forêts en plantations de palmiers. Elle représente un outil idoine pour aider les décideurs à l'affectation des forêts en palmeraies et à la mise en œuvre des activités de lutte contre les changements climatiques. Ce type d'outil devrait être développé sur des territoires aux surfaces plus vastes que la zone d'étude pour obtenir des informations sur la dynamique de la BA dues au remplacement des forêts en plantations de palmiers. La différence de données de télédétection (SPOT-7, LiDAR et PolInSAR vs FORMOSAT 2), ayant servi à produire les cartes de BA des forêts et des palmiers à huile, peut avoir contribué à générer des différences sur les valeurs de BA. La différence des résolutions spatiales de ces deux cartes peut également représenter un facteur limitant. Dans les études futures, il est alors conseillé d'utiliser les données de télédétection similaires (y compris les résolutions spatiales) pour produire les cartes des BA d'identification des sites de conversion des deux types de végétaux chlorophylliens de l'étude. Les erreurs inhérentes aux BA des cartes initiales des forêts et des palmeraies utilisées ont une incidence sur la carte illustrée à la Figure 8.3. Il est alors suggéré d'utiliser dans les études futures des BA des cartes des forêts et des plantations de palmiers possédant moins d'erreurs par rapport à celles considérées dans la présente étude.

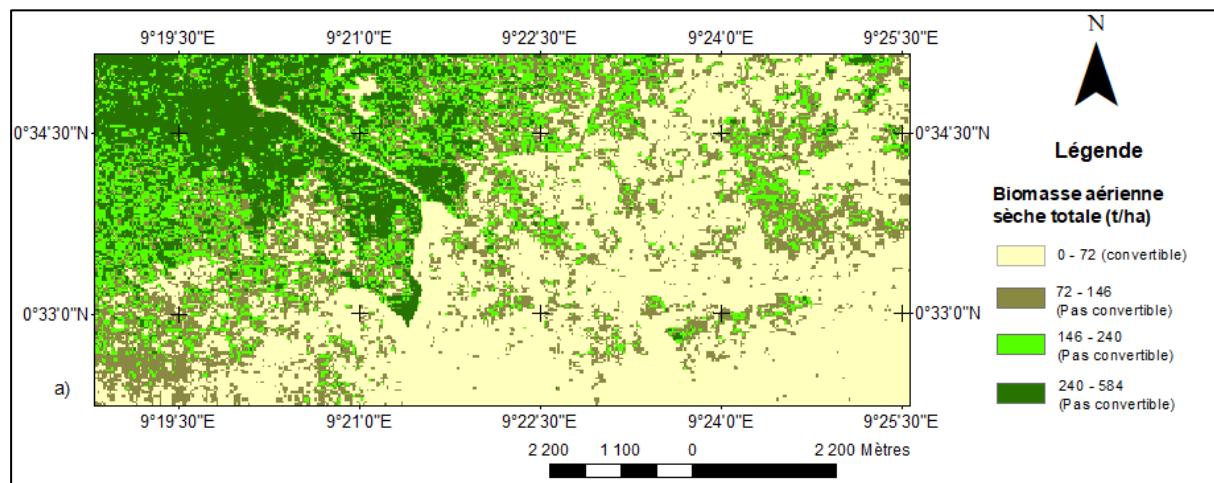


Figure 8.4. Carte de biomasse aérienne sèche totale d'aide à l'identification des sites de conversions ou de non-conversions des forêts en palmeraies.

8.4 Conclusion

Le présent chapitre a exploré l'évaluation des pertes et des gains de BA dus au remplacement des forêts en plantations de palmiers à huile de 35 ans en Afrique dans le Bassin du Congo, particulièrement au Gabon. Globalement, toutes les BA des différents types de forêt de l'étude ($> 72 \text{ t ha}^{-1}$), à l'exception des sols nus ou des forêts en repousse ($\leq 52 \text{ t ha}^{-1}$), sont plus élevées que celles des palmiers à huile ($\leq 72 \text{ t ha}^{-1}$). Les substitutions de ces forêts par les palmeraies à huile contribueraient à des pertes de BA $\geq 51\%$. De manière spécifique, les valeurs des BA des forêts matures sont plus élevées (584 t ha^{-1}) que celles des autres types de forêt ($\leq 240 \text{ t ha}^{-1}$), et leur remplacement par les plantations de palmiers à huile occasionnerait des pertes de BA évaluées à près de 88 %. Les forêts secondaires vieilles ont des valeurs de BA élevées (comprises entre 146 et 240 t ha^{-1}) mais inférieures à celles des BA des forêts matures et leur conversion par les plantations de palmiers à huile avec BA maximales générerait des pertes de BA de 70 %. En revanche, les BA des forêts secondaires jeunes-adultes ou inondables (comprises entre 72 et 146 t ha^{-1}) ne dépassent pas les BA des forêts secondaires vieilles et leur substitution par les palmeraies provoquerait des pertes de BA maximales de l'ordre de 51 %. Au-delà de ces potentielles pertes de BA, tous les deux types majeurs de palmiers à huile (sur des terres inondables et fermes) de l'étude ont des BA maximales plus élevées (59 et 72 t ha^{-1}) par rapport aux BA des sols nus ou des forêts en repousse (comprises entre 0 et 52 t ha^{-1}) et des forêts secondaires jeunes-adultes ou inondables (comprises entre 52 et 72 t ha^{-1}). Lors du remplacement des forêts par les palmeraies, les gains en BA maximales des palmiers à huile sur une terre ferme ($\geq 38\%$ soit $\geq 20 \text{ t ha}^{-1}$) sont nettement plus importants que les gains en BA des palmiers à huile sur une terre inondable ($\geq 12\%$ soit $\geq 7 \text{ t ha}^{-1}$). Les gains de BA de ces palmiers (sur une terre ferme) (72 t ha^{-1} soit 100 %) sont toutefois largement inférieurs à ceux des pertes en BA des forêts ($\geq 51\%$ soit $\geq 74 \text{ t ha}^{-1}$). Malgré l'acquisition des résultats inédits sur la dynamique de la BA due à la conversion des forêts en palmeraies, les travaux comportent des limites. Parmi ces limites, il y a l'utilisation des données de télédétection différentes (SPOT-7, LiDAR et radar vs FORMOSAT-2) pour produire les cartes des forêts et des plantations de palmiers à huile de l'étude. Les erreurs inhérentes aux BA de ces deux cartes sont aussi un autre facteur limitant. Les résolutions spatiales de ces cartes contribuent à limiter les résultats obtenus. L'originalité des travaux porte en premier sur l'utilisation des BA des cartes des forêts et des plantations de palmiers à huile inédites. La détermination des valeurs de gains et des pertes de BA dus à la conversion des forêts par les palmeraies dans le Bassin du Congo confère une grande importance à l'originalité des travaux. La conception d'un outil scientifique d'aide à la décision de l'identification des sites de conversion ou non des forêts en palmeraies

contribue également à l'originalité de l'étude. Dans les études futures, il est recommandé de réaliser les travaux de recherche sur des sites plus vastes. Cela permettrait d'avoir une meilleure représentativité et une diversité des biomasses des types de forêt et des palmeraies. Il est suggéré de considérer les différents stades de développement des forêts et des palmeraies. Dans ces travaux futurs, il serait également pertinent d'examiner la dynamique temporelle de la BA due à la conversion des forêts en plantations de palmiers en utilisant les données socio-économiques et la télédétection.

CHAPITRE 9. Discussion générale

Cette section traite de la discussion globale de la thèse. Chaque article du manuscrit constitutif du noyau de la recherche (chapitres 5, 6, 7 et 8) dispose de sa discussion.

9.1 Estimation de la biomasse *in situ*

Au cours de la présente étude, la biomasse aérienne sèche totale (BA) des palmiers à huile d'une plantation agro-industrielle mature a été estimée à l'aide des paramètres structuraux de ce végétal. La discussion sur cette estimation a été publiée dans le Journal *Forest* (cf. section référence : Migolet *et al.*, (2020). Un résumé de cette discussion est mis en lumière ici. Les détails sont disponibles dans l'article de Migolet *et al.*, (2020). Plusieurs variables ont été utilisées dans l'étude pour estimer la BA à l'aide de 18 palmiers à huile : le diamètre à hauteur de poitrine (DHP mesuré à 1,3 m au-dessus du sol et exprimée en cm), la hauteur de la tige (H_T , en m), la hauteur totale, l'infra-densité (ρ , en g cm⁻³) et/ou le nombre de feuilles (N_F) des palmiers à huile. La BA des palmiers à huile a été mieux estimée avec des modèles de loi puissance locales à l'aide des variables combinées (Tableaux 5.5 et 5.7 du chapitre 5). L'association de DHP à H_T , deux paramètres mesurables facilement sur le terrain, avait la troisième meilleure estimation de la BA dans la présente étude. La variable intégrée DHP^2H_T caractérise à elle seule les caractéristiques du volume d'un cylindre correspondant à la forme géométrique du palmier à huile. La variable intégrée combinant ρ à DHP^2H_T a constitué le paramètre explicatif de la BA du deuxième meilleur modèle d'estimation de la BA. ρ est caractérisée par le rapport de la masse sur le volume saturé en eau de bois. ρ est un paramètre représentatif de la masse et de la forme cylindrique de la tige du palmier. ρ apporte ainsi une information supplémentaire à l'estimation de la BA. Le premier meilleur modèle de BA a été prédit à l'aide des variables intégrées estimant les biomasses de la tige ($DHP^2H_T \rho$) et des feuilles ($DHP^2H_T N_F$) (Tableaux 5.5 et 5.7 du chapitre 5). La tige et les feuilles sont les deux parties essentielles de concentration de la BA du palmier. N_F a davantage apporté l'information sur les feuilles. Le cumul de ces différentes variables représentatives des caractéristiques des composantes du palmier à huile contenant la BA pourrait expliquer leurs apports à la bonification des modèles de la BA de terrain. Dans des études antérieures, l'estimation de la BA a aussi été améliorée par la combinaison des variables structurelles des palmiers à huile (Da Silva *et al.*, 2015; Cole et Ewel, 2006).

En dehors du développement des modèles aptes à estimer la BA, les modèles existants ont été comparés. Les BA des modèles existants de Khalid *et al.*, (1999), de Salgarriaga *et al.*, (1988),

de Goodman *et al.*, (2015) et d’Hughes *et al.*, (1988) ont été inapplicables dans le Bassin du Congo (Tableau 5.8; Figures 5.5 et 5.6 du chapitre 5). Ces modèles ont été développés en Malaisie (Khalid *et al.*, 1999), en Colombie / Venezuela (Salgarriaga *et al.*, 1988), au Pérou (Goodman *et al.*, 2015) et au Mexique (Hughes *et al.*, 1988). Ces mêmes modèles ont été bâties à partir des données constituées des palmiers à huile jeunes (Saldarriaga *et al.*, 1988; Hughes *et al.*, 1988), mi- matures (khalid *et al.*, 1999), et mixtes (jeunes et matures), avec dominance en grand nombre des jeunes palmiers à huile (Goodman *et al.*, 2015). La disparité des données de terrain et les diversités des conditions des sites pourraient expliquer l’inapplication de ces modèles dans le Bassin du Congo. Par ailleurs, les modèles de Da Silva *et al.*, (2015), de Thenkabail *et al.*, (2004) et de Cole et Ewel, (2006) ont été applicables dans le Bassin du Congo (Tableau 5.8; Figures 5.5 et 5.6 de l’article 1). Ces modèles ont été bâties au Brésil (Da Silva *et al.*, 2015), au Benin (Thenkabail *et al.*, 2004) et au Costa Rica (Cole et Ewel, 2006). Les modèles de BA existantes de Da Silva *et al.*, (2015) ont été mieux appliqués dans le Bassin du Congo que tous les modèles existants de BA considérés dans la présente étude (Tableau 5.8; Figures 5.5 et 5.6 de l’article 1). Les palmiers à huile avec des hauteurs variables de courtes à grandes ont été utilisés pour produire les modèles de Cole et Ewel, (2006). Des jeunes palmiers ont cependant été usités pour construire les modèles de Thenkabail *et al.*, (2004). Chacun de ces deux facteurs distincts pourrait expliquer la faible performance de chaque modèle par rapport au modèle de Da Silva *et al.*, (2015). La combinaison des paramètres structuraux pour établir le modèle de Cole et Ewel, (2006) et la forte proximité territoriale des palmiers à huile utilisés pour construire les modèles de Thenkabail *et al.*, (2004) pourraient avoir contribué à obtenir les performances des modèles de ces deux groupes d’auteurs dans la présente étude.

Les 18 palmiers abattus permettent certainement de développer des modèles et de les valider. Mais pour plus de robustesse, d’autres échantillons seront nécessaires. Aussi, les palmiers considérés sont tous matures, les autres classes d’âge ne sont pas représentées, ce qui est une limitation.

9.2 Estimation de la biomasse en utilisant la méthode FOTO

Les travaux démontrent le potentiel des indices FOTO dans l'estimation de la BA des palmiers (Tableaux 6.3 à 6.5; Figures 6.5 et 6.6, Chapitre 6). Ces indices caractérisent la variation du grain de texture grossier ou fin avec l’ouverture ou la fermeture de la canopée, ce qui a un lien avec la BA (Proisy *et al.*, 2007). L’homogénéité et la structure simple des palmiers à huile ont probablement aussi facilité la capacité des indices FOTO à prédire la BA dans la forêt tropicale

considérée. En effet, Ploton *et al.*, (2017) soulignent que les indices FOTO ont été conçus à l'origine pour les peuplements homogènes. Cependant, différentes études démontrent également leur applicabilité dans des peuplements plus hétérogènes. Ainsi, à titre d'exemple, Singh *et al.*, (2014a) ont estimé la BA d'une forêt tropicale mixte (incluant des palmiers huile) en Malaisie à l'aide d'indices FOTO de SPOT 5 avec des résultats convaincants (R^2 compris entre 0,81 et 0,97).

De manière globale, les indices FOTO de FORMOSAT-2 ont permis une meilleure estimation de la BA des palmiers comparé à ceux de PlanetScope (Tableaux 6.3, 6.4 et 6.5). Plusieurs facteurs peuvent expliquer ces résultats. FORMOSAT-2 a une résolution spatiale plus fine (2 m) que celle de PlanetScope (3,125 m). De plus, les incertitudes radiométriques propres à FORMOSAT-2 (< 5 %) (Liu *et al.*, 2010) sont plus faibles que celles de PlanetScope (5-6 %) (Cooley *et al.*, 2017). Finalement, il est recommandé de calculer les indices FOTO à partir des images originelles non corrigées (Proisy *et al.*, 2007). Dans cette étude, l'image PlanetScope disponible avait subie des corrections radiométriques et atmosphériques, ce qui n'était pas le cas pour FORMOSAT-2.

Dans tous les cas, l'approche MARS s'est révélée plus performante pour l'estimation de la BA avec les indices FOTO (Tableaux 6.3 à 6.5). Ce qui vérifie notre hypothèse de départ. Les niveaux des valeurs de BA de terrain (35,9 – 75,2 t ha⁻¹) et des BA de la carte de l'étude de résolution spatiale 120 m² (35,9 – 72,2 t ha⁻¹) produite avec le modèle MARS à l'aide des indices FOTO de FORMOSAT-2 sont similaires. L'approche sélectionne et identifie automatiquement les relations non linéaires et les interactions entre les variables. Les régressions linéaires multiples n'offrent pas cette possibilité (García Nieto *et al.*, 2012; Wang *et al.*, 2015; Park *et al.*, 2017). Cela pourrait expliquer l'adoption de la méthode dans plusieurs domaines, comme la médecine (Pramila *et al.*, 2015), l'hydrologie (Park *et al.*, 2017) et la foresterie (Vaglio Larin *et al.*, 2016). Mais peu de travaux de télédétection ont exploré l'approche.

9.3 Estimation de la biomasse par combinaison des données de télédétection

Durant les travaux de recherche de la présente étude, la BA de la forêt du site d'étude (de l'ancienne forêt de la Mondah) a également été estimée avec MARS à partir des variables individuelles et combinées des données de télédétection (optiques, LiDAR et radar). La discussion des résultats de l'estimation de cette BA a été consignée dans un article publié au journal *GIScience and remote sensing*. Une synthèse de cette discussion est présentée ici.

Les erreurs d'estimation de la BA ont plusieurs sources notamment les mesures de terrain, les données de télédétection et les modèles statistiques utilisés. Les erreurs moyennes de mesures des hauteurs modélisées de terrain (23 %), des DHP (18 %), la densité du bois (27 %) et des BA (20 %) ont été constatées dans diverses études antérieures (Labriere *et al.*, 2018; Ikati Lisongi 2011; Chave *et al.*, 2009; Chave *et al.*, 2014). Dans la présente étude, les erreurs standards résiduelles entre les hauteurs modélisées de terrain et les hauteurs dérivées des données LiDAR et PolInSAR sont respectivement de 17 % et de 20,3 %. Selon le type de données de télédétection, les erreurs des BA proviennent de plusieurs sources notamment la topographie (LiDAR, radar et optique passive), la couverture nuages (optique passive), la décorrélation temporelle (PolInSAR), la densité et la complexité des forêts (radar et optique passive). Les approches statistiques peuvent être limitées et moins performantes à cause de plusieurs facteurs comme le faible nombre de placettes échantillons, l'absence de variables explicatives pertinentes lors du développement des modèles de BA, ou le choix du type d'approche (Chave *et al.*, 2004; Li *et al.*, 2009; Shi et Liu, 2017; Zhang *et al.*, 2020). Des études antérieures ont mentionné ces sources d'erreurs (Chave *et al.*, 2004; Li *et al.*, 2009; Kumar *et al.*, 2015; Villard *et al.*, 2016; Shi et Liu, 2017; Urbazaev *et al.*, 2018; Coops *et al.*, 2021; Shi *et al.*, 2021).

Pour s'assurer d'une bonne distribution et représentativité des placettes échantillons, une analyse d'autocorrélation spatiale a été entreprise en utilisant l'indice local de Moran d'Anselin. Dans l'ensemble, l'analyse a révélé l'absence d'autocorrélation dans les BA des placettes utilisées (Tableau 7.4). Parmi ces placettes, certaines sont dérivées des grandes placettes de 1 ha de la campagne AfriSAR. Pour s'assurer de la qualité de l'approche utilisée pour ce faire, nous avons réalisé une analyse d'autocorrélation sur l'ensemble des placettes AfriSAR disponibles. Les résultats confirment l'absence générale d'autocorrélation, avec des niveaux similaires à ceux obtenus pour les placettes utilisées dans notre étude, qui ont une résolution de 30,8 m x 30,8 m (Tableau 7.5). Cela atteste de l'hétérogénéité des forêts au niveau des placettes échantillons. Cependant, qu'il s'agisse des placettes que nous avons utilisées ou de celles d'AfriSAR, l'analyse de l'autocorrélation au niveau du site d'étude dans son ensemble à l'aide de l'indice Global de Moran (Tableau 7.4; Tableau 7.5) montre bien que les BA sont autocorrélées. Ce résultat était attendu, puisqu'il s'agit d'une question d'échelle. Lorsque la grande surface de la zone d'étude est considérée, la forêt apparaît homogène, ce qui se traduit par une autocorrélation des BA. C'est une caractéristique qui se retrouve généralement dans les forêts

(Réjou-Méchain *et al.*, 2014; Méthot *et al.*, 2014; Ou *et al.*, 2019). Les résultats d'autocorrélation obtenus avec l'indice local de Moran d'Anselin démontrent dans l'ensemble une distribution aléatoire des placettes échantillons. Ces dernières ont alors été utilisées dans le développement et la validation des modèles de BA.

Les indices de texture GLCM de SPOT-7 de l'étude ont des corrélations les plus faibles avec la biomasse (Tableau 7.6) comparés aux indices FOTO, au LiDAR ou au radar. Les modèles MARS développés avec seulement ces indices sont quasiment non significatifs (Tableaux 7.8 et 7.9). Les résultats de ces indices sont souvent tributaires de divers paramètres notamment le type d'image, la taille de fenêtre, les distances interpixels ou les directions d'échantillonnage (Coulibaly et Gwyn, 2005; Kelsey et Neff, 2014; Pandit *et al.*, 2020). L'utilisation d'une seule distance interpixel au détriment de plusieurs distances interpixels dans les présents travaux pourrait expliquer les résultats trouvés.

Les indices FOTO, notamment le PC2, montrent un potentiel de corrélation avec la biomasse et les paramètres structuraux de la forêt (Diamètre et hauteur de l'arbre) (Tableau 7.6). Les modèles MARS développés à l'aide de PC2 sont relativement efficaces (Tableau 7.8, Model 5 : $R^2 = 0.60$; $P < 0.0001$; %RMSE = 63 %). La résolution spatiale fine de l'image *pansharped* (1,5 m × 1,5 m) a probablement contribué à obtenir ces résultats. Cette assertion est aussi confirmée dans diverses études antérieures (Coutreron *et al.*, 2005; Proisy *et al.*, 2007; Ploton *et al.*, 2012). Ce type de résolution favorise une meilleure délimitation des couronnes des arbres. La taille de la fenêtre FOTO choisie (175 m x 175 m) pourrait avoir contribué à l'obtention de ces résultats par sa capacité à mieux faire la distinction dans les textures fines et grossières avec des canopées fermées ou ouvertes de la forêt tropicale considérée. Diverses études ont d'ailleurs montré la pertinence d'utiliser des grandes tailles de fenêtre pour produire les indices FOTO utiles à l'estimation de la BA (Proisy *et al.*, 2007; Ploton *et al.*, 2012).

Le coefficient de rétrodiffusion σ^0 ou H_R montre des résultats significatifs avec la BA (Tableau 7.6), comme nous pouvons le constater avec les modèles 3, 4 et 6 développés uniquement à l'aide des données PolInSAR en bande L avec l'approche MARS (Tableaux 7.8, 7.9). Les erreurs de validation sont relativement faibles lorsque σ^0 est utilisée seule ou en combinaison avec la hauteur H_R (%RMSE de de 40 % ou 53 %). Ces résultats de validation sont meilleurs à ceux des indices de textures dérivés des images optiques multispectrales (Tableau 7.9). La diffusion volumique et la sensibilité au couvert de forêt dans la polarisation HV expliquent les

résultats obtenus (Ho Tong Minh *et al.*, 2018; El Hajj *et al.*, 2019). Cependant, les zones forestières très denses, comme la partie nord-ouest du site d'étude, peuvent produire des effets de saturation de la BA, et pourraient donc limiter l'utilisation des données radar en bande L (Bouvier *et al.*, 2018).

De toutes les variables individuelles de l'étude, les hauteurs médianes de la canopée (RH50) dérivées des données LiDAR ont montré les plus fortes capacités à estimer la BA de la forêt avec de faibles erreurs de validation (Tableau 7.9, Modèle 7 : $R^2 = 0,84$; $P < 0,0001$; % RE = 39 %; %RMSE = 28 %). Ce résultat est en conformité avec des études antérieures (Labriere *et al.*, 2018; Saatchi *et al.*, 2019). La topographie relativement plane du site est un facteur favorable, faisant en sorte que la densité de 2,3 points LiDAR par mètre carré lors de l'acquisition n'ait pas été un facteur limitatif. Cette dernière peut en effet être un facteur critique pour mieux caractériser les attributs de la forêt (Leitold *et al.*, 2015).

Les résultats de l'estimation des BA à l'aide de RH50 avec les données d'entraînement et de validation s'améliorent lorsqu'une combinaison est faite avec les variables optiques ou radar (Tableaux 7.8, 7.9; Modèles 11 à 14). Ainsi, le meilleur modèle obtenu dans cette recherche (Modèle 14) combine RH50, l'indice FOTO PC2, σ^0 et l'indice de texture GLCM moyenne ($R^2 = 0,89$; $P < 0,0001$; % RE = -9 %; %RMSE = 23,7 %). En effet, le LiDAR caractérise mieux la hauteur des peuplements. L'ajout des indices FOTO ou des variables radar apporte des informations complémentaires sur les structures spatiales (volume, couronne, densité), favorisant ainsi une meilleure estimation de la BA. Ces résultats ont montré l'importance de la combinaison des données de télédétection issues de techniques d'acquisition différentes pour estimer la BA dans les forêts tropicales. Cette conclusion est similaire à celles d'autres études antérieures (Sun *et al.*, 2011; Zhang *et al.*, 2014; Kumar *et al.*, 2015; Almeida *et al.*, 2019; Li *et al.*, 2020). Elle vérifie nos hypothèses de départ.

L'approche MARS a été utilisée pour développer les modèles d'estimation de la BA de l'étude; elle est très peu exploitée malgré son fort potentiel (Vaglio Laurin *et al.*, 2016; Baloloy *et al.*, 2018; Migolet et Goïta, 2020). Les modèles développés avec MARS ont davantage sommé les fonctions de base linéaires et ont moins utilisé les termes d'interactions entre les variables. Ces interactions sont plus observées avec les indices de texture (FOTO ou GLCM) de l'image optique, qui ont des relations beaucoup plus indirectes avec la BA que les hauteurs extraites du LiDAR ou du radar (voir par exemple Modèles 5, 8, 9 et 10). Les meilleurs modèles de l'étude

sont constitués uniquement de fonctions de base (ex. modèles 7 et 14). Le nombre relativement limité de placettes échantillons disponibles influence la nature des modèles ainsi que leurs performances. Li *et al.*, (2009) confirment cette affirmation.

Les BA de la carte (Figure 7.9) du meilleur modèle de l'étude (modèle 14) sont plus semblables aux BA de terrain qu'aux BA de toutes les cartes existantes (Tableau 7.10). Les cartes de Bouvet *et al.*, (2018) et de Labriere *et al.*, (2018) (résolution spatiale = 0,25 ha) ont produit des erreurs trop grandes (%RMSE > 80 %, Tableau 7.10). Les erreurs des BA de la carte de Saatchi *et al.*, (2018) ont été plus faibles (%RMSE = 68 %) comparées aux BA de toutes les cartes existantes (Tableau 7.10). Les différences d'échelles et les résolutions spatiales entre les cartes peuvent exercer une influence sur les résultats des comparaisons (Tableau 7.10, Figure 7.9). La forte hétérogénéité de la forêt du site d'étude (forêts matures, secondaires, jeunes-adultes ou inondables) a contribué à réduire la sensibilité des variables de télédétection utilisées pour produire les différentes cartes.

Au delà des résultats intéressants obtenus au cours de l'estimation de la BA de la forêt avec MARS à l'aide des données combinées de télédétection, le présent travail souffre d'un manque de données qui limite les nombres d'échantillons utilisés pour l'entraînement et la validation des différents modèles. Aussi, même si une combinaison de données paraît intéressante en termes de recherche, l'utilisation opérationnelle de telles approches peut être problématique. Disposer de données LiDAR et radar polarimétriques en même temps n'est pas très évident. En milieu tropical, les nuages peuvent constituer une grande limitation à la fois pour les données optiques et LiDAR.

9.4 Analyse de la dynamique de la biomasse due au remplacement des forêts par les palmeraies

Les pertes et les gains de la BA occasionnés par les conversions des forêts en palmeraies ont été évaluées dans le chapitre 8 pour deux sites d'étude dans le Bassin du Congo. L'examen des valeurs des BA des forêts et des palmiers à huile montre avec clarté que les BA maximales des forêts matures ($584,4 \text{ t ha}^{-1}$) et secondaires ($\geq 145 \text{ t ha}^{-1}$) sont nettement plus élevées que celles des palmiers à huile (72 t ha^{-1}) (Figure 8.1). En revanche, les forêts secondaires jeunes-adultes ou inondables présentent des biomasses égales ou plus faibles que celles des palmiers ($\leq 72 \text{ t ha}^{-1}$). Ainsi, les conversions des forêts matures ou secondaires en palmeraies occasionnent principalement des pertes de BA supérieures à 50 %. Spécifiquement les pertes seront de l'ordre

de 88 % lorsque les forêts matures sont converties, de 70 % pour les forêts secondaires vieilles, et de 51 % pour les forêts secondaires jeunes-adultes ou inondables (Figure 8a). Le long temps de croissance des forêts matures (≥ 100 ans) et secondaires (< 100 ans) par rapport aux palmiers à huile des plantations industrielles (35 à 40 ans), ainsi que la nature intrinsèque de ces couverts forestiers pourraient expliquer les différences importantes en biomasse, et les pertes qu'induirait les remplacements (Helmer *et al.*, 2009; Becknell *et al.*, 2012). Kho et Rudbeck-Jepsen (2015) ont aussi trouvé des résultats similaires à la présente étude en Malaisie.

Contrairement aux forêts matures et secondaires, les forêts secondaires jeunes-adultes ou inondables, les sols nus ou des forêts en repousse présentent des biomasses plus faibles que celles qu'on retrouve dans les plantations de palmiers (Figure 8.1). Leur conversion pourrait se traduire en un gain de biomasse (Figure 8a). Les BA maximales des palmiers à huile sur une terre ferme (72 t ha^{-1}) sont plus élevées à celles des palmiers à huile sur une terre inondable (59 t ha^{-1}) (Figure 8.1). Suivant ces valeurs, les palmiers sur une terre ferme occasionnent plus de gain de BA (38 % à 100 % soit 20 à 72 t ha^{-1}) que les palmiers à huile sur une terre inondable (12 à 100 % soit 7 à 59 t ha^{-1}) pendant la conversion des forêts en palmiers. Les palmiers sur une terre ferme sont localisés dans un environnement favorable à leur croissance, alors que ceux sur une terre inondable ont une croissance réduite à cause de la présence de l'eau. Ces aspects contribuent grandement à la variation de l'accumulation de la BA dans ces deux types de peuplement (Ngiye, 2015). Malgré leurs biomasses relativement faibles, substituer les forêts secondaires jeunes-adultes par des palmiers ne permettrait pas un gain de biomasse à long terme. Ces forêts croissent avec le temps et accumulent davantage de biomasse, ce qui est favorable à la lutte contre les changements climatiques.

CHAPITRE 10. Conclusion et perspectives

10.1 Conclusion

La présente thèse a mené des travaux de recherche sur l'utilisation de la télédétection pour l'analyse de la dynamique de la biomasse aérienne sèche totale des palmiers à huile et des forêts dans le Bassin du Congo. Elle a abouti à plusieurs résultats qui peuvent mener à une meilleure compréhension de la dynamique de la biomasse due à la conversion des forêts en palmeraies. Ainsi, les proportions en biomasse des tiges des palmiers à huile abattus sont plus importantes que celles des feuilles (incluant les pétioles, les rachis, les folioles et les fruits). L'utilisation de variables explicatives composées prenant en compte la tige (DHP^2H_T) et les feuilles ($DHP^2H_TN_F$) permet une meilleure estimation de la biomasse des palmiers à huile. L'étude démontre que l'approche MARS utilisée avec des indices de texture FOTO permet une bonne estimation de la biomasse des palmiers. Cependant, la résolution spatiale de l'image doit être la plus fine possible. De plus, il est préférable que l'image ne subisse pas de corrections radiométriques ou atmosphériques préalables pour ne pas altérer les textures. Les meilleurs résultats ont été obtenus avec l'image FORMOSAT-2 non corrigée, comparée à PlanetScope, qui est corrigée des effets atmosphériques dans cette recherche. L'approche MARS s'est révélée performante dans l'étude des BA des forêts. Parmi les différentes variables considérées, la hauteur médiane (RH50) de la canopée dérivée des données LiDAR est la plus corrélée à la BA. Les variables issues des données PolInSAR et l'indice FOTO PC2 donnent des résultats significatifs, contrairement aux indices de textures GLCM. Les meilleurs modèles obtenus combinent ces différentes variables de télédétection multisource pour estimer la biomasse, avec des erreurs relativement faibles variant autour de 24 %. Cette recherche confirme que les modèles locaux permettent une estimation plus précise de la BA des forêts tropicales que les modèles régionaux, continentaux ou globaux. Le développement des modèles locaux de BA à l'aide des données propres à la zone d'étude pourrait expliquer les résultats obtenus. Le meilleur modèle développé dans le cadre de l'étude avec l'approche MARS se caractérise par des incertitudes plus faibles comparées à celles des travaux existants touchant la zone d'étude. La conversion éventuelle des forêts (notamment matures et secondaires) par des plantations de palmiers provoquerait des pertes de biomasses importantes de plus de 50 %.

Les travaux de la présente thèse ont été confrontés à diverses limites. Elles concernent notamment les erreurs de mesures de terrain, les palmiers à huile d'âges identiques, ainsi que

le nombre relativement peu élevé de palmiers abattus (18) pour les fins de la recherche à cause des contraintes rattachées aux méthodes destructives. Dans le cas des 75 placettes échantillons disponibles pour la forêt, ce nombre aurait idéalement pu être plus élevé pour couvrir plus adéquatement les différentes classes de biomasse et types de forêt. Les limitations ne viennent pas seulement des mesures *in situ*. Les bruits inhérents aux données de télédétection, et leurs niveaux de sensibilité aux attributs forestiers en milieu tropical humide constituent également des limitations additionnelles.

10.2 Contributions originales

L'une des originalités majeures de cette étude repose davantage sur les données *in situ* inédites produites par méthode destructive sur les palmiers à huile dans le Bassin du Congo, et sur l'établissement d'équations allométriques locales permettant de calculer leur biomasse. Le développement de modèles d'estimation de la biomasse basés sur l'approche MARS et les indices FOTO issus d'images optiques apparaît tout aussi original. La réalisation d'une carte de BA des palmiers à huile avec une telle méthode est une première dans la littérature. Dans le même ordre d'idée, l'approche MARS a permis de combiner des variables multisource de télédétection (optique, LiDAR, radar interférométrique) pour développer des modèles permettant une meilleure estimation de la BA dans les forêts tropicales. C'est aussi une contribution significative et originale de cette thèse. En la combinant au travail réalisé sur les palmiers à huile, il a été possible d'analyser pour la première fois les pertes et gains en biomasse qui résulteraient d'une conversion éventuelle des forêts en plantations de palmiers dans le Bassin du Congo.

10.3 Perspectives

Les modèles et cartes de BA développés dans la présente étude permettront d'évaluer la BA des palmiers à huile et des arbres de forêts avec une meilleure précision et de comprendre la dynamique des BA de ces deux végétaux. L'obtention de ces informations sur les BA contribueront à une meilleure détermination des stocks de carbone nécessaires à la lutte contre les changements climatiques. Pour les études futures, des efforts devraient être mis sur le développement d'équations régionales et pantropicales de BA de tous les stades de croissance des palmiers à huile. Des inventaires forestiers des forêts matures et des mangroves devraient être menées pour établir des modèles de BA plus robustes. Des données récentes de terrain et de télédétection devraient également être acquises sur de vastes superficies de forêt et des palmeraies de divers âges. L'analyse chronologique de la dynamique de la BA devrait être

élargie et approfondie, en prenant en compte le passé et en simulant le futur (ex : 1970-2050). Cette analyse permettrait de rendre compte des pertes et des gains de BA dus au remplacement des forêts par des palmeraies ou d'autres plantations industrielles (cacaoyer, hévéa, caféier, etc.) sur une longue période dans le contexte des changements climatiques.

Références (hors articles)

- Abourou Otogo, R., Mboumba, G. B., Obiang, P. M., Obame, J. C. A., Ella, J., Mangongo, G. C., Johnson, A. E. D., Aguewhet, M. P., Bamoissi, J. E., Ntoungou, C. M., Boussamba, H., Moukoumi, D. V. B., Matsaya, Y. K., Ossavou, V., Nkoumankali, D. B., Migolet, P., Boundjang, D. D., Otogo, E. C., N'Gosso, H. et Ongalla, P. Y. (2018) Troisième communication nationale du Gabon à la convention cadre des nations unies sur les changements climatiques. Rapport technique finale de l'équipe de préparation de la troisième communication nationale/Ministère en charge de l'environnement, p. 275.
- Asari, N., Suratman, M. N. et Jaafar, J. (2017) Modelling and mapping of above ground biomass (AGB) of oil palm plantations in Malaysia using remotely-sensed data. International Journal of Remote Sensing, vol. 38, n°16, p. 4741-4764.
- Attema, E. P. W. et Ulaby, F. T. (1978) Vegetation modeled as a water cloud. Radio Science, vol. 13, n°2, p. 357-364.
- Austin, K. G., Lee, M. E., Clark, C., Forester, B. R., Urban, D. L., White, L., Kasibhatla, P. S. et Poulsen, J. R. (2017) An assessment of high carbon stock and high conservation value approaches to sustainable oil palm cultivation in Gabon. Environmental Research Letters, vol. 12, n°1, p. 014005-014005.
- Baccini, A., Friedl, M. A., Woodcock, C. E. et Warbington, R. (2004) Forest biomass estimation over regional scales using multisource data. Geophysical Research Letters, vol. 31, n°10, p. 1-4.
- Becknell, J. M., Kissing Kucek, L. et Powers, J. S. (2012) Aboveground biomass in mature and secondary seasonally dry tropical forests: A literature review and global synthesis. Forest Ecology and Management, vol. 276, p. 88-95.
- Blackard, J. A., Finco, M. V., Helmer, E. H., Holden, G. R., Hoppus, M. L., Jacobs, D. M., Lister, A. J., Moisen, G. G., Nelson, M. D., Riemann, R., Ruefenacht, B., Salajanu, D., Weyermann, D. L., Winterberger, K. C., Brandeis, T. J., Czaplewski, R. L., McRoberts, R. E., Patterson, P. L. et Tymcio, R. P. (2008) Mapping U.S. forest biomass using nationwide forest inventory data and moderate resolution information. Remote Sensing of Environment, vol. 112, n°4, p. 1658-1677.
- Bloch, I. (2003) Fusion d'informations en traitement du signal et des images. Paris : Hermès Science Publication, IC2 Série Traitement du signal et de l'image, vol. 1, p. 319.
- Bojórquez, A., Martínez-Yrízar, A., Búrquez, A., Jaramillo, V. J., Mora, F., Balvanera, P. et Álvarez-Yépez, J. C. (2020) Improving the accuracy of aboveground biomass

- estimations in secondary tropical dry forests. *Forest Ecology and Management*, vol. 474, p. 118384.
- Brigot, G., Simard, M., Colin-Koeniguer, E. et Boulch, A. (2019) Retrieval of Forest Vertical Structure from PolInSAR Data by Machine Learning Using LIDAR-Derived Features. *Remote Sensing*, vol. 11, n°4, p. 381.
- Brown, S. et Gaston, G. (1995) Use of Forest Inventories and Geographic Information Systems to Estimate Biomass Density of Tropical Forests: Application to Tropical Africa. *Environmental monitoring and assessment*, vol. 38, p. 157-68.
- Carreiras, J., Melo, J. et Vasconcelos, M. (2013) Estimating the Above-Ground Biomass in Miombo Savanna Woodlands (Mozambique, East Africa) Using L-Band Synthetic Aperture Radar Data. *Remote Sensing*, vol. 5, n°4, p. 1524-1548.
- Catry, T., Pottier, A., Marti, R., Li, Z., Roux, E., Herbreteau, V., Mangeas, M., Demagistri, L., Gurgel, H. et Dessay, N. (2018) Apports de la combinaison d'images satellites optique et RADAR dans l'étude des maladies à transmission vectorielle : cas du paludisme à la frontière Guyane française – Brésil. *Confins. Revue franco-brésilienne de géographie / Revista franco-brasilera de geografia*, n°37, p. 1-32.
- Chave, J., Condit, R., Aguilar, S., Hernandez, A., Lao, S. et Perez, R. (2004) Error propagation and scaling for tropical forest biomass estimates. (Y. Malhi et O. L. Phillips, Dir.). *Philosophical Transactions of the Royal Society of London. Series B: Biological Sciences*, vol. 359, n°1443, p. 409-420.
- Chazette, P., Totems, J., Hespel, L. et Bailly, J.-S. (2016) Principe et physique de la mesure lidar. Chap 5. 209-249 in Baghdadi, N et Zribi, M (réd) *Observation des surfaces continentales par télédétection optique ; techniques et méthodes*. (ISTE Editions Ltd., Vol. 1). Londres.
- Chen, P. et Wang, F. (2020) New Textural Indicators for Assessing Above-Ground Cotton Biomass Extracted from Optical Imagery Obtained via Unmanned Aerial Vehicle. *Remote Sensing*, vol. 12, n°24, p. 4170.
- Chi, H., Sun, G., Huang, J., Guo, Z., Ni, W. et Fu, A. (2015) National Forest Aboveground Biomass Mapping from ICESat/GLAS Data and MODIS Imagery in China. *Remote Sensing*, vol. 7, n°5, p. 5534-5564.
- Cloude, S. R. et Papathanassiou, K. P. (1998) Polarimetric SAR interferometry. *IEEE Transactions on Geoscience and Remote Sensing*, vol. 36, n°5, p. 1551-1565.
- Coops, N. C., Tompalski, P., Goodbody, T. R. H., Queinnec, M., Luther, J. E., Bolton, D. K., White, J. C., Wulder, M. A., van Lier, O. R. et Hermosilla, T. (2021) Modelling lidar-

- derived estimates of forest attributes over space and time: A review of approaches and future trends. *Remote Sensing of Environment*, vol. 260, p. 112477.
- Corlett, R. T. (1994) What is secondary forest? *Journal of Tropical Ecology*, vol. 10, n°3, p. 445-447.
- Cornet, A. (1981) Mesure de biomasse et détermination de la production nette aérienne de la strate herbacée dans trois groupements végétaux de la zone sahélienne au Sénégal. *Acta Oecologica*, vol. 2 (16), n°3, p. 251-266.
- Department of Economic and Social Affairs-United Nations (2021) *World Population Prospects - Population Division - United Nations*.
- Djomo, A. N., Ibrahima, A., Saborowski, J. et Gravenhorst, G. (2010) Allometric equations for biomass estimations in Cameroon and pan moist tropical equations including biomass data from Africa. *Forest Ecology and Management*, vol. 260, n°10, p. 1873-1885.
- Earthsight (2018) Congo Basin: The coming storm | How secrecy and collusion in industrial agriculture spell disaster for the Congo Basin's rainforests. Wolrd Rainforest Movement. Bulletin 237.
- Ebuy, J., Lokombe, J., Ponette, Q., Sonwa, D. et Picard, N. (2011) Allométric equation for predicting aboveground biomass of three species. *Journal of Tropical Forest Science*, vol. 23, n°2, p. 125-132.
- FAO (2021) *Évaluation des ressources forestières mondiales 2020: Rapport principal*. Rome, Italy: FAO.
- Fayolle, A., Doucet, J.-L., Gillet, J.-F., Bourland, N. et Lejeune, P. (2013) Tree allometry in Central Africa: Testing the validity of pantropical multi-species allometric equations for estimating biomass and carbon stocks. *Forest Ecology and Management*, vol. 305, p. 29-37.
- Ferro-Famil, L. et Pottier, E. (2016) 1 - Synthetic Aperture Radar Imaging. In N. Baghdadi et M. Zribi (dir.), *Microwave Remote Sensing of Land Surface* (p. 1-65). Elsevier.
- Fichet, L., Sannier, C., Makaga, E. M. K. et Seyler, F. (2014) Assessing the Accuracy of Forest Cover Map for 1990, 2000 and 2010 at National Scale in Gabon. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 7, n°4, p. 1346-1356.
- Galidaki, G., Zianis, D., Gitas, I., Radoglou, K., Karathanassi, V., Tsakiri-Strati, M., Woodhouse, I. et Mallinis, G. (2017) Vegetation biomass estimation with remote sensing: focus on forest and other wooded land over the Mediterranean ecosystem. *International Journal of Remote Sensing*, vol. 38, n°7, p. 1940-1966.

- Garestier, F. (2006) Evaluation du potentiel de la technique PolInSAR pour l'estimation des paramètres physiques de la végétation en conditions satellitaires (phdthesis). Thèse de doctorat, Université Sciences et Technologies - Bordeaux I.
- Ghasemi, N., Sahebi, M. R. et Mohammadzadeh, A. (2011) A review on biomass estimation methods using synthetic aperture radar data. International Journal of Geomatics and Geosciences, vol. 1, n°4, p. 776-788.
- Gleason, C. J. et Im, J. (2012) Forest biomass estimation from airborne LiDAR data using machine learning approaches. Remote Sensing of Environment, vol. 125, p. 80-91.
- Gonçalves, F., Treuhaft, R., Law, B., Almeida, A., Walker, W., Baccini, A., Dos Santos, J. R. et Graça, P. (2017) Estimating Aboveground Biomass in Tropical Forests: Field Methods and Error Analysis for the Calibration of Remote Sensing Observations. Remote Sensing, vol. 9, n°1, p. 47.
- Gould, S. J. (1971) Geometric Similarity in Allometric Growth: A Contribution to the Problem of Scaling in the Evolution of Size. The American Naturalist, vol. 105, n°942, p. 113-136.
- Han, S. H. et Park, B. B. (2020) Comparison of Allometric Equation and Destructive Measurement of Carbon Storage of Naturally Regenerated Understory in a *Pinus rigida* Plantation in South Korea. Forests, vol. 11, n°4, p. 425.
- Hardwick, S. R., Toumi, R., Pfeifer, M., Turner, E. C., Nilus, R. et Ewers, R. M. (2015) The relationship between leaf area index and microclimate in tropical forest and oil palm plantation: Forest disturbance drives changes in microclimate. Agricultural and Forest Meteorology, vol. 201, p. 187-195.
- Helmer, E., Lefsky, M. et Roberts, D. (2009) Biomass Accumulation Rates of Amazonian Secondary Forest and Biomass of Old-Growth Forests from Landsat Time Series and GLAS. AGU Fall Meeting Abstracts.
- Henry, M., Bombelli, A., Trotta, C., Alessandrini, A., Birigazzi, L., Sola, G., Vieilledent, G., Santenoise, P., Longuetaud, F., Valentini, R., Picard, N. et Saint-André, L. (2013) GlobAllomeTree: international platform for tree allometric equations to support volume, biomass and carbon assessment. iForest: Biogeosciences and Forestry, vol. 6, p. E1-E5.
- Hyppä, J. et Hallikainen, M. (1996) Applicability of airborne profiling radar to forest inventory. Remote Sensing of Environment, vol. 57, n°1, p. 39-57.
- IPCC-Robert T. Watson, Ian R. Noble, Bert Bolin, N.H. Ravindranath, David J. Verardo and David J. Dokken (Eds). (2000) Land Use, Land-Use Change, and Forestry. Cambridge

- University Press, UK. pp 375 Available from Cambridge University Press, The Edinburg Building Shaftesbury Road, Cambridge CB2 2RU ENGLAND.
- Jacquemoud, S., Verhoef, W., Baret, F., Bacour, C., Zarco-Tejada, P. J., Asner, G. P., François, C. et Ustin, S. L. (2009) PROSPECT+SAIL models: A review of use for vegetation characterization. *Remote Sensing of Environment*, vol. 113, p. S56-S66.
- Kashongwe, H. B., Roy, D. P. et Bwangoy, J. R. B. (2020) Democratic Republic of the Congo Tropical Forest Canopy Height and Aboveground Biomass Estimation with Landsat-8 Operational Land Imager (OLI) and Airborne LiDAR Data: The Effect of Seasonal Landsat Image Selection. *Remote Sensing*, vol. 12, n°9, p. 1360.
- Kuhn, M. et Johnson, K. (2013) Applied Predictive Modeling. New York, NY : Springer New York.
- Lasserre, G. (1955) Okoumé et chantiers forestiers du Gabon. *Les Cahiers d'Outre-Mer*, vol. 8, n°30, p. 119-160.
- Laurance, W. F., Sayer, J. et Cassman, K. G. (2014) Agricultural expansion and its impacts on tropical nature. *Trends in Ecology & Evolution*, vol. 29, n°2, p. 107-116.
- Lewis, K., Rumpang, E., Kho, L. K., McCalmont, J., Teh, Y. A., Gallego-Sala, A. et Hill, T. C. (2020) An assessment of oil palm plantation aboveground biomass stocks on tropical peat using destructive and non-destructive methods. *Scientific Reports*, vol. 10, n°1, p. 2230.
- Li, C., Zhou, L. et Xu, W. (2021) Estimating Aboveground Biomass Using Sentinel-2 MSI Data and Ensemble Algorithms for Grassland in the Shengjin Lake Wetland, China. *Remote Sensing*, vol. 13, n°8, p. 1595.
- Li, D. H. W., Chen, W., Li, S. et Lou, S. (2019) Estimation of hourly global solar radiation using Multivariate Adaptive Regression Spline (MARS) – A case study of Hong Kong. *Energy*, vol. 186, p. 115857-115857.
- Li, Y., Li, M., Li, C. et Liu, Z. (2020) Forest aboveground biomass estimation using Landsat 8 and Sentinel-1A data with machine learning algorithms. *Scientific Reports*, vol. 10, n°1, p. 9952.
- Lopez-Gonzalez, G., Lewis, S. L., Burkitt, M. et Phillips, O. L. (2011) ForestPlots.net: a web application and research tool to manage and analyse tropical forest plot data. *Journal of Vegetation Science*, vol. 22, n°4, p. 610-613.
- Lu, D. et Batistella, M. (2005) Exploring TM image texture and its relationships with biomass estimation in Rondônia, Brazilian Amazon. *Acta Amazonica*, vol. 35, n°2, p. 249-257.

- Lu, D., Chen, Q., Wang, G., Moran, E., Batistella, M., Zhang, M., Vaglio Laurin, G. et Saah, D. (2012) Aboveground Forest Biomass Estimation with Landsat and LiDAR Data and Uncertainty Analysis of the Estimates. International Journal of Forestry Research, vol. 2012, p. 1-16.
- Lu, H., Suo, Z., Guo, R. et Bao, Z. (2013) S-RVoG model for forest parameters inversion over underlying topography. Electronics Letters, vol. 49, n°9, p. 618-620.
- Lund, J. F., Sungusia, E., Mabele, M. B. et Scheba, A. (2017) Promising Change, Delivering Continuity: REDD+ as Conservation Fad. World Development, vol. 89, p. 124-139.
- Michez, A. (2016) Caractérisation des forêts à l'aide de la technologie lidar. Chap. 8, p. 322-348 in Baghdadi, N et Zribi, M (réd) Observation des surfaces continentales par télédétection I ; agriculture et forêt. (ISTE Editions Ltd., Vol. 3). Londres.
- Montesano, P. M., Cook, B. D., Sun, G., Simard, M., Nelson, R. F., Ranson, K. J., Zhang, Z. et Luthcke, S. (2013) Achieving accuracy requirements for forest biomass mapping: A spaceborne data fusion method for estimating forest biomass and LiDAR sampling error. Remote Sensing of Environment, vol. 130, p. 153-170.
- Mrema, G. C., Baker, D. C. et Kahan, D. (2008) Agricultural mechanization in Sub-saharan Africa: time for a new look. Rome: Food and Agriculture Organization on the United Nations.
- Mukhopadhyay, R., Kumar, S., Aghababaei, H. et Kulshrestha, A. (2021) Estimation of aboveground biomass from PolSAR and PolInSAR using regression-based modelling techniques. Geocarto International, p. 1-27.
- Ngiye, E. (2015) La filière palmier à huile au Burundi : acteurs et territoires. Thèse de doctorat, Université de Toulouse, Toulouse, France, 323 p.
- Oduro, S. D., Metia, S., Duc, H., Hong, G. et Ha, Q. P. (2015) Multivariate adaptive regression splines models for vehicular emission prediction. Visualization in Engineering, vol. 3, n°1, p. 13.
- Ozesmi, S. L. et Bauer, M. E. (2002) Satellite remote sensing of wetlands. Wetlands Ecology and Management, vol. 10, n°5, p. 381-402.
- Park, S.-E., Jung, Y. T., Cho, J.-H., Moon, H. et Han, S. (2019) Theoretical Evaluation of Water Cloud Model Vegetation Parameters. Remote Sensing, vol. 11, n°8, p. 894.
- Ploton, P., Barbier, N., Takoudjou Momo, S., Réjou-Méchain, M., Boyemba Bosela, F., Chuyong, G., Dauby, G., Droissart, V., Fayolle, A., Goodman, R. C., Henry, M., Kamdem, N. G., Mukirania, J. K., Kenfack, D., Libalah, M., Ngomanda, A., Rossi, V., Sonké, B., Texier, N., Thomas, D., Zebaze, D., Couteron, P., Berger, U. et Pélissier, R.

- (2016) Closing a gap in tropical forest biomass estimation: taking crown mass variation into account in pantropical allometries. *Biogeosciences*, vol. 13, n°5, p. 1571-1585.
- Ploton, P., Mortier, F., Rejou-Mechain, M., Barbier, N., Picard, N., Rossi, V., Dormann, C. F., Cornu, G., Viennois, G., Bayol, N., Lyapustin, A. I., Gourlet-Fleury, S. et Pélassier, R. (2020) Spatial validation reveals poor predictive performance of large-scale ecological mapping models. *Nature Communications*.
- Ramdani, F. et Hino, M. (2013) Land Use Changes and GHG Emissions from Tropical Forest Conversion by Oil Palm Plantations in Riau Province, Indonesia. *PLOS ONE*, vol. 8, n°7, p. e70323.
- Saatchi, S., Houghton, R., Alvalá, R., Soares, J. et YU, Y. (2007) Distribution of aboveground live biomass in the Amazon basin. *Global Change Biology*, vol. 13, p. 816-837.
- Schepaschenko, D., Chave, J., Phillips, O. L., Lewis, S. L., Davies, S. J., Réjou-Méchain, M., Sist, P., Scipal, K., Perger, C., Herault, B., Labrière, N., Hofhansl, F., Affum-Baffoe, K., Aleinikov, A., Alonso, A., Amani, C., Araujo-Murakami, A., Armston, J., Arroyo, L., Ascarrunz, N., Azevedo, C., Baker, T., Bałazy, R., Bedeau, C., Berry, N., Bilous, A. M., Bilous, S. Y., Bissiengou, P., Blanc, L., Bobkova, K. S., Braslavskaya, T., Brienen, R., Burslem, D. F. R. P., Condit, R., Cuni-Sánchez, A., Danilina, D., del Castillo Torres, D., Derroire, G., Descroix, L., Sotta, E. D., d'Oliveira, M. V. N., Dresel, C., Erwin, T., Evdokimenko, M. D., Falck, J., Feldpausch, T. R., Foli, E. G., Foster, R., Fritz, S., Garcia-Abril, A. D., Gornov, A., Gornova, M., Gothard-Bassébé, E., Gourlet-Fleury, S., Guedes, M., Hamer, K. C., Susanty, F. H., Higuchi, N., Coronado, E. N. H., Hubau, W., Hubbell, S., Ilstedt, U., Ivanov, V. V., Kanashiro, M., Karlsson, A., Karminov, V. N., Killeen, T., Koffi, J.-C. K., Konovalova, M., Kraxner, F., Krejza, J., Krisnawati, H., Krivobokov, L. V., Kuznetsov, M. A., Lakyda, I., Lakyda, P. I., Licona, J. C., Lucas, R. M., Lukina, N., Lussetti, D., Malhi, Y., Manzanera, J. A., Marimon, B., Junior, B. H. M., Martinez, R. V., Martynenko, O. V., Matsala, M., Matyashuk, R. K., Mazzei, L., Memiaghe, H., Mendoza, C., Mendoza, A. M., Morozuk, O. V., Mukhortova, L., Musa, S., Nazimova, D. I., Okuda, T., Oliveira, L. C., Ontikov, P. V., Osipov, A. F., Pietsch, S., Playfair, M., Poulsen, J., Radchenko, V. G., Rodney, K., Rozak, A. H., Ruschel, A., Rutishauser, E., See, L., Shchepashchenko, M., Shevchenko, N., Shvidenko, A., Silveira, M., Singh, J., Sonké, B., Souza, C., Stereńczak, K., Stonozhenko, L., Sullivan, M. J. P., Szatniewska, J., Taedoumg, H., ter Steege, H., Tikhonova, E., Toledo, M., Trefilova, O. V., Valbuena, R., Gamarra, L. V., Vasiliev, S., Vedrova, E. F., Verhovets, S. V., Vidal, E., Vladimirova, N. A., Vleminckx, J., Vos, V. A., Vozmitel, F. K., Wanek,

- W., West, T. A. P., Woell, H., Woods, J. T., Wortel, V., Yamada, T., Nur Hajar, Z. S. et Zo-Bi, I. C. (2019) The Forest Observation System, building a global reference dataset for remote sensing of forest biomass. *Scientific Data*, vol. 6, n°1, p. 198.
- Schlund, M. et Davidson, M. W. J. (2018) Aboveground Forest Biomass Estimation Combining L- and P-Band SAR Acquisitions. *Remote Sensing*, vol. 10, n°7, p. 1151.
- Shapiro, A. C., Grantham, H. S., Aguilar-Amuchastegui, N., Murray, N. J., Gond, V., Bonfils, D. et Rickenbach, O. (2021) Forest condition in the Congo Basin for the assessment of ecosystem conservation status. *Ecological Indicators*, vol. 122, p. 107268.
- Shi, L. et Liu, S. (2017) Methods of Estimating Forest Biomass: A Review. *Biomass Volume Estimation and Valorization for Energy* (Vol. Chapitre 2, p. 24-46).
- Shi, Y., He, B. et Liao, Z. (2021) An improved dual-baseline PolInSAR method for forest height inversion. *International Journal of Applied Earth Observation and Geoinformation*, vol. 103, p. 102483.
- Shooshtari, S. J. et Gholamalifard, M. (2015) Scenario-based land cover change modeling and its implications for landscape pattern analysis in the Neka Watershed, Iran. *Remote Sensing Applications: Society and Environment*, vol. 1, p. 1-19.
- Silva, C. A., Saatchi, S., Garcia, M., Labriere, N., Klauberg, C., Ferraz, A., Meyer, V., Jeffery, K. J., Abernethy, K., White, L., Zhao, K., Lewis, S. L. et Hudak, A. T. (2018) Comparison of small- and large-footprint lidar characterization of tropical forest aboveground structure and biomass: A case study from Central Gabon. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*. 11(10): 3512-3526., vol. 11, n°10, p. 3512-3526.
- Singh, M., Malhi, Y. et Bhagwat, S. (mai 2014a) Biomass estimation of mixed forest landscape using a Fourier transform texture-based approach on very-high-resolution optical satellite imagery. *International Journal of Remote Sensing*, vol. 35, n°9, p. 3331-3349.
- Singh, M., Malhi, Y. et Bhagwat, S. (2014b) Evaluating land use and aboveground biomass dynamics in an oil palm-dominated landscape in Borneo using optical remote sensing. *Journal of Applied Remote Sensing*, vol. 8, n°1.
- Sun, G., Ranson, K. J., Guo, Z., Zhang, Z., Montesano, P. et Kimes, D. (2011) Forest biomass mapping from lidar and radar synergies. *Remote Sensing of Environment*, vol. 115, n°11, p. 2906-2916.
- Sun, X., Wang, B., Xiang, M., Fu, X., Zhou, L. et Li, Y. (2019) S-RVoG Model Inversion Based on Time-Frequency Optimization for P-Band Polarimetric SAR Interferometry. *Remote Sensing*, vol. 11, n°9, p. 1033.

- Trephaft, R. N., Madsen, S. N., Moghaddam, M. et Zyl, J. J. van (1996) Vegetation characteristics and underlying topography from interferometric radar. *Radio Science*, vol. 31, n°6, p. 1449-1485.
- Tyukavina, A., Hansen, M. C., Potapov, P., Parker, D., Okpa, C., Stehman, S. V., Kommareddy, I. et Turubanova, S. (2018) Congo Basin forest loss dominated by increasing smallholder clearing. *Science Advances*, vol. 4, n°11, p. 12.
- Vazirabad, Y. F. et Karslioglu, M. O. (2011) Lidar for Biomass Estimation. *Biomass - Detection, Production and Usage*. IntechOpen.
- Verbeeck, H., Boeckx, P. et Steppe, K. (2011) Tropical forests: Include Congo basin. *Nature*, vol. 479, n°7372, p. 179-179.
- Villard, L., Le Toan, T., Ho Tong Minh, D., Mermoz, S. et Bouvet, A. (2016) Biomasse des forêts par télédétection radar. Chap. 9, 349-404 in Baghdadi, N et Zribi, M (réd) *Observation des surfaces continentales par télédétection I ; agriculture et forêt*. (ISTE Editions Ltd., Vol. 1). Londres.
- Vorster, A., Evangelista, P., Stovall, A. et Ex, S. (2020) Variability and uncertainty in forest biomass estimates from the tree to landscape scale: the role of allometric equations. *Carbon Balance and Management*, vol. 15.
- Waqar, M. M., Sukmawati, R., Ji, Y. et Sri Sumantyo, J. T. (2020) Tropical PeatLand Forest Biomass Estimation Using Polarimetric Parameters Extracted from RadarSAT-2 Images. *Land*, vol. 9, n°6, p. 193.
- Weiskittel, A. R., MacFarlane, D. W., Radtke, P. J., Affleck, D. L. R., Temesgen, H., Woodall, C. W., Westfall, J. A. et Coulston, J. W. (2015) A Call to Improve Methods for Estimating Tree Biomass for Regional and National Assessments. *Journal of Forestry*, vol. 113, n°4, p. 414-424.
- White, J. F. et Gould, S. J. (1965) Interpretation of the Coefficient in the Allometric Equation. *The American Naturalist*, vol. 99, n°904, p. 5-18.
- Willstätter, R. et Stoll, A. (1918) Untersuchungen Über die Assimilation der Kohlensäure: Sieben Abhandlungen (Verlag von Julius Springer.). Berlin : Springer-Verlag.
- Xiao, J., Chevallier, F., Gomez, C., Guanter, L., Hicke, J. A., Huete, A. R., Ichii, K., Ni, W., Pang, Y., Rahman, A. F., Sun, G., Yuan, W., Zhang, L. et Zhang, X. (2019) Remote sensing of the terrestrial carbon cycle: A review of advances over 50 years. *Remote Sensing of Environment*, vol. 233, p. 111383.

- Yadav, S., Padalia, H., Sinha, S., Srinet, R. et Chauhan, P. (2020) Above-ground biomass estimation of Indian tropical forests using X band Pol-InSAR and Random Forest. *Remote Sensing Applications Society and Environment*, vol. 21, p. 100462.
- Zhang, Y., Ma, J., Liang, S., Li, X. et Li, M. (2020) An Evaluation of Eight Machine Learning Regression Algorithms for Forest Aboveground Biomass Estimation from Multiple Satellite Data Products. *Remote Sensing*, vol. 12, n°24, p. 4015.
- Zhao, P., Lu, D., Wang, G., Wu, C., Huang, Y. et Yu, S. (2016) Examining Spectral Reflectance Saturation in Landsat Imagery and Corresponding Solutions to Improve Forest Aboveground Biomass Estimation. *Remote Sensing*, vol. 8, n°6, p. 469-469.
- Zhu, X. et Liu, D. (2015) Improving forest aboveground biomass estimation using seasonal Landsat NDVI time-series. *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 102, p. 222-231.

Annexe (hors articles)

Annexe 3 : Codes utilisés pour produire les indices FOTO

%-----

% NAME: rspectrum.m

% PROJECT: canopy structure project

% PURPOSE: calculate the r-spectra for a matrix (helper function)

% CATEGORY:

% CALLING SEQUENCE:

% INPUTS: x a square matrix, w size of the matix

% PARAMETERS:

% OUTPUTS:

% NOTES: the matrix (img) should be square or results will be discarded

% the output is an increment to i (global) and data that is

% written to matrix 'output' (global) to be defined beforehand.

% CREATION DATE: 01/07/2013

% AUTHOR: Koen Hufkens, koen.hufkens@gmail.com

% UPDATE: 29/07/2013

%-----

function i = rspectrum(img,windowsize)

% set global variables, these are defined in the final

% FOTO.m algorithm as well. If not called, data won't

% be written to these global variables and stay internal

% to the function.

% These variables should also be declared as global in the

% FOTO function, otherwise these will be overwritten with

% an empty matrix by the rspectrum function.

global i output;

% get the nr of pixels of the image fed

% into the function, will be used to

% determine if an image is square (to be processed)

```

% or not
[M, N] = size(img);
cells = M*N;

% check if
if windowsize == sqrt(cells)

% increase increment
i = i + 1;

% calculate the variance
img_var=var(reshape(img,N*M,1));

% FFT transform
tf = (abs(fft2(img))/(N*M)).^2;

% eliminates central peak
low = min(min(tf));
tf(1,2)=low;
tf(2,1)=low;
tf(1,end)=low;
tf(end,1)=0;

% center fft
tf = fftshift(tf);

% Make Cartesian grid
[X Y] = meshgrid(-M/2:M/2-1,-M/2:M/2-1);
[theta rho] = cart2pol(X, Y);

% get distances (round them)
rho = round(rho);
% create a matrix to contain the
% locations of given distance class

```

```

% pixels
count = cell(floor(M/2) + 1, 1);
% find locations of pixels
% for a given distance from the center of the image
for r = 0:floor(M/2)
    count{r + 1} = find(rho == r);
end

% create a vector to hold the distance averaged
% spectral data
Pf = zeros(1, floor(M/2)+1);

% fill this vector with the averaged data per
% distance class
for r = 0:floor(M/2)
    Pf(1, r + 1) = nanmean(tf(count{r+1}))/img_var;
    % set first two values to zero, inherent to image structure
    Pf(1:2) = 0;
end

if length(Pf) < 29
    output(i,1:length(Pf)) = Pf;
else
    output(i,1:29) = Pf(1:29);
end

else

    % in case of non square data
    % output increment value, nothing else
    i = i + 1;
end

end

```

```
%-----
% NAME: FOTO.m
% PROJECT: canopy structure project
% PURPOSE: classify image data based upon r-spectra
% CATEGORY:
% CALLING SEQUENCE: FOTO(imagefile,windowsize)
% INPUTS: an image layer, a block window size
% PARAMETERS:
% OUTPUTS: rspectra of image blocks
% NOTES: included rank normalization of the image
%       to deal with hazy clouds and uneven illumination
%       depends on rspectra.m
% CREATION DATE: 01/07/2013
% AUTHOR: Koen Hufkens, koen.hufkens@gmail.com
% UPDATE: 20/08/2013
%-----
```

```
function rspectra = FOTO(imagefile,windowsize)

% define global variables for the increment vector
% and the final output matrix (with rspectra)
global i output;

% set counter
i = 0;

% convert image to double and average
% image bands if necessary
img = imread(imagefile);
Z = size(img,3);

if Z == 1;
    img = double(img);
else
```

```

img = double(mean(img,3));
end

% get number of blocks that will be processed
% using the blockproc function below
[M N] = size(img);
M = ceil(M/windowsize);
N = ceil(N/windowsize);
cells = M*N;

% output matrix has a maximum vector length of 29
% only use the first 29 harmonics, if less are
% produce reduce the output file dimensions
if windowsize/2 < 29;
    output = zeros(cells,floor(windowsize/2));
else
    output = zeros(cells,29);
end

% blockprocess r spectra using rspectrum.m
% I'm currently working on an octave implementation to go completely GPL
fun = @(block_struct) rspectrum(block_struct.data,windowsize);
block_count = blockproc(img,[windowsize
windowsize],fun,'PadPartialBlocks',true,'PadMethod','symmetric','TrimBorder',true);

% finally, write output to csv files
% reshape the block_count file to get the
% correct order in the final output file
% blockproc doesn't calculate blocks perfectly row or column wise
loc_spectra = reshape(block_count,numel(block_count),1);
rspectra = output(loc_spectra,:);

% write rspectra to file, useful when calling
% the function from a non interactive matlab cli session

```

```
csvwrite('rspectra.csv',output(loc_spectra,:));  
% visualize the rspectra, reduce the dimensionality of the matrix using a  
% principal component analysis, mapping the first 3 PC to RGB colours  
% center the rspectra matrix by subtracting the column mean and dividing by  
% the standard deviation  
norm_rspectra = (rspectra - ones(size(rspectra,1),1)*mean(rspectra)) ./  
(ones(size(rspectra,1),1)*var(rspectra).^2);  
norm_rspectra(isnan(norm_rspectra)) = 0; % set NaN to 0, not allowed by princomp  
[~,score,~,~]=princomp(norm_rspectra);  
RGB=zeros(M,N,3);  
RGB(:,:,1)=reshape(score(:,1),M,N);  
RGB(:,:,2)=reshape(score(:,2),M,N);  
RGB(:,:,3)=reshape(score(:,3),M,N);  
  
% visualize the texture classification  
imshow(RGB);  
  
end
```