



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA, INOVAÇÕES E COMUNICAÇÕES
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

sid.inpe.br/mtc-m21b/2016/10.25.15.44-TDI

**SENSORIAMENTO REMOTO LIDAR E ÓPTICO
APLICADOS À ESTIMATIVA DE BIOMASSA AÉREA
DE MANGUEZAIS: ESTUDO DE CASO NA APA DE
GUAPIMIRIM, RJ**

Francisca Rocha de Souza Pereira

Tese de Doutorado do Curso de Pós-Graduação em Sensoriamento Remoto, orientada pelos Drs. Milton Kampel, e Gregoire Vincent, aprovada em 18 de novembro de 2016.

URL do documento original:

<http://urlib.net/8JMKD3MGP3W34P/3MM3DAP>

INPE
São José dos Campos
2017

PUBLICADO POR:

Instituto Nacional de Pesquisas Espaciais - INPE

Gabinete do Diretor (GB)

Serviço de Informação e Documentação (SID)

Caixa Postal 515 - CEP 12.245-970

São José dos Campos - SP - Brasil

Tel.:(012) 3208-6923/6921

Fax: (012) 3208-6919

E-mail: pubtc@inpe.br

COMISSÃO DO CONSELHO DE EDITORAÇÃO E PRESERVAÇÃO DA PRODUÇÃO INTELECTUAL DO INPE (DE/DIR-544):

Presidente:

Maria do Carmo de Andrade Nono - Conselho de Pós-Graduação (CPG)

Membros:

Dr. Plínio Carlos Alvalá - Centro de Ciência do Sistema Terrestre (CST)

Dr. André de Castro Milone - Coordenação de Ciências Espaciais e Atmosféricas (CEA)

Dra. Carina de Barros Melo - Coordenação de Laboratórios Associados (CTE)

Dr. Evandro Marconi Rocco - Coordenação de Engenharia e Tecnologia Espacial (ETE)

Dr. Hermann Johann Heinrich Kux - Coordenação de Observação da Terra (OBT)

Dr. Marley Cavalcante de Lima Moscati - Centro de Previsão de Tempo e Estudos Climáticos (CPT)

Silvia Castro Marcelino - Serviço de Informação e Documentação (SID)

BIBLIOTECA DIGITAL:

Dr. Gerald Jean Francis Banon

Clayton Martins Pereira - Serviço de Informação e Documentação (SID)

REVISÃO E NORMALIZAÇÃO DOCUMENTÁRIA:

Simone Angélica Del Ducca Barbedo - Serviço de Informação e Documentação (SID)

Yolanda Ribeiro da Silva Souza - Serviço de Informação e Documentação (SID)

EDITORAÇÃO ELETRÔNICA:

Marcelo de Castro Pazos - Serviço de Informação e Documentação (SID)

André Luis Dias Fernandes - Serviço de Informação e Documentação (SID)



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA, INOVAÇÕES E COMUNICAÇÕES
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

sid.inpe.br/mtc-m21b/2016/10.25.15.44-TDI

**SENSORIAMENTO REMOTO LIDAR E ÓPTICO
APLICADOS À ESTIMATIVA DE BIOMASSA AÉREA
DE MANGUEZAIS: ESTUDO DE CASO NA APA DE
GUAPIMIRIM, RJ**

Francisca Rocha de Souza Pereira

Tese de Doutorado do Curso de Pós-Graduação em Sensoriamento Remoto, orientada pelos Drs. Milton Kampel, e Gregoire Vincent, aprovada em 18 de novembro de 2016.

URL do documento original:

<http://urlib.net/8JMKD3MGP3W34P/3MM3DAP>

INPE
São José dos Campos
2017

Dados Internacionais de Catalogação na Publicação (CIP)

Pereira, Francisca Rocha de Souza.

P414s Sensoriamento remoto LIDAR e óptico aplicados à estimativa de biomassa aérea de manguezais: estudo de caso na APA de Guapimirim, RJ / Francisca Rocha de Souza Pereira. – São José dos Campos : INPE, 2017.

xxii + 189 p. ; (sid.inpe.br/mtc-m21b/2016/10.25.15.44-TDI)

Tese (Doutorado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2016.

Orientadores : Drs. Milton Kampel, e Gregoire Vincent.

1. LiDAR. 2. Imagem óptica de alta resolução. 3. Análise textural. 4. Estimativa de biomassa aérea. 5. Manguezal. I.Título.

CDU 528.711.7:633.876



Esta obra foi licenciada sob uma Licença [Creative Commons Atribuição-NãoComercial 3.0 Não Adaptada](https://creativecommons.org/licenses/by-nc/3.0/).

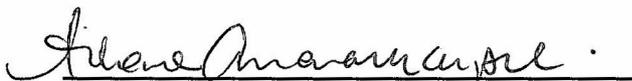
This work is licensed under a [Creative Commons Attribution-NonCommercial 3.0 Unported License](https://creativecommons.org/licenses/by-nc/3.0/).

Aluno (a): **Francisca Rocha de Souza Pereira**

Título: "SENSORIAMENTO REMOTO LIDAR E ÓPTICO APLICADOS À ESTIMATIVA DE BIOMASSA AÉREA DE MANGUEZAIS: ESTUDO DE CASO NA APA DE GUAPIMIRIM, RJ"

Aprovado (a) pela Banca Examinadora em cumprimento ao requisito exigido para obtenção do Título de **Doutor(a)** em **Sensoriamento Remoto**

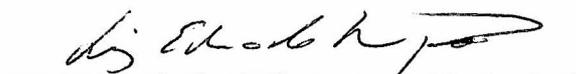
Dra. Silvana Amaral Kampel


Presidente / INPE / SJCampos - SP

Dr. Milton Kampel


Orientador(a) / INPE / SJCampos - SP

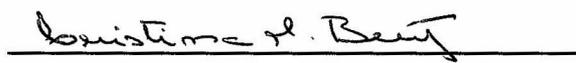
Dr. Luiz Eduardo Oliveira e Cruz de Aragão


Membro da Banca / INPE / São José dos Campos - SP

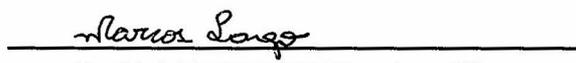
Dr. Dalton de Morisson Valeriano


Membro da Banca / INPE / SJCampos - SP

Dra. Cristina Maria Bentz


Convidado(a) / PETROBRAS / Rio de Janeiro - RJ

Dr. Marcos Longo


Convidado(a) / EMBRAPA / Campinas - SP

Este trabalho foi aprovado por:

() maioria simples

(X) unanimidade

São José dos Campos, 18 de novembro de 2016

*“Tudo o que encontrei
na minha longa descida,
montanhas, povoados,
caieiras, viveiros, olarias,
mesmo esses pés de cana
que tão iguais me pareciam,
tudo levava um nome
com que poder ser conhecido.
A não ser esta gente
que pelos mangues habita:
eles são gente apenas
sem nenhum nome que os distinga;
que os distinga na morte
que aqui é anônima e seguida.
São como ondas de mar,
uma só onda, e sucessiva.”*

O Rio - João Cabral de Melo Neto

À amorosa mãe Elizabeth e ao criativo e autêntico pai Dudu do banjo!..

AGRADECIMENTOS

Esta tese foi feita com muito carinho e contou com a participação de muitas pessoas, tanto no âmbito profissional, quanto pessoal. A colaboração de todos foi essencial para a elaboração deste trabalho.

Ao meu orientador Dr. Milton Kampel, por incentivar e acreditar neste estudo e me orientar durante todos estes anos acadêmicos. Ao co-orientador Gregoire Vincent pela orientação e dedicação com este estudo durante os meses que realizei o intercâmbio no laboratório *Botanique et Bio-informatique de l'Architecture des Plantes* (AMAP) do *Institut de Recherche pour le Développement* (IRD), Montpellier, França.

Agradeço à PETROBRÁS pelo compartilhamento de dados para esta pesquisa, em especial à Cristina Bentz e Leandro Freitas do CENPES/PETROBRÁS pela disponibilização dos dados LiDAR, imagens ópticas de alta resolução e dados de campo. Agradeço a colaboração com a Geoambiente.

A toda Equipe NEMA da UERJ em especial ao Dr. Mario Luiz Gomes Soares pela colaboração nas estimativas de biomassa de mangue em campo. Agradeço aos colegas da equipe NEMA Gustavo Duque Estrada, Daniel, Mayne, Viviane, Paula, Marciel e Brunna.

Ao cartógrafo e professor Paulo Gurgel pela dedicação e auxílio durante os trabalhos de campo na APA de Guapimirim.

À Coordenadora da Pós Graduação em Sensoriamento Remoto do INPE (PGSER) Dra. Elisabete Moraes e às secretárias Vera e Valéria, pela atenção nestes anos como aluna e suporte aos trabalhos acadêmicos e de campo.

A toda a equipe de funcionários da Biblioteca Central do INPE que me auxiliaram durante as pesquisas bibliográficas e formatações, Simone, Malu, Yolanda.

Aos docentes da PGSER pelos ensinamentos em especial à Dra. Evlyn Novo pelas sugestões, comentários e críticas durante a qualificação e proposta e Dr. Flavio Ponzoni pela atenção durante sua coordenação acadêmica.

Aos membros da banca Dr. Dalton Valeriano, Dr. Luiz Aragão, Dr. Marcos Longo, Dra Cristina Bentz e Dra. Silvana Amaral pelos comentários, críticas e sugestões e pela disponibilidade, atenção e tempo dedicado à avaliação deste trabalho.

Agradeço à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela bolsa concedida durante o doutorado e durante o intercâmbio sanduíche na França (Bolsista da CAPES - Processo: BEX 9861/14-9) que sem dúvida complementaram a minha formação acadêmica e ajudaram no desenvolvimento da tese.

A toda a equipe de coordenadores e gerenciadores da APA de Guapimirim pelo apoio durante os trabalhos de campo, em especial ao Julio Andrade e equipe do ICMBIO. Agradeço também aos barqueiros Carlinhos e Flavio Lontro.

Aos pesquisadores do laboratório *Botanique et Bio-informatique de l'Architecture des Plantes* (AMAP) do *Institut de Recherche pour le Développement* (IRD) da França pelo apoio e colaboração durante o meu estágio, em especial ao meu segundo orientador Gregoire Vincent e aos pesquisadores Pierre Couteron e Christophe Proisy.

À Profa. Matilde e Prof. Mário da Univap pelo estágio docência necessário à minha formação.

A meus pais e familiares pelo apoio emocional e profissional. Meu pai Dudu, minha mãe Beth pela presença e carinho, meus irmãos Emanuel, Ícaro, Fabíola, e os irmãos Tadeu, Tuca e Patrícia, incluindo todos os sobrinhos, meu avô Hugo e avó Cida, tio Adriano, tia Mara pelo apoio que sempre me deram. E em especial ao meu tio Huguinho pela paciência, conversas e dedicação e por me ajudar durante as fases mais intensas da tese.

A minha família de São José dos Campos, tia Clarisse e tio José Calvo, Alexandre e todos os primos pelo carinho.

Ao amigo Gabriel Moiano pelo essencial auxílio em campo.

Em especial às minhas amigas queridas que sempre estiveram presente em todos os momentos desta tese: Laura, Nathália, Lu Arasato, Janaína. E meu amigo especial Lico.

A todos os amigos e colegas do Inpe que foram essenciais nesta jornada: Silvia, Lu Sato, Liki, Marília, Aline, Matheus, Rodrigo Matos, Johnny e todos amigos do Grupo MOceanS, e do Nibiroots: Rodrigo, Eduardo, Liana, Ton, Renato, Aragão, Felipe, Alê, prof Chris Myai.

E a todos que fizeram parte desta trajetória e estão em meu coração!

RESUMO

Os manguezais são ecossistemas costeiros que ocorrem na interface entre a terra e o mar tipicamente em regiões tropicais, apresentando espécies adaptadas à salinidade e inundações pelas marés. Os manguezais realizam funções ecológicas essenciais para a manutenção da vida terrestre e marinha e para o sustento de comunidades costeiras. São importantes transformadores de nutrientes em matéria orgânica e geradores de bens e serviços como a estabilização e proteção da linha de costa, controle da poluição, sequestro de carbono atmosférico e regulação do clima. Seu atual desflorestamento é preocupante tanto ambientalmente como socioeconomicamente e sua restauração e conservação são importantes não só para a regulação dos fluxos de carbono e controle das mudanças climáticas, mas também para a manutenção de seus valiosos serviços prestados à zona costeira. No presente trabalho uma área relativamente extensa (~58,2 km²) de manguezal inserida na APA de Guapimirim na Baía de Guanabara, RJ foi estudada. O objetivo geral do estudo é averiguar o potencial uso de dados LiDAR aerotransportado de retorno discreto para estimar a biomassa acima do solo (AGB) do manguezal com distintos graus de alteração, e comparativamente, investigar o potencial uso de índices texturais derivados de imagem óptica de alta resolução WordView-2 para estimar a AGB e distinguir tipos de cobertura do manguezal. Foram extraídas 26 métricas descritivas da altura normalizada da nuvem de pontos LiDAR e os índices texturais *Fourier-based textural ordination* (FOTO) e *Grey-Level Co-occurrence Matrix* (GLCM) da imagem óptica pancromática. Foram testados os métodos de análise de regressão Random Forest, AutoPLS e PLS para estimativa da AGB. Foi demonstrado que o uso de dados LiDAR para estimativa de AGB de manguezal com distintos graus de alteração foi efetivo e superior aos resultados obtidos com uso dos índices texturais extraídos da imagem óptica. O modelo preditivo mais preciso da AGB utilizando dados LiDAR (M2a) apresentou $R^2(\text{CAL})=0,89$, $R^2(\text{LOO})=0,80$, $\text{RMSE}(\text{CAL})=11,20$ t/ha, $\text{RMSE}(\text{LOO})= 14,80$ t/ha e $\text{RSE}\% = 8,90$. As variáveis preditoras que mais contribuíram na modelagem foram avg, min, max, d02, d03, d04, d05 e d08 demonstrando que informações de densidade de pontos relativos aos estratos estruturais da floresta são importantes variáveis para a estimativa de AGB de bosques de mangue com distintos graus de alteração, bem como para detecção de áreas mais alteradas ou mais preservadas. O padrão de variabilidade textural associado às características dos dosséis florestais com distintos graus de alteração mensuradas pelos índices FOTO e GLCM não apresentou forte relação com os valores de AGB. Porém, a classificação Random Forest baseada nos índices texturais apresentou bons resultados na discriminação de tipos de cobertura como áreas de não mangue, mangue alterado e mangue mais preservado. A presente tese demonstra a eficácia do uso de técnicas de sensoriamento remoto, em especial de dados LiDAR de retorno discreto para estimar e mapear a AGB com boa acurácia e para discriminar tipos de cobertura no manguezal. Os resultados aqui apresentados podem contribuir com as análises e caracterização estrutural do manguezal, quantificação e qualificação da AGB e estoques de carbono, bem como, contribuir com o monitoramento, formulação de políticas públicas de conservação e proteção deste ecossistema, auxiliando a sua gestão.

Palavras-chave: LiDAR. Imagem óptica de alta resolução. Análise textural. Estimativa de biomassa aérea. Manguezal.

**LIDAR AND OPTIC REMOTE SENSING APPLIED TO MANGROVE
ABOVEGROUND BIOMASS ESTIMATES: STUDY CASE APA DE
GUAPIMIRIM, RJ**

ABSTRACT

Mangroves form important intertidal ecosystems that link terrestrial and marine systems typically in tropical and subtropical regions, presenting physiological and morphological adaptations to environmental stresses of high salinity and flooding by tides. Mangroves perform essential ecological functions for the maintenance of terrestrial and marine life and the livelihoods of coastal communities. They provide valuable ecological and economical ecosystem goods and services transforming nutrients in organic matter, contributing to coastal erosion protection, pollution control, atmospheric carbon sequestration and climate regulation, among many other factors. Nevertheless, mangroves have experienced a dramatic decline in area caused by overexploitation and conversion to other uses. Their restoration and conservation are important not only for the regulation of carbon fluxes and climate change control, but also to maintain their valuable services for the coastal zone. Remote sensing techniques offer a useful tool of estimating forest biomass contributing with the monitoring of land use and land cover dynamics and the effectiveness of environmental policies. In the present work a relatively large area (~58.2 km²) of mangroves inserted in the Environmental Protection Area of Guapimirim, Guanabara Bay, RJ was studied. The main goal of this study is to investigate the potential use of discrete return LiDAR data to estimate the aboveground biomass (AGB) of a mangrove forest with different degrees of disturbance, and comparatively investigate the potential use of textural indices derived from a high resolution WorldView-2 image to estimate AGB and to distinguish types of mangrove coverage. Twenty-six descriptive LiDAR metrics were extracted from the normalized height of the LiDAR point cloud data together with the Fourier-based textural ordination (FOTO) and Grey-Level Co-occurrence Matrix (GLCM) textural indices from the panchromatic optical image. Random Forest, AutoPLS and PLS regression methods were tested to estimate AGB. The results obtained using LiDAR data for estimating AGB were effective and superior to the results obtained using the textural indices. The most accurate predictive model of AGB using LiDAR data (M2a) presented $R^2(\text{CAL}) = 0.89$, $R^2(\text{LOO}) = 0.80$, $\text{RMSE}(\text{CAL}) = 11.20$ t/ha, $\text{RMSE}(\text{LOO}) = 14.80$ t/ha and $\text{RSE}\% = 8.90\%$. The most important predictor variables for the M2a model were avg, min, max, d02, d03, d04, d05 and d08 demonstrating that point density relative to the forest structural strata are important variables for the AGB estimation in mangrove forests with different degrees of disturbance as well as for detecting more altered or preserved areas. The textural variability pattern associated with the canopy characteristics with different degrees of disturbance measured by FOTO and GLCM indices showed weak relationships with AGB values. However, the Random Forest classification based on the textural indices showed good results on the discrimination of different types of coverage such as non-mangrove, altered and preserved mangroves. This thesis demonstrates the effectiveness use of remote sensing techniques, particularly discrete return LiDAR data to accurately estimate and map the AGB and to discriminate types of mangrove coverage. The results

presented here can contribute to the analysis and structural characterization of mangroves, its AGB and carbon stocks quantification and qualification, also contributing with the monitoring and formulation of public policies for the conservation and protection of this ecosystem.

Keywords: LiDAR. High resolution optical image. Textural analysis. Biomass estimation. Mangrove.

LISTA DE FIGURAS

	<u>Pág.</u>
Figura 2.1 - Demonstração do arranjo espacial das células adjacentes.	25
Figura 2.2 - Ordenação dos índices texturais obtido com o método FOTO.....	27
Figura 2.3 - Exemplo de <i>r-spectra</i> médios dos estágios de desenvolvimento sucessional de bosques de mangue.....	28
Figura 2.4 - Esquema demonstrando a coleta de dados LiDAR sobre o terreno.....	31
Figura 2.5 - Nuvem de pontos LiDAR de uma parcela de mangue.....	33
Figura 2.6 - Valores médios de RSE e RSE% categorizado por tipo de sensor.....	37
Figura 2.7 - Relação entre os valores de RSE% e tamanho das parcelas.....	38
Figura 2.8 - Extração de copas de árvores por meio dos métodos VWF e IWS.	42
Figura 2.9 - Técnica utilizada com um sistema LiDAR terrestre para obtenção do volume da árvore.	43
Figura 3.1- Localização do manguezal de estudo.....	55
Figura 3.2- Mapa do uso do solo e cobertura vegetal da APA de Guapimirim em 2000.	61
Figura 3.3- Mapa das fisionomias da APA de Guapimirim e ESEC Guanabara em 2012.	62
Figura 3.4 - Mapa de tipos de mangue na APA Guapimirim em 2012.	63
Figura 4.1 - Análise de agrupamento dos parametros estruturais.....	66
Figura 4.2 - Fluxograma metodológico de estimativa de biomassa com dados LiDAR.	71
Figura 4.3 - Fluxograma metodológico das etapas de processamento do método FOTO para a escala da paisagem e escala de parcela (34 vinhetas).....	80
Figura 4.4 - Fluxograma metodológico da estimativa de biomassa de bosques de mangue com índices texturais obtidos pelos métodos FOTO e GLCM e valores de biomassa das 34 parcelas de campo.....	84
Figura 4.5 - Fluxograma metodológico para a estimativa de biomassa do manguezal utilizando variáveis predictoras provenientes dos índices texturais FOTO e GLCM e AGB obtida do mapa de biomassa do manguezal gerado com dados LiDAR.	86
Figura 4.6 - Fluxograma metodológico da classificação de tipos de cobertura do solo do manguezal utilizando método Random Forest, as métricas LiDAR e os índices texturais FOTO e GLCM.....	89
Figura 5.1 - Variação de biomassa de mangue acima do solo (AGB, t/ha)	92
Figura 5.2 - Correlação entre as variáveis LiDAR.	95
Figura 5.3 - Diagramas de dispersão do valor da biomassa (AGB) predita <i>versus</i> observada.....	96
Figura 5.4 - Mapa de AGB (t/ha) do manguezal da APA de Guapimirim.....	98
Figura 5.5 – Distribuição das PCA1 e PCA2 das métricas LiDAR.....	99
Figura 5.6 –Distribuição das PCA1 e PCA2 das métricas LiDAR para todo o manguezal.....	100

Figura 5.7 - Distribuição da altura média LiDAR.	103
Figura 5.8 - Classes de densidade de pontos LiDAR - d00 e d01.	113
Figura 5.9 - Classes das métricas LiDAR - avg, d02, max e d03.	114
Figura 5.10 - Classes obtidas com as métricas LiDAR - d04 d05 e d09.	115
Figura 5.11 - Modelo da altura do dossel.	116
Figura 5.12 - imagem pancromática representativa das parcelas de estudo.	120
Figura 5.13 - Diagrama de dispersão das componentes PCA 1 e PCA2 dos índices texturais FOTO.	123
Figura 5.14 - Diagrama de dispersão entre os valores de AGB preditos e observados para os modelos M9,2000.	128
Figura 5.15 - Taxas dos erros OOB estimado para as classificações RF.	131
Figura 5.16 - <i>Boxplot</i> das variáveis LiDAR e dos índices texturais FOTO e GLCM para discriminação entre as classes <i>mangue denso</i> , <i>mangue alterado</i> e <i>não-mangue</i>	136
Figura 5.17 - Resultado do agrupamento k-médias sobre os valores de r-spectra para o FOTO janela de análise de 100 pixels.	135
Figura 5.18 - Composição colorida (RGB) utilizando as 3 primeiras componentes da PCA obtidas com o método FOTO janela de análise de 100 pixels RPCA1/GPCA2/BPCA3.	137
Figura 5.19 - Recortes da imagem pancromática representativos de cada janela de análise de 100 pixels.	138
Figura A.1 - Aquisição de dados de campo.	186
Figura A.2 - Tipos de cobertura vegetal encontrados no manguezal da APA de Guapimirim.	187
Figura B.1 - Importância das variáveis para o modelo M2b Random Forest.	189

LISTA DE TABELAS

	<u>Pág.</u>
Tabela 2.1 - Modelos alométricos para estimativa de biomassa acima do solo (AGB em gramas) para árvores vivas e mortas.	20
Tabela 4.1– Principais especificações do sistema LiDAR RIEGL 560 utilizado neste estudo.	69
Tabela 4.2 - Informações técnicas dos produtos gerados no pré-processamento dos dados LiDAR obtidos com o sistema RIEGL 560.	69
Tabela 4.3 - Características da imagem original WorldView-2 utilizada neste trabalho	70
Tabela 4.4 - Parâmetros estatísticos descritivos utilizados como métricas LiDAR para a modelagem da AGB de mangue.	74
Tabela 4.5 - Modelos preditivos de estimativa de biomassa com uso de dados LiDAR.	76
Tabela 4.6 - Modelos preditivos de estimativa de biomassa com uso de índices texturais estimados pelos métodos FOTO e GLCM.	86
Tabela 4.7 - Todos os parâmetros utilizados na classificação Random Forest: métricas Lidar, índices texturais Foto e GLCM.	88
Tabela 5.1 - Resultados dos modelos preditivos de AGB de bosques de mangue para o manguezal da APA de Guapimirim. Sendo o RMSE (CAL) de calibração e RMSE (LOO) de validação.	93
Tabela 5.2 - AGB média t/ha e desvio padrão do erro na escala da paisagem utilizando um estimador de regressão de inferência design-based e técnica de reamostragem. ...	101
Tabela 5.3 - Resultados dos modelos de regressão para estimativa de biomassa das 34 parcelas de campo por meio dos índices de textura.	118
Tabela 5.4 - Resultados dos modelos preditivos da AGB de bosques de mangue na APA de Guapimirim, RJ utilizando índices texturais GLCM e FOTO.	125
Tabela 5.5 - Resultados RMSE e R ² dos modelos de estimativa de biomassa de bosques de mangue com uso das variáveis texturais e AGB do mapa LiDAR.	127
Tabela 5.6 - Resultado da classificação Random Forest para o grupo (i) com todas as variáveis LiDAR e índices texturais FOTO e GLCM.	132
Tabela 5.7 - Resultado da classificação Random Forest para o grupo (ii) com todas as variáveis LiDAR.	133
Tabela 5.8 - Resultado da classificação Random Forest para o grupo (iii) com as variáveis FOTO.	134
Tabela 5.9 - Resultado da classificação Random Forest para o grupo (iv) com as variáveis GLCM.	134
Tabela 5.10 - Resultado da classificação Random Forest para o grupo (v) com as variáveis FOTO e GLCM.	135
Tabela 5.11 - Resultado da classificação Random Forest para as variáveis avg, FOTO 100 PCA1 e homogeneidade.	135
Tabela A.1 - Características das parcelas de campo.	175

Tabela B.1 - Resultados da estimativa de variância <i>jackknife</i> (<i>jack.test.autopls</i>) para o modelo M2a.	188
--	-----

LISTA DE SIGLAS E ABREVIATURAS

AGB	Biomassa acima do solo do inglês <i>aboveground biomass</i>
APA	Área de Proteção Ambiental
APP	Área de Proteção Permanente
AutoPLS	<i>Partial Least Squares regression with backward selection of predictors</i>
BGB	Biomassa abaixo do solo do inglês <i>belowground biomass</i>
C	Carbono
CHM	Modelo de Altura do Dossel do inglês <i>Canopy Height Model</i>
CV	Validação cruzada do inglês <i>cross-validation</i>
CV-LOO	Leave-one-out cross-validation
DAP	Diâmetro à altura do peito
DOM	Matéria orgânica morta do inglês <i>dead organic matter</i>
DRL	Lidar de retorno discreto do inglês <i>discrete return lidar</i>
DSM	Modelo digital da superfície do inglês <i>digital surface model</i>
DTM	Modelo digital do terreno do inglês <i>digital terrain model</i>
DVI	Índice de vegetação por diferença do inglês <i>Difference Vegetation Index</i>
ESEC	Estação Ecológica
EVI	Índice de vegetação realçado do inglês <i>Enhanced Vegetation Index</i>
FFT	Transformada rápida de Fourier do inglês <i>Fast Fourier Transform</i>
FOTO	<i>Fourier Based Textural Ordination</i>
FRL	Lidar de retorno contínuo do inglês <i>full return LiDAR</i>
GLCM	Matriz de co-ocorrência de níveis de cinza do inglês <i>Grey-level co-occurrence matrix</i>
GPS	Sistema de posicionamento global
ICESa t/GLAS	<i>Ice, Cloud, and land Elevation Satellite/Geoscience Laser Altimeter System</i>
IMU	Sistema de medição inercial do inglês <i>Inertial Measurement Unit</i>
LiDAR	<i>Light Detection and Ranging</i>
LOO	<i>Leave-One-Out</i>
LV	Variáveis Latentes do inglês <i>Latent Variables</i>
M	Modelo
MCH	<i>Mean canopy profile height</i>
MS	Multi-sensor

MSEP	<i>Mean squared error of prediction</i>
MSR	<i>Mean of Squared Residuals</i>
NDVI	Índice de vegetação por diferença normalizada do inglês <i>Normalized Difference Vegetation Index</i>
OOB	<i>Out-Of-Bag</i>
PCA	Análise de principais componentes do inglês <i>Principal Component Analysis</i>
PCA1	Primeira componente da PCA
PCR	Regressão em componentes principais do inglês <i>principals component regression</i>
PLS	<i>Partial Least Squares Regression</i>
R ²	Coefficiente de múltipla determinação
REDD	Redução de Emissões por Desmatamento e Degradação Florestal do inglês <i>Reducing Emissions from Deforestation and Forest Degradation</i>
RF	<i>Random Forest</i>
RMSE	Erro quadrático médio do inglês <i>Root mean square error</i>
RSE	Erro padrão residual do inglês <i>residual standard error</i>
SAR	Radar de abertura sintética do inglês <i>Synthetic Aperture Radar</i>
SAVI	Índice de vegetação ajustado ao solo do inglês <i>Soil-adjusted Vegetation Index</i>
SOM	Matéria orgânica do solo do inglês <i>soil organic matter</i>
SRTM	<i>Shuttle Radar Topography Mission</i>

SUMÁRIO

	<u>Pág.</u>
1 INTRODUÇÃO	1
1.1 Objetivos.....	7
2 REVISÃO DA LITERATURA	9
2.1 Ecossistema Manguezal.....	9
2.2 Estrutura florestal.....	14
2.3 Biomassa	17
2.4 Dados e técnicas de sensoriamento remoto.....	20
2.4.1 Sistema óptico	20
2.4.2 <i>Light Detection and Ranging</i> (LiDAR)	29
2.4.2.1 LiDAR e floresta.....	31
2.4.2.2 LiDAR e manguezal	39
2.5 Modelos de regressão e métodos de análise de incertezas.....	45
3 ÁREA DE ESTUDO.....	53
3.1 Baía de Guanabara.....	53
3.2 Características gerais do manguezal da APA de Guapimirim	56
4 MATERIAL E MÉTODOS	65
4.1 Dados de campo.....	65
4.2 Dados de sensoriamento remoto	68
4.3 Processamento de dados LiDAR.....	70
4.3.1 Modelos preditivos de biomassa aérea de bosques de mangue obtidos a partir de métricas LiDAR	74
4.3.2 Mapeamento da biomassa na escala da paisagem com uso de dados LiDAR	76
4.3.3 Avaliação da cobertura da amostragem das parcelas para os dados LiDAR..	76
4.3.4 Análise da incerteza no nível da paisagem	77

4.4	Processamento da imagem óptica de alta resolução e análise textural.....	78
4.4.1	<i>Fourier-based textural ordination</i> (FOTO).....	79
4.4.2	<i>Grey-Level Co-occurrence Matrix</i> (GLCM).....	82
4.4.3	Modelos preditivos de biomassa aérea de bosques de mangue obtidos a partir dos índices texturais	83
4.4.4	Avaliação da cobertura da amostragem das parcelas para o método FOTO ..	84
4.5	Simulação da estimativa da biomassa do manguezal com uso de índices texturais FOTO e GLCM e valores da AGB do mapeamento obtido com LiDAR	85
4.6	Classificação dos tipos de mangue	87
5	RESULTADOS E DISCUSSÕES	91
5.1	Avaliação dos modelos de estimativa de biomassa com uso de dados LiDAR	92
5.1.1	Avaliação da cobertura amostral das métricas Lidar.....	98
5.1.2	Avaliação da incerteza na escala da paisagem.....	101
5.1.3	Discussão do desempenho da estimativa da AGB com dados LiDAR	103
5.2	Avaliação dos modelos de estimativa de biomassa aérea com uso dos índices texturais.....	117
5.2.1	Avaliação dos modelos de estimativa de biomassa aérea com uso de índices texturais do método FOTO	117
5.2.2	Avaliação da cobertura amostral para os índices FOTO	121
5.2.3	Avaliação dos modelos de estimativa de biomassa com uso dos produtos do método GLCM.....	123
5.2.4	Estimativa de AGB com uso dos índices texturais FOTO e GLCM e valores de AGB estimados com LiDAR	126
5.3	Classificação dos tipos de mangue	129
6	CONCLUSÕES	143
	REFERÊNCIAS BIBLIOGRÁFICAS	147
	APÊNDICE A	175
	APÊNDICE B.....	188

1 INTRODUÇÃO

Mudanças ambientais globais têm sido causadas nos últimos séculos principalmente pelas ações humanas (ROCKSTRÖM et al., 2009; STEFFEN et al., 2007). Relacionadas tanto com as mudanças biofísicas como socioeconômicas que alteram a estrutura e funcionalidade do sistema terrestre, as mudanças globais incluem alterações num vasto e diversificado conjunto de fenômenos que interagem e se condicionam uns aos outros (STEFFEN et al., 2007). Rockström et al. (2009) identificam processos do sistema terrestre e limiares associados que permitem definir os limites planetários, que são os espaços seguros operados pelas atividades humanas no sistema terrestre. Tais processos quando alterados podem causar mudanças ambientais inaceitáveis, e segundo estes autores os processos que atualmente já ultrapassaram os limites planetários seguros, são: a perda de biodiversidade, a interferência no ciclo de nitrogênio e a mudança climática, sendo esta última intimamente relacionada com a concentração de dióxido de carbono (CO₂) na atmosfera. Por ser um dos gases responsáveis pelo efeito estufa, alterações na concentração de CO₂ na atmosfera influenciam diretamente os processos climáticos.

As florestas, por sua vez, desempenham papel crucial no ciclo global de carbono (C), capturando CO₂ da atmosfera e estocando na matéria orgânica grandes quantidades deste elemento. Os reservatórios de carbono florestal incluem a biomassa acima do solo (AGB, do inglês *aboveground biomass*) e a biomassa abaixo do solo (BGB, do inglês *belowground biomass*), tanto viva como morta, composta de raízes, troncos, galhos, cascas, sementes, folhagens, serapilheira e carbono orgânico do solo (DONATO et al., 2011; IPCC, 2006; MERIDIAN INSTITUTE, 2009). Suscetível a mudanças através de processos naturais e de impactos antrópicos, a biomassa pode fornecer uma indicação do sequestro, estocagem, e/ou emissão de carbono na atmosfera (BARBOSA et al., 2014; GOETZ; DUBAYAH, 2011).

Os mais altos índices de biodiversidade e estocagem de C convergem nas florestas tropicais, as quais também enfrentam as mais elevadas taxas de desflorestamento e degradação (HÄGER; SCHWENDENMANN, 2016). Debate-se atualmente se as florestas tropicais representam hoje uma fonte ou um sumidouro de carbono, dadas as

inúmeras incertezas sobre os fluxos de carbono que ainda persistem e que resultam de informação imprecisa da cobertura florestal, métodos inconsistentes de estimativa de biomassa, ou dificuldades de se medir os estoques de carbono abaixo do solo (HÄGER; SCHWENDENMANN, 2016). Entretanto, aponta-se o desflorestamento como a causa mais importante de distúrbio nos fluxos de carbono em florestas tropicais, e como principal responsável pelas emissões causadas pelas mudanças de uso da terra (LORENZ; LAL, 2010; MALHI, 2010). Segundo Pan et al. (2011) estima-se uma fonte de $1,3 \pm 0,7 \text{ Pg C ano}^{-1}$ proveniente de mudanças do uso da terra, compreendendo uma emissão bruta devida ao desflorestamento de floresta tropical equivalente a $2,9 \pm 0,5 \text{ Pg C ano}^{-1}$ parcialmente compensada por um sumidouro de carbono de floresta tropical em regeneração equivalente a $1,6 \pm 0,5 \text{ Pg C ano}^{-1}$.

Comparativamente a outras florestas, como a boreal, temperada e tropical de terra firme, as florestas de mangue são mais ricas em carbono, na medida em que fixam e transferem para o solo enormes quantidades, entre 49% a 98% do total de carbono nelas armazenado (DONATO et al., 2011). Por estocá-lo principalmente no solo, as florestas de mangue chegam a armazenar mais carbono por área-base específica (956 tC/ha) do que outros ecossistemas (241 tC/ha para florestas tropicais úmidas) (ALONGI, 2014). Ocupando apenas ~ 0,5% da área costeira global, ou o equivalente a ~ 0,7% da área de floresta tropical (ALONGI; MUKHOPADHYAY, 2015; GIRI et al., 2010), os manguezais são responsáveis por cerca de 10-15% do sequestro de carbono total na área costeira, ou 3% do sequestro de carbono atribuído às florestas tropicais (ALONGI, 2014). Por esta razão, as taxas atuais de remoção de manguezais podem causar a emissão de quantidades relativamente significativas de carbono para a atmosfera.

Entretanto, o atual desflorestamento de manguezais é preocupante sobretudo por suas funções ecológicas essenciais para a manutenção da vida terrestre e marinha e sustento de inúmeras comunidades humanas. Os serviços realizados pelos manguezais incluem a estabilização e proteção da linha de costa, retenção de sedimentos, filtragem da água e controle da poluição, transformação de nutrientes em matéria orgânica, fornecendo habitat e alimento para muitas espécies de animais, cuja reprodução e sobrevivência são essenciais ao funcionamento de outros ecossistemas e à produção pesqueira. Desta forma, a restauração e conservação dos manguezais são importantes não apenas para a

manutenção dos estoques de carbono e controle das mudanças climáticas, mas sobretudo para a manutenção de seus valiosos serviços prestados à zona costeira tropical (DUKE et al., 2007; EWEL et al., 1998).

Os manguezais caracterizam-se por serem ecossistemas costeiros que ocorrem na interface entre a terra e o mar tipicamente em regiões tropicais (ALONGI, 2009), e possuem espécies adaptadas às condições de elevada salinidade e inundações pelas marés. O desenvolvimento estrutural da floresta de mangue está associado à intensidade e frequência de fatores ambientais, sendo que o máximo desenvolvimento estrutural da floresta de mangue ocorre em regiões onde a topografia está sujeita a uma significativa amplitude de maré, grande aporte de água doce, precipitação, insolação, nutrientes e sedimentos (DUKE et al., 1998; SCHAEFFER-NOVELLI et al., 1990). As áreas cobertas por manguezais estão em declínio, sendo hoje um dos ecossistemas mais ameaçados do planeta (DUKE et al., 2007). Um terço das florestas de mangue da Terra já foi destruído, principalmente pelo aumento da densidade populacional humana. O crescimento da população nas zonas costeiras tem induzido grandes perturbações nos manguezais, sobretudo com o desmatamento e com a aquicultura, que representam sérias ameaças (ALONGI, 2002; POLIDORO et al., 2010). A aquicultura tem impacto sobre a qualidade da água, alterando os fluxos naturais das marés e liberando resíduos tóxicos (ALONGI, 2002).

O monitoramento da dinâmica do uso e ocupação do solo juntamente com a estimativa de biomassa diretamente relacionada com o carbono armazenado nas florestas, são cruciais para quantificar o balanço global do carbono e sua influência no sistema climático (ALONGI, 2014; PAN et al., 2011,2013; PENDLETON et al., 2012; SAATCHI et al., 2011). Estimativas acuradas da biomassa florestal permitem estimar e monitorar as mudanças no conteúdo de carbono florestal, contribuindo para a eficácia das políticas ambientais, como por exemplo, a Redução de Emissões por Desmatamento e Degradação Florestal (REDD, do inglês *Reducing Emissions from Deforestation and Forest Degradation*). O REDD representa um esforço de se gerar um valor financeiro para o carbono armazenado em florestas, criando incentivos para os países em desenvolvimento reduzirem as emissões de áreas florestadas e investirem na economia de baixo carbono para seu desenvolvimento sustentável. O REDD+ vai além do

desflorestamento e degradação florestal, incluindo o papel da conservação, gerenciamento sustentável e aumento dos estoques de carbono florestal. De acordo com Siikamaki et al. (2012), a conservação dos manguezais é economicamente viável considerando-se a alta concentração de carbono neste ecossistema.

Desta forma, a caracterização e o monitoramento das florestas de mangue, tendo em vista sua preservação e conservação, são essenciais para regular as emissões de carbono e manter os bens e serviços dos ecossistemas costeiros. As estimativas de biomassa de mangue são realizadas primeiro na escala de parcela, a partir de medições de árvores individuais e de equações alométricas específicas, posteriormente extrapoladas para escalas maiores com base em técnicas de sensoriamento remoto óptico (PROISY et al., 2007), radar de abertura sintética (SAR) (LUCAS et al., 2009) e *Light Detection and Ranging* (LiDAR), juntamente com outras fontes de dados complementares (FATOYINBO; SIMARD, 2013; SIMARD et al., 2008). O LiDAR é um sistema ativo utilizado para estimar e mapear a estrutura de florestas, biomassa aérea e estoque de carbono florestal (ASNER et al., 2012; GREGOIRE et al., 2016; MASCARO et al., 2011; NÆSSET; GOBAKKEN, 2008; POPESCU, 2007; VINCENT et al., 2012; VINCENT et al., 2014; ZOLKOS et al., 2013).

O desenvolvimento de modelos para estimativa de biomassa aplicados na escala de paisagem, deve considerar potenciais fontes de erros. Entre estas, pode-se citar a coerência espacial e temporal entre os dados LiDAR e dados de campo, erros de posicionamento GPS, discrepâncias temporais entre diferentes aquisições de dados, discordâncias entre os limites das medidas LiDAR e das medidas das parcelas de campo (ou de calibração dos modelos) que acabam por incluir ou excluir partes de árvores (MASCARO et al., 2011; VINCENT et al., 2012). Além disso, incertezas nos modelos para estimativa de biomassa podem sofrer influências de diferentes tamanhos das parcelas (FRAZER et al., 2011; MASCARO et al., 2011), tipos de floresta e tipos de sensores (ZOLKOS et al., 2013). Devido às inúmeras fontes de erros que podem afetar o processo de modelagem, a avaliação das incertezas dos modelos em várias escalas espaciais é parte inerente do desenvolvimento dos modelos (CHEN et al., 2015; FRAZER et al., 2011; GREGOIRE et al., 2016; MASCARO et al., 2011; VINCENT et al., 2012).

Em estudos de manguezais, diversas técnicas de sensoriamento remoto para extração de parâmetros biofísicos florestais costumam ser utilizadas para se mensurar a estrutura florestal, biomassa e estoque de carbono, cada uma delas apresentando diferentes possibilidades com vantagens (e desvantagens) técnicas específicas, o que torna seu uso bastante seletivo em função das finalidades, condições e necessidades próprias de cada estudo.

Os dados SAR são utilizados principalmente para a caracterização estrutural de bosques de mangue e estimativa de sua biomassa, dada a possibilidade de penetração da onda incidente no dossel florestal e obtenção de informações tridimensionais da estrutura florestal, além da sua independência em relação às condições atmosféricas durante a aquisição de dados (BROWN et al., 2016; COUGO et al., 2015; LUCAS et al., 2009; MOUGIN et al., 1999; PEREIRA et al., 2012; PEREIRA et al., 2016; PROISY et al., 2000; 2002).

Já no caso de sensores ópticos passivos, a interação da energia eletromagnética ocorre principalmente com a parte superior do dossel florestal. Os dados ópticos são geralmente utilizados para o mapeamento e distribuição de áreas de mangue, discriminação de espécies, estimativa de parâmetros estruturais e de biomassa, e detecção de mudanças no uso e cobertura do solo (DAHDOUH-GUEBAS, 2002; GIRI et al., 2010; GREEN et al., 1998; HEUMANN, 2011; HUANG et al., 2009; JACHOWSKI et al., 2013; KAMAL; PHINN, 2011; KOEDSIN; VAIPHASA, 2013; PROISY et al., 2007; VO et al., 2013; WANG; GLENN, 2008; WANG et al., 2016; YANG et al., 2009; ZHU et al., 2015). Para a estimativa de parâmetros estruturais e biomassa de mangue podem ser utilizados índices de vegetação (KOVACS et al., 2005), estereofotogrametria (LAGOMASINO et al., 2015) e informações texturais das imagens (PROISY et al., 2007). A caracterização textural extraída de imagens ópticas pode ser obtida por diferentes abordagens, tais como *grey-level co-occurrence matrix* (GLCM) (HARALICK; ROBERT, 1979), análise de Fourier com o método *Fourier Based Textural Ordination* (FOTO) (BASTIN et al., 2014; COUTERON et al., 2005; PROISY et al., 2007) e análise de *wavelet* (KENNEL et al., 2013), dentre outras abordagens. Porém, os dados ópticos têm como desvantagem a limitação pela cobertura de nuvens.

Os dados LiDAR, por sua vez, possibilitam estimar a altura dos dosséis dos bosques de mangue com maior precisão, e consequentemente, obter estimativas mais acuradas da biomassa (LAGOMASINO et al., 2016; SIMARD et al., 2008; WANNASIRI et al., 2013). Outra vantagem do uso de dados LiDAR é a possibilidade de extração de modelos de superfície e de terreno e, por consequência, a obtenção do modelo da altura do dossel em uma determinada área florestal. Desta forma é possível obter uma estimativa tridimensional da estrutura florestal. Segundo Zolkos et al. (2013), o uso de sistemas LiDAR para a estimativa de biomassa florestal acima do solo mostrou melhor resultado do que o uso de dados ópticos e SAR. Dados LiDAR têm possibilitado o mapeamento da AGB e a extração de parâmetros biofísicos em diferentes tipos de florestas, como decídua, de coníferas (BRANDTBERG et al., 2003; EDSON; WING, 2011; POPESCU, 2007) e florestas tropicais (ASNER et al., 2012; VINCENT et al., 2014). Especificamente para florestas de mangue, as aplicações de LiDAR visam mapear os manguezais (ZHANG; HOULE et al., 2006), detectar clareiras (ZHANG, 2008a), estimar e mapear parâmetros estruturais e biomassa a partir da integração com outros dados de sensoriamento remoto (CHADWICK, 2011; FATOYINBO; SIMARD, 2013; KAMAL et al., 2015; SIMARD et al., 2006; 2008), servindo também para detecção de indivíduos arbóreos e estimativa de sua estrutura (GALVINCIO; POPESCU, 2016; LAGOMASINO et al., 2016; WANNASIRI et al., 2013). Com uso de sistema LiDAR terrestre é possível estimar parâmetros estruturais e biomassa das árvores diretamente em campo (FELICIANO et al., 2014; OLAGOKE et al., 2016). Wannasiri et al., (2013) utilizaram dados de LiDAR aerotransportado para obter parâmetros estruturais de mangue ao nível de indivíduo, como o diâmetro da copa, altura e posição da árvore, utilizando um Modelo de Altura do Dossel (CHM, do inglês *Canopy Height Model*) e métodos de filtragem e segmentação das copas. Os resultados, obtidos para uma pequena área de manguezal, mostraram que dosséis com copas sobrepostas comprometem a acurácia de detecção e estimativa estrutural das árvores. Resultados promissores para a estimativa de biomassa de indivíduos arbóreos de mangue usando dados LiDAR terrestre foram apresentados por Feliciano et al., (2014) e Olagoke et al., (2016), demonstrando a eficácia deste tipo de sistema para estimativas de biomassa em campo. O uso de dados LiDAR e *Shuttle Radar Topography Mission* (SRTM) para estimar a altura e biomassa em grandes áreas de manguezal foi realizado

por SIMARD et al., (2006;2008). Simard et al. (2008) utilizaram dados *Ice, Cloud, and land Elevation Satellite/Geoscience Laser Altimeter System (ICESat/GLAS)* para calibrar os dados SRTM de elevação e para produzir um mapa de altura do manguezal. Este método de mapeamento recobriu uma área geográfica considerável usando dados publicamente disponíveis, mas às custas de uma redução na precisão das estimativas de altura e biomassa. No entanto, ainda há uma necessidade de se realizar esforços adicionais de pesquisa com o objetivo de estimar a AGB de manguezais para extensas áreas utilizando sistemas LiDAR aerotransportados de retorno discreto, considerando suas capacidades de exatidão, precisão e possibilidade de aquisições repetidas de dados.

Diante do exposto e considerando a relativa falta de exemplos de aplicação de técnicas LiDAR para o estudo de manguezais, a presente tese tem o intuito de contribuir com a estimativa de biomassa florestal do ecossistema manguezal e investigar o potencial uso de dados LIDAR aerotransportado de retorno discreto para esta finalidade. Também foi investigado o potencial uso de índices texturais extraídos de imagem óptica de alta resolução para detectar e estimar a biomassa de bosques de mangue com distintos graus de alteração e preservação. O ecossistema estudado é o manguezal da Área de Proteção Ambiental (APA) de Guapimirim no Estado do Rio de Janeiro, localizado no entorno da Baía de Guanabara em uma região com intensa urbanização.

1.1 Objetivos

O objetivo geral da presente tese é averiguar o potencial uso de dados LiDAR para estimar a biomassa aérea do manguezal com distintos graus de alteração, e comparativamente, investigar o potencial uso de índices texturais obtidos a partir de imagem óptica de alta resolução para estimar a biomassa de bosques de mangue e distinguir tipos de cobertura do manguezal com distintos graus de alteração.

Os objetivos específicos são:

- Estimar e mapear a biomassa aérea de bosques de mangue com distintos graus de alteração utilizando dados LiDAR de retorno discreto e avaliar as incertezas do modelo de predição.

- Avaliar o potencial do uso de índices texturais extraídos de uma imagem óptica de alta resolução espacial para estimar a biomassa aérea de bosques de mangue com distintos graus de alteração.
- Avaliar o potencial das informações texturais obtidas com a imagem óptica de alta resolução para distinguir tipos de cobertura do manguezal da APA de Guapimirim, com áreas preservadas e alteradas.

A presente tese foi norteada por três perguntas científicas e está estruturada de forma convencional com introdução geral, objetivos, revisão da literatura, área de estudo, material e métodos utilizados, resultados e discussões, e conclusões. Procurou-se ordenar a redação da tese (metodologia, resultados) na mesma sequência das três questões investigadas:

- 1) O quão precisa é a estimativa de biomassa de bosques de mangue com distintos graus de alteração com uso de dados LiDAR?
- 2) Qual o potencial da análise textural aplicada a imagens ópticas de alta resolução espacial para estimar a biomassa de floresta de mangue com distintos graus de alteração?
- 3) É possível distinguir tipos de bosques de mangue em diferentes estágios de alteração por meio de análise textural?

2 REVISÃO DA LITERATURA

2.1 Ecossistema Manguezal

O manguezal é um ecossistema costeiro típico de regiões tropicais e subtropicais sujeito ao regime das marés. Ocorre em regiões costeiras abrigadas e representa a interface entre as comunidades marinha e terrestre, recebendo entrada de água oceânica juntamente com água doce, nutrientes e sedimentos provenientes dos rios. É considerado importante fonte de suporte para a conservação da biodiversidade terrestre e marinha, fornecendo habitat, local para desova, viveiros e alimento para diversos animais, além de ser importante transformador de nutrientes em matéria orgânica e gerador de bens e serviços como estabilização e proteção da linha de costa, filtragem da água e controle de poluição, sequestro do carbono atmosférico e regulação do clima, dentre outras funções (ALONGI, 2002; SCHAEFFER-NOVELLI, 1991; WEBBER et al., 2016).

Os manguezais distribuem-se globalmente ocupando uma área total de ~150.000 km², sendo a Indonésia o país com a maior extensão de manguezais, o equivalente a 31.894 km² (20,9% da área global), seguida do Brasil com 13.000 km² (8,5%) e Austrália com 9.910 km² (6,5%) (SPALDING et al., 2010). Apesar de ocuparem apenas ~0,5% da área costeira global e ~0,7% da área total de florestas tropicais, os manguezais são responsáveis por ~10-15% do sequestro de carbono total na área costeira e ~3% do sequestro de carbono atribuído às florestas tropicais (ALONGI, 2014). São considerados ecossistemas altamente produtivos com uma produtividade primária líquida média acima do solo de 11,1 tC ha⁻¹ ano⁻¹ (ALONGI, 2009;2014), superando taxas de outros ecossistemas marinhos. Segundo Donato et al., (2011), o ecossistema manguezal está entre as florestas mais ricas em carbono nos trópicos, contendo em média 1.023 tC/ha armazenado principalmente no solo. De acordo com Alongi (2014), os manguezais armazenam mais carbono por área-específica (956 tC/ha) do que outros ecossistemas, como a floresta tropical úmida (241 tC/ha), pântanos de turfa (408 tC/ha), marismas (593 tC/ha) ou pradarias marinhas (142,2 tC/ha). Segundo cálculos feitos por Estrada (2013), as médias globais para o armazenamento e o sequestro de carbono na

biomassa aérea de manguezais seriam de $78,0 \pm 64,5$ tC/ha (máximo de 418,5 e mínimo de 0,9 tC/ha) e $2,9 \pm 2,2$ tC ha⁻¹ ano⁻¹ (máximo de 9,7 e mínimo de 0,4 tC ha⁻¹ ano⁻¹), respectivamente. Em escala global, o armazenamento de carbono em florestas de mangue depende da latitude (aumentando em direção ao equador) e também de parâmetros climáticos mais específicos como a precipitação anual, balanço hídrico, amplitude térmica anual, entre outros (ESTRADA, 2013).

Considerando a necessidade de se definir com mais rigor as escalas espaço-temporais e os níveis de observação em estudos de manguezais, Schaeffer-Novelli et al. (2000) apresentaram detalhada descrição dos cinco níveis hierárquicos de organização dos manguezais em função da escala espacial, mostrando que cada um destes níveis contém uma organização que evoluiu para facilitar a dissipação da energia em sua respectiva escala, e que se caracteriza por processos funcionais e propriedades particulares. Estes níveis são: *Site*, *Stand*, *Setting*, *Coastal Domain* e *Large Marine Ecosystem*. O nível *Site* (parcela) corresponde a unidades da cobertura vegetal ocupando entre 0,01 e 0,1 ha de área. O nível *Stand*, ocupando de 0,1 a 100 ha, corresponde ao bosque de mangue. O nível *Setting* (paisagem) representa extensões de 10 a 100 km da costa e são geomorfologicamente criados e modificados por forças erosivas e deposicionais. Os outros níveis – *Coastal Domain* e *Large Marine Ecosystem* – correspondem, respectivamente, ao domínio costeiro e a regiões biogeográficas marinhas.

A vegetação típica de mangue é representada por poucas espécies, todas tolerantes à salinidade. De acordo com Spalding et al. (2010) há uma diversidade genética de aproximadamente 73 espécies de flora de mangue, normalmente localizadas em áreas de solos alagados, pobres em oxigênio e substratos inconsolidados, onde o complexo sistema de raízes aéreas promove o suporte e as trocas gasosas (DAHDOUH-GUEBAS, 2002; SCHAEFFER-NOVELLI, 1991). Segundo Schaeffer-Novelli e Cintrón-Molero (1986), as espécies de flora de mangue possuem adaptações surpreendentes ao seu ambiente, como a habilidade de extrair água doce da água do mar, órgãos especiais para a excreção de sal, lenticelas nas raízes-escora e nos pneumatóforos permitindo a respiração da planta, raízes-escora e adventícias que ajudam a sustentar a árvore em

solos lodosos e reprodução por viviparidade através de propágulos que se dispersam por via aquática.

Rhizophora, *Avicennia*, *Laguncularia* e *Conocarpus* são os principais gêneros de mangue que ocorrem do Brasil. As principais espécies associadas a bosques de mangue são: *Hibiscus tiliaceus* L., *Acrostichum aureum* Linnaeus, *Spartina brasiliensis* Raddi, e *Spartina alterniflora* Loiseleur (Poaceae). A seguir serão descritas algumas características estruturais das três principais espécies de mangue: *Rhizophora mangle* L. (*Rhizophoraceae*), *Avicennia schaueriana* Stapf. & Leechman (*Acanthaceae*, *Avicenniaceae*) e *Laguncularia racemosa* (L.) Gaertn. F. (*Combretaceae*), com base nos trabalhos de Schaeffer-Novelli (1991) e Schaeffer-Novelli et al. (2000).

Rhizophora mangle (mangue vermelho) - no Brasil, normalmente são encontradas na parte frontal do bosque ocupando substratos menos consolidados. As árvores possuem copas arredondadas, os bosques variam de 5 a 30 m de altura e o sistema radicular não chega a ultrapassar os 50 cm de profundidade no sedimento. As raízes-escora são formadas ao longo da parte basal do tronco e curvam-se em direção ao sedimento formando arcos. As raízes adventícias partem dos galhos, chegando ao substrato. As folhas são opostas, coriáceas, carnosas e ovais.

Avicennia schaueriana (mangue preto) - apresentam estrutura entre 6 a 25 m de altura para os bosques maduros. Apresentam sistema radicular bem ramificado horizontalmente com distribuição radial, de onde partem estruturas de forma cônica, com 10 a 30 cm de altura, conhecidos como pneumatóforos. As folhas são opostas, simples, elípticas.

Laguncularia racemosa (mangue branco) - normalmente ocupam terrenos mais firmes e arenosos no manguezal apresentando porte arbustivo ou arbóreo, variando de 2 a 8 m, com copa arredondada. O sistema radicular se desenvolve semelhante ao sistema do gênero *Avicennia*, com os pneumatóforos. As folhas são opostas, pecioladas, elípticas, espessas e coriáceas.

De acordo com Saenger (2002), a classificação de comunidades de mangue pode se efetuar de acordo com qualquer dos seus vários atributos (interações físico-químicas e bióticas, funções, estrutura e florística), e uma adequada seleção dos atributos depende da finalidade da classificação. Por exemplo, a análise dos atributos estruturais como a biomassa, altura, cobertura foliar, permite classificar o manguezal tanto em relação à sua fase de desenvolvimento ou estágio sucessional, como em relação ao grau de desenvolvimento máximo que o manguezal pode atingir em função das condições ambientais como fertilidade do solo, temperatura, luminosidade ou balanço hídrico. A classificação correlacionando atributos fisiográficos e estruturais foi apresentada por Lugo e Snedaker (1974), que sugeriram os seguintes tipos fisiográficos de bosques: ilhote, ribeirinho, franja, bacia, arbustivo e anão. Cintrón et al., (1985) simplificaram esta classificação sugerida por Lugo e Snedaker (1974) e consideraram apenas três tipos fisiográficos: ribeirinho, franja (incluindo ilhote) e bacia (incluindo arbustivo e anão como tipos especiais). Schaeffer-Novelli et al., (2000) sugerem uma classificação dos bosques de mangue em dois tipos principais segundo suas características fisiográficas: bosques de franja e bosques de bacia. Esta classificação tem como critério fundamental a hidrodinâmica local. Bosques de franja ocorrem ao longo das margens de costas protegidas, em estuários e baías abrigadas, recebendo maior frequência de inundação e apresentando altos níveis de desenvolvimento. Bosques de bacia ocupam terrenos com menor frequência de inundação e apresentam-se estruturalmente menos desenvolvidos. Nesta classificação os tipos ribeirinho e ilhote são considerados sub-tipos de franja. O tipo ribeirinho desenvolve-se nas margens dos rios, dos quais recebe água doce rica em nutrientes, apresentando alto grau de desenvolvimento estrutural. O tipo ilhote é basicamente um bosque de franja que envolve pequenas ilhas protegidas e submetidas às flutuações diárias das marés. E os sub-tipos arbustivo e anão descrevem certos tipos de bosques (franja ou bacia) com desenvolvimento limitado por condições ambientais extremas ou oligotróficas.

O desenvolvimento estrutural de bosques de mangue depende da intensidade e periodicidade de inúmeros fatores ambientais. De uma forma geral, regiões com uma topografia sujeita à grande amplitude de marés, ampla entrada de água doce por efluentes, abundante precipitação, nutrientes e sedimentos proporcionam um máximo

desenvolvimento estrutural dos manguezais (LUGO; MEDINA, 2014; SCHAEFFER-NOVELLI et al., 1990). Globalmente, o desenvolvimento estrutural e os índices de produção orgânica dos manguezais são maiores para as latitudes mais baixas, denotando uma forte relação entre a biomassa, a altura das árvores (desenvolvimento estrutural) e a latitude (insolação e temperatura) (SAENGER; SNEDAKER, 1993).

No Brasil, as maiores extensões e desenvolvimento estrutural de bosques de mangue são encontrados no litoral da região norte, onde convergem as condições ambientais mais favoráveis ao seu desenvolvimento como o relevo com extensas planícies costeiras, marés de grandes amplitudes, abundante precipitação, temperaturas médias elevadas, grande aporte de sedimentos, nutrientes e água doce. No litoral das regiões sudeste e sul do Brasil os manguezais são estruturalmente menos desenvolvidos devido às condições ambientais e latitudinais presentes como menor amplitude das marés, precipitações menos regulares e temperaturas médias decrescentes. Além disso, a proximidade de cadeias montanhosas junto à costa delimita nestas regiões faixas mais estreitas de planície costeira onde os manguezais podem se expandir, tendo assim sua extensão limitada pelo relevo. Apesar dessas restrições, grandes florestas de mangue se desenvolvem no sul e sudeste, normalmente associadas aos estuários dos rios, nas baías ou margens das lagoas costeiras (SCHAEFFER-NOVELLI et al., 1990; SCHAEFFER-NOVELLI, 1991). O limite sul do Brasil com ocorrência de manguezais é a Lagoa Santo Antônio (28°28' S - 48°50' W) localizada no município de Laguna (SC), com baixo grau de desenvolvimento estrutural. Ao sul deste ponto da costa brasileira os manguezais são substituídos por marismas (SOARES et al., 2012).

Por serem ecossistemas sensíveis a distúrbios ambientais sutis e muitas vezes difíceis de se detectar, os manguezais são potenciais indicadores ambientais das mudanças climáticas e do nível do mar (SCHAEFFER-NOVELLI et al., 2016). O aumento da temperatura, por exemplo, resulta normalmente em maior aceleração no crescimento, reprodução, respiração, fotossíntese, diversidade, mudanças na estrutura da comunidade e expansão dos manguezais para maiores limites latitudinais (ALONGI, 2015). Mas por outro lado, resulta também em aumento do nível do mar, o que pode representar uma grande ameaça aos manguezais devido à limitação de áreas disponíveis para sua

migração. Neste caso, somente um planejamento costeiro adequado pode facilitar a migração e sobrevivência de inúmeros manguezais (GILMAN et al., 2008).

O desenvolvimento estrutural da floresta de mangue pode ser influenciado por tensores ou alguma forma de estresse causado por fatores ambientais. Saenger (2002) destaca alguns índices que indicam a "saúde" dos manguezais e que podem ser úteis no monitoramento deste ecossistema. Características sintomáticas de patologias ou condições de estresse podem ser indicadas, por exemplo, com a diminuição do índice de área foliar, redução de folhas por galho, ramos mais altos mortos, distância dos entrenós encurtada e cessação do crescimento dos ramos.

O declínio das áreas de manguezais tem sido considerável e contínuo. Cerca de 36.000 km² foram perdidos entre 1980 e 2005 (FAO, 2007). O desflorestamento a nível mundial tem causado uma diminuição de 1 a 2% de florestas de mangue por ano (DUKE et al., 2007; VALIELA et al., 2001). As maiores ameaças que conduzem à perda de florestas de mangue são as conversões de áreas em aquicultura (maricultura, carcinicultura e piscicultura), agricultura e outros usos urbanos (IPCC, 2014; POLIDORO et al., 2010; SPALDING et al., 2010; VALIELA et al., 2001). A taxa de declínio dos manguezais é muitas vezes condicionada às políticas nacionais de proteção deste ecossistema. Segundo Spalding et al. (2010), aproximadamente 1/4 dos remanescentes de manguezais a nível mundial estão incorporados a áreas de proteção ambiental para fins de conservação. No Brasil, a Legislação Ambiental considera o ecossistema manguezal como Área de Preservação Permanente - APP (Lei Federal nº 12.651/2012). Entretanto, o novo Código Florestal não mais considera os apicuns e marismas tropicais hipersalinos como APP, mesmo que sejam feições interdependentes e interligadas aos manguezais.

2.2 Estrutura florestal

Em geral, o termo "estrutura" refere-se (1) ao conjunto de elementos conectados de um sistema, e (2) à estruturação de um sistema em relação aos aspectos espaciais, temporais e funcionais (SCHAEFER, 1992; citado por ZEHM et al., 2003). Segundo Franklin et al. (2002), os ecossistemas florestais podem ser descritos pela caracterização de sua

estrutura, funcionalidade e composição. A estrutura refere-se à variedade de estruturas individuais, como árvores e clareiras, de vários tamanhos, formas e condições, e ao arranjo espacial destas estruturas componentes do ecossistema, como a altura dos diferentes estratos florestais e o espaçamento entre as árvores. Para uma descrição mais completa do ecossistema, é necessário analisar suas funções, que se referem às características e às taxas de ocorrência dos processos ecológicos realizados, como a produtividade, conservação de nutrientes e regulação dos ciclos hidrológicos. Deve-se também analisar a sua composição, dada pela diversidade dos componentes, compreendendo as características, riqueza e proporção das várias espécies do ecossistema (FRANKLIN et al., 2002; MCELHINNY et al., 2005).

A descrição estrutural de um bosque de mangue permite averiguar o seu grau de desenvolvimento, permitindo ainda detectar a resposta desse ecossistema às variações ambientais existentes, bem como identificar e delimitar bosques com propriedades semelhantes e compará-los com outros bosques (SCHAEFFER-NOVELLI; CINTRÓN-MOLERO, 1986; SOARES et al., 2005). Indicadores de biodiversidade em uma floresta, na escala da unidade amostral mínima representativa do bosque ou tipo florestal, podem ser obtidos com a identificação de espécies e/ou com base na identificação estrutural (MCELHINNY et al., 2005). Na análise da dinâmica florestal são investigadas mudanças na composição e estrutura ao longo do tempo (DAHDOUH-GUEBAS et al., 2002). Dahdouh-Guebas et al. (2002) investigaram a dinâmica da vegetação de bosques de mangue com desenvolvimento estrutural e níveis de degradação distintos, e sua relação com fatores ambientais como salinidade, intensidade luminosa, aporte hídrico e abundância de caranguejos herbívoros. Os resultados mostraram que a estrutura dos bosques é mais complexa em locais com menor distúrbio e que a altura das árvores e densidade de indivíduos são maiores para estes locais.

Segundo Franklin et al. (2002), a estrutura de um ecossistema florestal inclui a variedade estrutural dos indivíduos e o arranjo espacial destas estruturas. Este arranjo espacial compreende a distribuição vertical dos galhos e folhagens e a distribuição horizontal das árvores e outras estruturas como clareiras e troncos caídos. O padrão espacial vertical e horizontal de distribuição estrutural influencia a funcionalidade do ecossistema. A alta densidade vertical numa floresta, além de afetar o microclima,

oferece proteção para pequenos animais. A vegetação com alta densidade horizontal também proporciona proteção para os animais que habitam a superfície, ou seja, a densidade vertical e horizontal numa floresta são fatores importantes ecologicamente (BARKMAN, 1988). Embora considerando arbitrárias as classificações dos estágios de desenvolvimento estrutural de florestas, Franklin et al. (2002) apontam, no entanto, a utilidade prática de se reconhecer uma série de estágios de desenvolvimento comumente encontrados e nos quais predominam condições estruturais e processos de desenvolvimento específicos. Os estágios assim identificados seriam: (1) criação de distúrbio (por incêndios, etc.) e legado biológico (os organismos sobreviventes ao distúrbio), (2) estabelecimento de novos grupos (novas gerações de árvores), (3) fechamento do dossel (encontro e sobreposição das copas das árvores), (4) acumulação da biomassa e exclusão competitiva, (5) maturação (árvores atingem o máximo de altura e expansão dos dosséis), (6) diversificação vertical, (7) diversificação horizontal e (8) perda dos grupos pioneiros. Esta classificação tem por base os processos de nascimento, crescimento, decadência, e morte das árvores.

Segundo Newton (2007), a caracterização estrutural da vegetação de uma floresta pode ser feita por amostragem da população florestal. Uma amostra deve ser representativa de uma comunidade. A área amostral mínima da parcela depende principalmente da composição das espécies na comunidade (DAHDOUH-GUEBAS; KOEDAM, 2006; KNAPP, 1984). A seleção do tamanho apropriado de cada parcela depende das características de cada floresta e dos objetivos do estudo. Para caracterizar o desenvolvimento estrutural dos bosques de mangue em estudos de ecologia de manguezais, Schaeffer-Novelli e Cintrón (1986) padronizaram uma metodologia na qual as parcelas são delimitadas com tamanhos variáveis, em função da densidade de indivíduos. A definição da localização das parcelas, bem como do tamanho das mesmas, é feita em função das características estruturais representativas de cada bosque de mangue (FROMARD et al., 1998). Assim, bosques com alta densidade de indivíduos jovens podem ser representados por parcelas menores do que bosques menos densos e com indivíduos mais desenvolvidos estruturalmente. A decisão sobre as técnicas mais apropriadas para cada situação particular depende dos objetivos da pesquisa. Estrada (2009) determinou a área amostral mínima necessária para caracterizar a estrutura

vegetal de florestas de mangue na região sudeste do Brasil. O autor demonstrou que existe uma tendência de redução da área amostral mínima relacionada à redução do desenvolvimento estrutural, recomendando a utilização de parcelas com área de 100 a 450 m² para florestas de franja, 25 a 180 m² para florestas de bacia e 15 a 50 m² para florestas arbustivas de transição.

2.3 Biomassa

O termo "biomassa" refere-se à matéria (massa) de organismos vivos (bio), incluindo plantas, animais e microorganismos (ou de um ponto de vista bioquímico: celulose, lignina, açúcares, gorduras, proteínas). A biomassa, enquanto matéria orgânica, inclui tanto a viva como a morta. Nos estudos de biomassa florestal, porém, o termo "biomassa" nem sempre inclui todas as formas de matéria orgânica vegetal. Nestes estudos, geralmente o termo "biomassa" refere-se apenas à matéria "viva" da planta, salvo quando especificado de outro modo. Para designar a biomassa vegetal morta (madeiras mortas, serapilheira, etc.), emprega-se geralmente o termo "matéria orgânica morta" (DOM, do inglês *dead organic matter*), e quando esta se fragmenta e se decompõe, incorporando-se ao solo, passa a ser designada como "matéria orgânica do solo" (SOM, do inglês *soil organic matter*) (HOUGHTON, 2008; IPCC, 2006).

A biomassa de uma espécie vegetal, ou grupo de espécies, ou comunidade, é o conteúdo total de matéria orgânica viva presente em um dado local em determinado tempo (WESTLAKE, 1963). Isto inclui tanto a biomassa que está acima da superfície do solo, como a que está abaixo. A biomassa acima do solo (AGB, do inglês *above-ground biomass*) é definida como toda a biomassa vegetal viva lenhosa e herbácea acima do solo incluindo o caule, troncos, galhos, cascas, sementes e folhagens (IPCC, 2006). Em estudos de manguezais incluem-se ainda as raízes aéreas (*Rhizophoras*) acima do solo (DONATO et al., 2011; SOARES, 1997). A biomassa abaixo do solo (BGB, do inglês *below-ground biomass*) inclui todas as raízes vivas da planta.

Os estudos de biomassa florestal tornaram-se hoje objeto de especial interesse público, sobretudo por causa das relações entre a biomassa florestal e o CO₂ atmosférico, e deste com as mudanças climáticas. Com efeito, a biomassa vegetal, incluindo as partes acima

e abaixo do solo, é a principal via para remoção de CO₂ da atmosfera através dos processos da fotossíntese e respiração (IPCC, 2006). No processo de fotossíntese, a vegetação absorve e armazena na matéria orgânica produzida grande parte do carbono atmosférico, contribuindo assim para atenuar o efeito estufa e retardar as mudanças climáticas em curso (HAGER; SCHWEDENMANN, 2016). Porém, os estudos e estimativas de biomassa florestal não se limitam a este aspecto, nem possuem esta única finalidade. Pois os serviços gerados pelas florestas não se reduzem ao sequestro e armazenamento do CO₂ atmosférico (nem ao fornecimento de madeira e celulose para as indústrias). O estudo e o monitoramento das florestas com vistas à sua conservação e preservação, são necessários por outras razões também: desde a sobrevivência de inúmeras espécies vegetais e animais, até a sobrevivência de incontáveis comunidades humanas que vivem integradas aos ecossistemas florestais. As maiores incertezas sobre biomassa florestal e taxas de desflorestamento são relativas às florestas tropicais, indicando a necessidade de estudos mais detalhados nestas áreas (HOUGHTON, 2005). Em relação aos manguezais brasileiros, Soares e Schaeffer-Novelli (2005) constataram, de modo enfático, a enorme escassez de estudos e de dados sobre a biomassa destas florestas.

Segundo Fromard et al. (1998) e Soares et al. (2005), estudos sobre a biomassa de espécies de mangue são utilizados para estimar a produtividade dos manguezais, determinar o estoque e ciclagem dos elementos deste ecossistema, estimar o grau de maturidade, desenvolvimento estrutural e nível de estresse. Essas estimativas auxiliam na determinação do grau de restauração de áreas degradadas, permitindo também estimar e analisar o estoque e a ciclagem de carbono, assim como analisar a dinâmica deste ecossistema.

Estimar a biomassa em florestas tropicais requer um amplo conjunto de dados provenientes de estudos ecológicos que mensuram a biomassa diretamente. Estas medições podem ser realizadas por diferentes métodos. O método mais direto, custoso e destrutivo, consiste em delimitar parcelas e efetuar o desbaste de todos os indivíduos pertencentes à parcela para posterior tratamento e pesagem, sendo feita em seguida a extrapolação destes resultados para a área total de interesse. Ou então emprega-se o método por amostragem de indivíduos, selecionados segundo a espécie e conforme o

seu diâmetro a altura do peito (DAP), de modo a representarem todas as classes de diâmetro daquela espécie encontradas na área pesquisada. Os indivíduos assim selecionados são medidos e coletados para posterior tratamento e pesagem. Os resultados destas medições permitem a obtenção de modelos de regressão que relacionam determinadas medidas estruturais com a biomassa propriamente dita (FROMARD et al., 1998; KOMIYAMA et al., 2008; SOARES et al., 2005), de modo que se possa estimar a biomassa de árvores daquela mesma espécie a partir de suas propriedades estruturais, medidas mais facilmente e sem necessidade de destruí-las. Para o caso do modo indireto, tais modelos de regressão são então aplicados aos indivíduos estruturalmente mensurados dentro de parcelas representativas com tamanho delimitado. Para elaborar os modelos de regressão utilizados em estimativas da biomassa pode-se empregar diversas variáveis estruturais, tais como: DAP, altura, densidade da madeira, área basal, área da copa, diâmetro médio da copa, volume parabólico, volume do cone, volume do cilindro ou combinações destas variáveis.

Um exemplo detalhado de metodologia para estimativa de biomassa de mangue aplicada no Brasil é encontrado nos trabalhos de Estrada (2013) e Soares et al. (2005). Estes autores elaboraram modelos de regressão relacionando medidas estruturais como altura, DAP, diâmetro e área da copa com a biomassa aérea total e por diversos compartimentos das espécies *Rhizophora mangle*, *Laguncularia racemosa* e *Avicennia schaueriana* para o manguezal do sudeste do Brasil. Modelos alométricos para estimativa de biomassa em manguezais podem ser encontradas em Estrada (2013), Estrada et al. (2014), Fu e Wu (2011), Komiyama et al. (2008), Medeiros e Sampaio (2008), Soares et al. (2005). Alguns modelos alométricos para a estimativa de biomassa para os manguezais do Brasil são encontradas na Tabela 2.1 a seguir. Estas são as equações para estimativa de biomassa das espécies *Laguncularia racemosa* e *Rhizophora mangle* (SOARES, 1997; SOARES et al., 2005), *Avicennia schaueriana* e das três espécies juntas obtidas em ESTRADA et al. (2014).

Tabela 2.1 - Modelos alométricos para estimativa de biomassa acima do solo (AGB em gramas) para árvores vivas e mortas.

Espécie	Modelo alométrico	R ² adj	SSE
AGB para indivíduos vivos			
<i>A. schaueriana</i>	$\text{Ln}(\text{TOTAL}) = 4.8017 + 2.5282 \times \text{Ln}(\text{DAP})$	0.994	0.187
<i>L. racemosa</i>	$\text{Ln}(\text{TOTAL}) = 14.2536 + 0.4985 \times \text{Ln}(\text{BA}^2 \times \text{Ht})$	0.987	0.194
<i>L. racemosa</i>	$\text{Ln}(\text{TOTAL}) = 5.2394 + 2.2792 \times \text{Ln}(\text{DAP})$	0.986	0.204
<i>R. mangle</i>	$\text{Ln}(\text{TOTAL}) = 14.9105 + 0.5261 \times \text{Ln}(\text{BA}^2 \times \text{Ht})$	0.991	0.171
<i>R. mangle</i>	$\text{Ln}(\text{TOTAL}) = 5.2985 + 2.4810 \times \text{Ln}(\text{DAP})$	0.989	0.182
AGB para indivíduos mortos			
<i>A. schaueriana</i>	$\text{Ln}(\text{TR} + \text{MBr}) = 4.4117 + 2.5578 \times \text{Ln}(\text{DAP})$	0.992	0.227
<i>L. racemosa</i>	$\text{Ln}(\text{TR} + \text{MBr}) = 4.9308 + 2.2951 \times \text{Ln}(\text{DAP})$	0.989	0.181
<i>R. mangle</i>	$\text{Ln}(\text{TR} + \text{PR}) = 4.9851 + 2.5142 \times \text{Ln}(\text{DAP})$	0.984	0.227

O modelo para a espécie *Avicennia schaueriana* foi obtido de ESTRADA et al. (2014) e para as espécies *Laguncularia racemosa* e *Rhizophora mangle* de SOARES et al. (2005). R²adj = coeficiente de determinação ajustado; SSE = erro padrão da estimativa; DAP = diâmetro a altura do peito (cm); Ht = altura (m); BA = área basal (m²); Total= AGB total da árvore; TR+MBr = AGB do tronco + galhos principais; TR+PR = AGB do tronco + raízes aéreas.

Fonte: adaptado de ESTRADA et al. (2014b).

2.4 Dados e técnicas de sensoriamento remoto

2.4.1 Sistema óptico

Sistemas imageadores ópticos funcionam nos comprimentos de onda do visível e infravermelho do espectro eletromagnético registrando a energia refletida pela vegetação. A energia refletida é igual à energia incidente menos a energia absorvida e transmitida pela superfície foliar da planta (JENSEN, 2007). A interação da vegetação com a energia eletromagnética está relacionada, principalmente, com o processo de fotossíntese. Este processo é fundamentado na absorção da energia luminosa do sol, especificamente nos comprimentos de onda de 0,4 a 0,72 µm no visível, por parte dos pigmentos fotossintetizantes como as clorofilas, xantofilas e carotenos. Já nos comprimentos de onda de 0,72 a 2,6 µm no infravermelho, a refletância é controlada pelo mesófilo esponjoso e conteúdo de água foliar (PONZONI; SHIMABUKURO, 2007). Dessa forma, o estudo das características espectrais de um tipo vegetal pode ser

útil na identificação do estresse vegetal, produtividade, fenologia e identificação de espécies.

Para estudos do ecossistema manguezal, imagens de sensores ópticos são utilizadas em diversas abordagens, tais como: distribuição e mapeamento de áreas de mangue (GAO, 2010; GIRI et al., 2011; GREEN et al., 1998; KAMAL et al., 2015; SATYANARAYANA et al., 2011; VO et al., 2013; WANG et al., 2016; YANG et al., 2009), discriminação de espécies e tipos de mangue (HEUMANN, 2011a; HUANG et al., 2009; KAMAL; PHINN, 2011; KOEDSIN; VAIPHASA, 2013; WANG et al., 2008), mapeamento e estimativa de parâmetros estruturais e biomassa (HIRATA et al., 2013; JACHOWSKI et al., 2013; LAGOMASINO et al., 2015; MITCHELL et al., 2007; PROISY, 2007; WANG; GLENN, 2008; ZHU et al., 2015), avaliação e estimativa de índice de área foliar (GREEN et al., 1997; ILL; JENSEN, 1996; KOVACS et al., 2004), detecção de mudanças e monitoramento (JAHARI et al., 2011; LUCAS et al., 2002; NFOTABONG-ATHEULL et al., 2013) e proteção da linha de costa (OLWIG et al., 2007).

Índices de vegetação baseados em dados de reflectância espectral foram desenvolvidos para estimar propriedades biofísicas como a biomassa, índice de área foliar (IAF) e porcentagem de cobertura de dosséis vegetais. Elvidge e Chen (1995) e Jensen (2007) resumem os principais índices de vegetação utilizados nesses estudos, cabendo mencionar: razão simples (RS), índice de vegetação por diferença normalizada (NDVI, do inglês *Normalized Difference Vegetation Index*), índice de vegetação realçado (EVI, do inglês *Enhanced Vegetation Index*), índice de vegetação ajustado ao solo (SAVI, do inglês *Soil-adjusted Vegetation Index*) e índice de vegetação por diferença (DVI, do inglês *Difference Vegetation Index*). As respectivas equações, fontes e maiores informações destes e outros índices de vegetação podem ser encontrados em Elvidge e Chen (1995), Huete et al. (2002) e Jensen (2007). Colwell (1974) identificou diferentes fatores que podem influenciar a refletância do dossel vegetal, tais como: refletância e transmitância hemisférica foliar e da estrutura da planta, área e orientação foliar, refletância efetiva do solo, ângulo zenital solar, ângulo de visada e ângulo azimutal. Os índices de vegetação possibilitam remover algumas destas influências citadas anteriormente, como por exemplo, as condições atmosféricas, ângulo de visada solar,

influência da reflexão do solo e geometria do dossel. A caracterização espectral dos manguezais é influenciada principalmente pela vegetação, efeito da maré sobre o solo e propriedades físicas do solo (BLASCO et al., 1998). Modelos de estimativa de parâmetros estruturais utilizando o NDVI são apropriados em estudos multitemporais uma vez que este índice permite atenuar as influências atmosféricas, ainda que seja sensível às influências do substrato e sature para valores altos de IAF e biomassa. Segundo Huete et al. (2002), o NDVI e o EVI se complementam para estudos da cobertura vegetal, para a detecção de mudanças e extração de parâmetros biofísicos do dossel. A grande vantagem do uso do sensoriamento remoto para estimar IAF, biomassa e outros parâmetros estruturais é a possibilidade de mensurar e mapear extensas áreas de mangue com boa relação custo/benefício.

O uso de pares estereoscópicos de alta resolução espacial pode ser útil para caracterizar a altura do dossel florestal a partir de modelos de elevação da superfície (LAGOMASINO et al., 2015; MITCHELL et al., 2007). Com o uso de pares estereoscópicos obtidos com imagens WoldView-1 Lagomasino et al. (2015) modelaram a altura do dossel de manguezais de Moçambique (África), utilizando um modelo digital de elevação da superfície. Os resultados apresentaram boa correlação ($R^2 = 80$, RMSE = 1,18 m) entre a altura média estimada com uso dos pares estereoscópicos e dados de campo e para a altura das cem árvores eminentes - (H100) ($R^2 = 0,87$, RMSE = 1,84 m). Comparando resultados de estimativas de altura do dossel de floresta de mangue com a altura obtida por modelos de superfície gerados com outros tipos de dados de sensoriamento remoto como o *Shuttle Radar Topography Mission* (SRTM), *Light Detection and Ranging* (LiDAR) e *Synthetic Aperture Radar* (SAR) banda X do TanDEM-X, foi observado que dosséis acima de 10 m foram preditos com boa acurácia por todos os tipos de modelos de superfície, enquanto o uso de pares estereoscópicos de imagens ópticas de alta resolução apresentou melhores resultados na predição da distribuição da altura dos dosséis (LAGOMASINO et al., 2016). A escolha e uso de diferentes fontes de dados de sensoriamento remoto depende da abordagem e estratégias requeridas para atender às necessidades de caracterização e monitoramento em escala regional ou global.

A caracterização e análise textural em imagens de alta resolução espacial tem sido efetiva para a detecção de feições, caracterização florestal, estimativa de parâmetros estruturais, biomassa (BARBIER et al., 2006; BASTIN et al., 2014; COUTERON, 2002; COUTERON et al., 2005;2006; ECKERT, 2012; KENNEL et al., 2013; LU; BATISTELLA, 2005; MENG et al., 2016; NICHOL; SARKER, 2011; SARKER; NICHOL, 2011; WANG et al., 2016; WANG et al., 2014; ZHANG; XIE, 2012) e mais especificamente, para estimativas de biomassa de manguezais (PROISY et al., 2007; 2011; NFOTABONG-ATHEULL, 2011). Imagens de alta resolução espacial permitem identificar sombras e dosséis iluminados pela luz solar, o que pode ser fonte de informação importante sobre a estrutura do dossel.

De acordo com Tuceryan e Jain (1998) a textura da imagem pode ser definida como uma função da variação espacial das intensidades (níveis digitais) dos pixels. Imagens de objetos reais raramente apresentam regiões de intensidades uniformes. A imagem de uma superfície de madeira, por exemplo, não é uniforme, mas contém variações de intensidades que formam certos padrões repetidos chamados de textura visual. Estes padrões podem ser o resultado das propriedades físicas da superfície (lisa ou rugosa) ou o resultado de diferenças na reflectância desta (como as cores numa superfície). Não existe uma definição de textura que seja geralmente aceita. Algumas definições são motivadas perceptualmente, outras completamente orientadas pela aplicação na qual a definição será utilizada.

Segundo Haralick (1979) e Haralick et al. (1973) a textura de uma imagem é descrita pelo número e tipos de seus componentes tonais, ou *tonal primitives* (regiões com propriedades tonais diferentes), e pela organização espacial destes seus componentes. Ou seja, a textura apresenta duas dimensões básicas a serem descritas: (i) uma relativa aos elementos tonais (*tonal primitives*) que compõem a textura da imagem; e (ii) outra relativa à organização espacial destes elementos. O conceito de tonalidade baseia-se na variação de tons de cinza nas células de resolução em uma imagem, enquanto que a textura diz respeito à distribuição espacial estatística dos tons de cinza (HARALICK, 1979).

A textura de uma imagem é utilizada em variadas aplicações para o reconhecimento de regiões homogêneas. A identificação destas regiões homogêneas é a classificação textural, que objetiva identificar regiões texturais uniformes relacionadas com classes de textura. Para caracterizar a textura de uma imagem é necessário caracterizar tanto as propriedades tonais dos pixels como a inter-relação entre elas. Algumas propriedades básicas da textura são descritas em Tuceryan e Jain (1998): (i) textura é uma propriedade contextual e sua definição deve envolver valores de cinza da vizinhança espacial; (ii) textura envolve a distribuição espacial dos níveis de cinza; (iii) textura na imagem pode ser percebida em diferentes escalas de resolução; (iv) quando existe um grande número de objetos primitivos em uma região esta é perceptível de ter textura. Uma propriedade importante da tonalidade e textura é o padrão espacial das células (pixels) compondo cada característica tonal. Desta forma, qualidades perceptíveis da textura tais como a uniformidade, densidade, aspereza, rugosidade, regularidade, linearidade, direção, frequência e fase são importantes descritores. A textura da imagem pode ser avaliada qualitativamente por algumas destas propriedades.

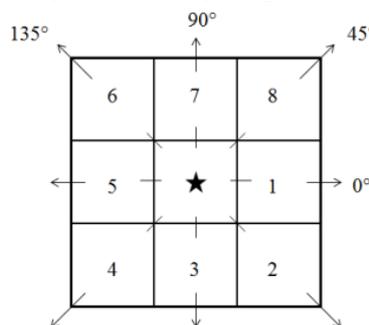
Técnicas de extração de informações das imagens foram desenvolvidas objetivando detectar distintos padrões texturais que refletem diferentes alvos ou mesmo características dos dosséis florestais, como por exemplo, o método *Gray Level Co-occurrence Matrices* (GLCM), o método utilizando análise espectral bidimensional com a transformada rápida de Fourier como o *FOurier-based Textural Ordination* (FOTO), Transformada em *Wavelet*, dentre outros (COUTERON et al., 2006; HARALICK; SHANMUGAM, 1973; HARALICK, 1979; LIVENS et al., 1997; NFOTABONG-ATHEULL, 2011; PROISY et al., 2007).

Gray Level Co-occurrence Matrix (GLCM)

A distribuição espacial dos valores de cinza é uma das qualidades da textura que a define. O método GLCM apresentado em Haralick (1979) e Haralick et al. (1973) para caracterização textural, sumariza a relação espacial de níveis de cinza entre pares de pixels. Isto é feito armazenando a frequência que cada nível de cinza está relacionado com o nível de cinza dos pixels vizinhos. Supõe-se, portanto, que a informação textural pode ser adequadamente especificada pela matriz de frequência relativa que dois pixels

vizinhos separados por uma distância, um com nível de cinza i e outro com nível de cinza j , ocorre na imagem (HARALICK et al., 1973). Desta forma, assume-se que a informação textural é especificada por um conjunto de matrizes de tons de cinza espacialmente dependentes computadas por meio das relações angulares e distâncias entre os pares de células vizinhas. Haralick et al. (1973) consideram que uma célula de resolução tem oito células de resolução como vizinho mais próximo (Figura 2.1). Segundo os autores, o pressuposto para caracterizar a textura da imagem é que as informações texturais estão contidas nas matrizes de dependência espacial de níveis de cinza. Desta forma, todas as informações texturais ou índices texturais GLCM são derivadas destas matrizes de dependência. Diferentes medidas para extração e caracterização de informações texturais de imagens foram apresentadas em Haralick et al. (1973), tais como: *angular second moment*; *contrast*; *correlation*; *variance*; *inverse difference moment*; *sum average*; *sum variance*; *sum entropy*; *entropy*; *difference variance*; *difference entropy*; *information measures of correlation*; *maximal correlation coefficient*. As respectivas equações das medidas de caracterização textural e maiores informações sobre métodos de análise e extração textural podem ser encontradas em Haralick (1979) e Haralick et al. (1973).

Figura 2.1 - Demonstração do arranjo espacial das células adjacentes.



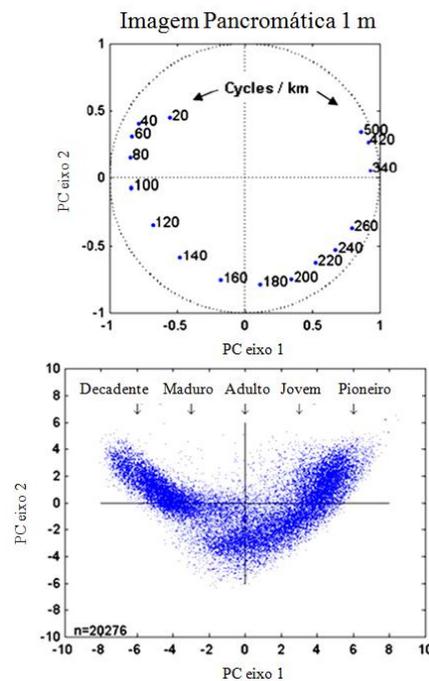
Demonstração do arranjo espacial das células adjacentes que consideram oito células de resolução como vizinho mais próximo da célula central, sendo que as células 1 e 5 estão a 0° da célula de resolução central; as células 2 e 6 estão a 135° da célula central; as células 3 e 7 estão a 90° da célula central e as células 4 e 8 estão a 45° da célula central. Fonte: Adaptado de Haralick et al. (1973).

FOurier-based Textural Ordination (FOTO)

Couteron et al. (2006) e Proisy et al. (2007) desenvolveram um método para extração da textura de imagens de alta resolução chamado FOTO. O método FOTO é baseado na ordenação textural fundamentado na análise da transformada rápida de Fourier discreta (FFT, do inglês *Fast Fourier Transform*) e análise de principais componentes (PCA, do inglês *Principal Component Analysis*). Na imagem óptica a ser analisada os dosséis florestais apresentam granulometrias com distintos graus de repetitividade e o uso da transformada de Fourier permite modificar as propriedades granulométricas do dossel no domínio espacial (imagem) para o domínio da frequência. O método extrai informações texturais da imagem e ordena estas informações de acordo com o gradiente textural observado na imagem. Aplica-se o método em uma imagem contendo áreas de floresta e com um intervalo de níveis de cinza expressando a radiância de cada pixel. O método utiliza uma janela de análise, na qual são computados os respectivos valores de espectro radial de Fourier (*r-spectra*). A escolha do tamanho da janela amostral pode variar em função da análise que se pretende e tipo florestal, mas é importante que dentro da janela estejam incluídas várias repetições do maior padrão de interesse (ex: copas das árvores) (BARBIER et al., 2010; COUTERON et al., 2006). O *r-spectrum* representa a frequência da distribuição dos padrões de tamanho na rugosidade do dossel. Um valor de baixa frequência espacial indica que a janela contém objetos grandes - dosséis largos, enquanto que a alta frequência espacial descreve a contribuição de textura granulométrica fina, isto é, dosséis de indivíduos jovens. Este método permite quantificar as propriedades texturais referentes à rugosidade por meio da análise da decomposição da variância entre frequências espaciais. A variabilidade entre os espectros é analisada pela análise de principais componentes. A análise de principais componentes é um método de ordenação que estabelece um conjunto de eixos perpendiculares a partir de uma matriz de correlação (VALENTIN, 2012). Esta análise permite a identificação do principal gradiente de variação textural entre janelas, separando os dosséis dominados por pequenas árvores daqueles dominados por grandes árvores. Os valores das janelas dos eixos mais proeminentes são utilizados como índices de textura ou chamados índices texturais FOTO ou FOTO índices (PROISY et al., 2011; PROISY et al., 2007). O primeiro eixo da PCA geralmente expressa o gradiente de

rugosidade do dossel florestal, como pode ser observado na Figura 2.2. A Figura 2.3 exemplifica o *r-spectrum* médio dos estágios sucessionais. O método FOTO permite ordenar (por amostragem das janelas da imagem) os dosséis florestais com respeito às suas granulações (PLOTON et al., 2012). Assim, são obtidos os FOTO índices, que são os valores das componentes da PCA respectivos para cada parcela de estudo. A modelagem da AGB é realizada por meio da análise de regressão utilizando os FOTO índices como variáveis preditoras e os valores de biomassa florestal obtidos *in situ* como verdade de campo. Detalhes das funções e maiores explicações da análise espectral bidimensional através da transformada de Fourier podem ser encontradas em Muggleston e Renshaw (1998), Renshaw e Ford (1984), e mais especificamente sobre o método FOTO em Coueron (2002), Coueron et al. (2005;2006) e Proisy et al. (2007).

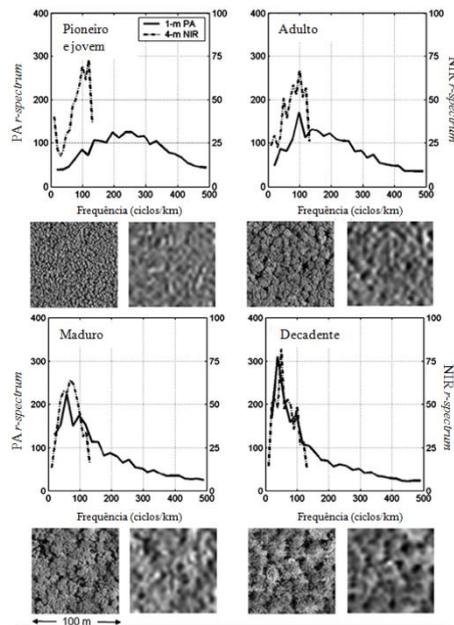
Figura 2.2 - Ordenação dos índices texturais obtidos com o método FOTO.



Ordenação dos índices texturais obtidos com o método FOTO no plano formado pelos eixos das componentes principais 1 e 2 (PC1 e PC2), utilizando uma imagem pancromática de alta resolução espacial. Observa-se a ordenação referente aos bosques de mangue de distintos estágios sucessionais - pioneiro, jovem, adulto, maduro e decadente.

Fonte: Adaptado de Proisy et al. (2007).

Figura 2.3 - Exemplo de espectros radiais de Fourier (*r-spectra*) médios dos estágios de desenvolvimento sucessional de bosques de mangue.



Exemplo de *r-spectra* médios dos estágios de desenvolvimento sucessional de bosques de mangue, para jovem, adulto, maduro e decadente. PA=pancromática, NIR=infravermelho próximo.

Fonte: Adaptado de Proisy et al. (2007).

O método FOTO foi testado em florestas tropicais (BARBIER et al., 2010; BASTIN et al., 2014; COUTERON et al., 2005; PLOTON et al., 2012), no semiárido (COUTERON, 2002) e em manguezais com diferentes estágios de desenvolvimento (NFOTABONG-ATHEULL, 2011; PROISY, 2007). Barbier et al. (2010) simularam imagens de dosséis homogêneos florestais com distintos tamanhos de copas utilizando o modelo de transferência radiativa *Discrete Anisotropic Radiative Transfer* (DART) e aplicando o método FOTO. O resultado apresentado demonstrou forte relação dos índices FOTO com as informações granulométricas dos dosséis florestais ($R^2=0,96$) indicando que a granulometria do dossel capturada pelos índices FOTO diz respeito principalmente aos padrões periódicos de repetição dos diâmetros das copas presentes nas imagens. O método FOTO foi utilizado para analisar a textura de dosséis de mangue com diferentes estágios de desenvolvimento estrutural e para mensurar e mapear a biomassa de manguezais na Guiana Francesa (PROISY et al., 2007). Os autores utilizaram imagens pancromática e multiespectral, com resolução de 1 m e 4 m respectivamente, do sensor IKONOS. O melhor resultado para a predição da biomassa total ($R^2 = 0,92$ e $RMSE < 33$ t/ha) foi obtido com o uso da imagem pancromática com

janelas de 50 pixels. Com a aplicação deste método foi possível capturar o gradiente textural na imagem resultante de diferentes estágios de desenvolvimento florestal, com estágios jovens apresentando textura fina e estágio de bosques maduros apresentando textura grossa (Figura 2.3). A biomassa de mangue estimada variou de 50 a 450 t/ha, sem saturação do sinal para valores mais altos de AGB. Esta característica de não saturação do sinal para altos valores de AGB florestal é interessante na medida em que outras estimativas baseadas em dados SAR banda-P, na mesma região de estudo, saturaram em 160 t/ha (MOUGIN et al., 1999).

Nfotabong-Atheull (2011) aplicou o método FOTO em imagens de alta resolução QUICKBIRD com resolução de 1 m objetivando estimar a distribuição do diâmetro da árvore, biomassa e estoque de carbono do manguezal preservado no estuário de *Cameroon* em Camarões, na África. As estimativas apresentaram boas correlações para o diâmetro ($R^2 = 0,84$; RMSE = 1,88 cm) e biomassa ($R^2 = 0,92$; RMSE = 19,7 t/ha). A maior parte da biomassa mapeada variou entre 200 a 300 t/ha. Como esperado, com o método FOTO não se obteve saturação da estimativa de biomassa para valores de AGB relativamente mais altos.

Entretanto, as aplicações do método FOTO no estudo de manguezais ainda podem ser consideradas incipientes (NFOTABONG-ATHEULL, 2011; PROISY, 2007). Ainda assim, os resultados obtidos mostraram-se promissores para o uso de imagens ópticas de alta resolução dedicadas à caracterização de parâmetros biofísicos e estimativa de biomassa de manguezais preservados e com distintos estágios de desenvolvimento estrutural.

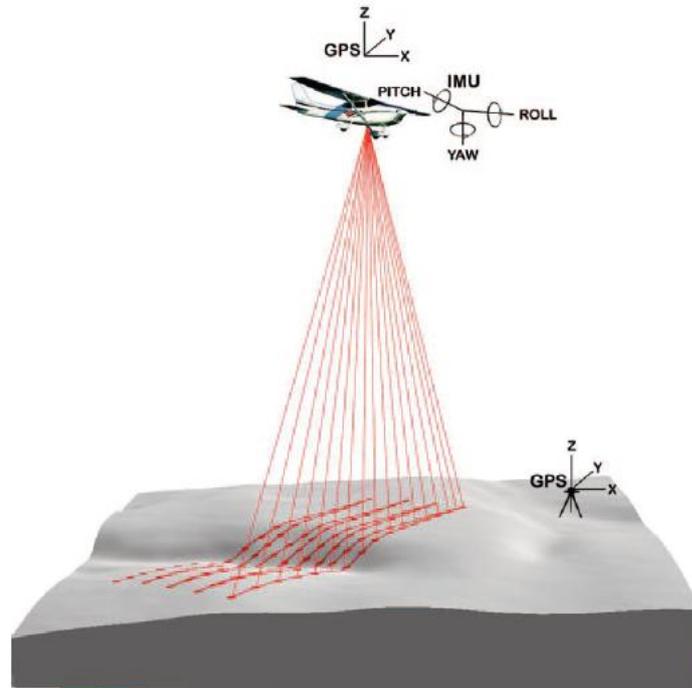
2.4.2 *Light Detection and Ranging (LiDAR)*

O LiDAR é um sensor ativo de sistema a laser que emite feixes ópticos em direção ao solo usando um espelho de varredura que recebe a porção do laser retroespalhada. Com o uso sinérgico de sistemas de posicionamento global (GPS) e de medição inercial (IMU do inglês *Inertial Measurement Unit*), são registradas as localizações exatas, a altitude das plataformas onde o sensor está instalado, os movimentos da aeronave (*roll, pitch e yaw*) nos instantes em que o pulso LiDAR é emitido e recebido (Figura 2.4)). O

sistema mede o tempo da trajetória do pulso emitido e recebido pelo sensor, possibilitando calcular a distância percorrida pelo feixe na velocidade da luz. Os sistemas LiDAR emitem feixes de luz com comprimento de onda variando do visível ao infravermelho próximo, dependendo do equipamento utilizado e/ou objetivo do estudo. O sinal de retorno varia em intensidade dependendo da energia inicial do pulso, tamanho do objeto interceptado e características de reflectância do alvo. A densidade de pontos depende da altitude do sensor, velocidade da plataforma, campo de visada do sistema e frequência de amostragem (AXELSSON, 1999). O tamanho da área de cobertura instantânea do laser (*footprint*) gerada pelo pulso LiDAR ao encontrar a superfície amostrada depende do ângulo fornecido pelo espelho rotativo, da altitude do sensor e da topografia do terreno (ou superfície) (JENSEN, 2007). O *footprint* corresponde à área do campo de visada instantânea do LiDAR projetada no solo (SHENG, 2008). Sistemas LiDAR podem ser classificados em duas categorias: (i) sistema LiDAR de retorno discreto e (ii) sistema de onda contínua (*waveform*). O sistema *waveform* coleta a energia de retorno em onda contínua num intervalo de tempo (SHENG, 2008) medindo a diferença de fase entre o sinal emitido e o sinal recebido após este ter sido retroespalhado pela superfície (WEHR; LOHR, 1999). Normalmente, possui maior *footprint* que o sistema de retorno discreto. Este último sistema coleta um ou mais pulsos discretos com menor *footprint* e alta resolução espacial.

O conjunto de dados LiDAR de retorno discreto deve incluir: número de pulsos, número de retornos, coordenadas geográficas, elevação e intensidade do retorno para cada retorno LiDAR, além do metadado documentando os parâmetros da missão do vôo LiDAR, tipo de sensor e respectivas configurações, GPS, datum vertical e horizontal, unidades das coordenadas e projeção, data e hora da missão (REUTEBUCH et al., 2005). Detalhes sobre o funcionamento dos dois sistemas, discreto e contínuo, suas características e equações para os cálculos da distância, área de cobertura do pulso, largura da faixa de cobertura, ângulo de varredura e densidade de amostragem dos pontos podem ser encontradas, por exemplo, em Axelsson (1999); Baltsavias (1999); Jensen (2007); Sheng (2008) e Wehr e Lohr (1999).

Figura 2.4 - Esquema demonstrando a coleta de dados LiDAR sobre o terreno.



Observa-se os sistemas de posicionamento global (GPS) e de medição inercial IMU, registrando posicionamento (x, y z) e os movimentos da aeronave (*roll*, *pitch* e *yaw*).
Fonte: Adaptado de Reutebuch et al.(2005).

2.4.2.1 LiDAR e floresta

Considerando a capacidade de se obter informações sobre a topografia do solo, cobertura da superfície, penetração nos dosséis florestais e detecção da estrutura florestal tridimensional, é possível também obter informações sobre os atributos estruturais de florestas direta e indiretamente com dados LiDAR. Exemplos de atributos estruturais derivados de dados LiDAR incluem a altura da árvore, topografia do sub-bosque, discriminação de copas das árvores, cobertura do dossel, volume do dossel, índice de área foliar, diâmetro médio do tronco, densidade de indivíduos, área basal, biomassa aérea e estimativas de carbono florestal (ASNER et al., 2012; FATOYINBO; SIMARD, 2013; LEFSKY et al., 1999; LIM et al., 2003; NÆSSET, 2002;2011; NELSON et al., 1988; POPESCU, 2007; RIAÑO et al., 2004; WANG; GLENN, 2008; WANNASIRI et al., 2013; ZHANG, 2008; ZHANG et al., 2008; ZOLKOS et al., 2013). Uma importante vantagem dos sistemas LiDAR é a possibilidade de obter informações

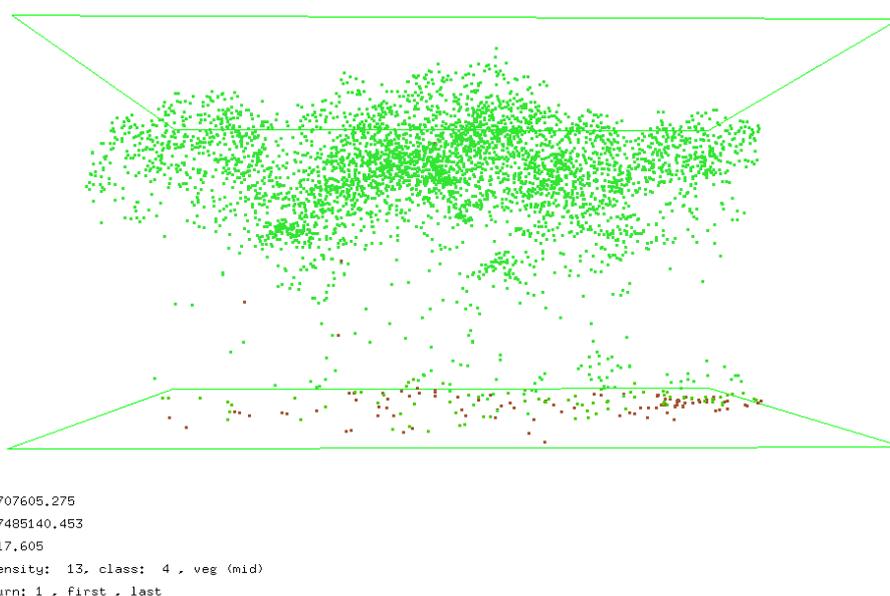
sobre a distribuição dos elementos no sub-bosque florestal (LEE; LUCAS, 2007). Entretanto, a habilidade de se obter as informações do sub-dossel depende da capacidade do pulso LiDAR de atravessar o dossel dada a estrutura deste (LIM et al., 2003). De acordo com ASNER et al. (2012), a capacidade do LiDAR penetrar no dossel e detectar a estrutura tridimensional de florestas o torna um importante componente de estratégias internacionais de mensuração e estimativa de biomassa e de emissões de carbono por florestas tropicais.

Os dois sistemas LIDAR, de pulso discreto e *waveform*, possibilitam a realização de estudos sobre as características florestais. Means et al. (1999) utilizaram o sistema LIDAR *waveform* com *footprint* de 10 m de diâmetro para estimar características estruturais como altura da árvore, área basal e biomassa de florestas obtendo boas correlações com medidas obtidas *in situ* ($R^2 = 0,95, 0,96$ e $0,96$, respectivamente).

O sistema LiDAR de retorno discreto pode gerar um retorno ou múltiplos retornos quando, por exemplo, a energia interagir somente com o solo e retornar para o sensor ou interagir com a copa da árvore ou interior desta, proporcionando assim dois ou mais retornos em tempos distintos. Neste sistema de nuvens de pontos discretos a estimativa da altura do dossel é calculada pela diferença entre o dado LiDAR de retorno classificado como vegetação e a superfície representativa do terreno. O modelo digital do terreno (DTM do inglês *digital terrain model*) e o modelo digital da superfície (DSM do inglês *digital surface model*) podem ser obtidos por meio de técnicas de interpolação dos pontos representativos do terreno e representativos da superfície. Para o caso de estudos florestais os pontos mais altos dentro de uma grade representam o topo dos dosséis (POPESCU, 2007). O modelo de altura do dossel (CHM do inglês *canopy height model*) é uma superfície tridimensional derivada dos dados LiDAR que contém informações sobre a altura da vegetação. O CHM representando a altura do dossel florestal pode ser criado subtraindo-se o DTM, que representa a superfície do terreno, do DSM que representa o topo do dossel. Técnicas de filtragem baseadas em métodos morfológicos ou métodos de interpolação podem ser utilizadas para remover os pontos que não representam o solo, assim gerando o modelo digital de terreno (CHEN et al., 2007; KILIAN et al., 1996; KRAUS; PFEIFER, 1998; SITHOLE; VOSSSELMAN, 2004). Em regiões de floresta com solo alagado, pulsos laser tendem a refletir mais

fracamente no comprimento de onda do infravermelho próximo (CHADWICK, 2011). Assim, a probabilidade de retorno proveniente do terreno é reduzida em relação a superfícies mais secas e reflexivas (HOPKINSON et al., 2005). A Figura 2.5 mostra um exemplo de nuvem de pontos referentes à altura normalizada para uma parcela representativa de bosque de mangue. A altura normalizada é a altura de cada ponto LiDAR acima do solo, assumindo que os pontos referentes ao solo foram anteriormente classificados como solo (*ground*) e interpolados. Na Figura 2.5 pode-se observar que o ponto mais alto referente ao dossel do bosque de mangue possui altura z igual a 17,6 m.

Figura 2.5 - Nuvem de pontos LiDAR de uma parcela de mangue.



Exemplo de nuvem de pontos LiDAR referentes a altura normalizada de uma parcela de bosque de mangue da APA de Guapimirim do presente estudo (área da parcela igual à 408m²). Valores das coordenadas x , y e z do retorno LiDAR mais alto da parcela.

Sensores laser de retorno discreto como o laser *scanning* produzem nuvens de pontos tridimensionais, onde os pontos são ecos provenientes de várias partes do dossel florestal, objetos no solo, raízes, rochas, vegetação rasteira, etc. (NÆSSET, 2011). Muitos sistemas sensores LiDAR permitem obter além das informações de altura dos alvos, informações da intensidade do sinal retroespalhado. A intensidade para o pulso do laser representa um pico de amplitude do pulso de retorno. Valores de intensidade

adquiridos por diferentes sensores podem variar de acordo com as propriedades do pulso emitido, como energia, largura e pico de potência do pulso (NÆSSET, 2016). Em aplicações realizadas em áreas de floresta boreal, o uso de informações da intensidade LiDAR de retorno discreto não possibilitou a classificação ou distinção entre áreas com pequenas árvores e áreas sem árvores, porém as medidas das alturas (z) permitiram esta distinção (NÆSSET, 2016). A estimativa de parâmetros estruturais por meio da nuvem de pontos LiDAR pode ser obtida a partir de relações empíricas entre métricas estatísticas derivadas dos pontos LiDAR referentes à altura do dossel florestal e medidas estruturais obtidas em campo. A forte relação existente entre a AGB e dados LiDAR pode ser atribuída à habilidade deste sistema em capturar com precisão a altura do dossel, sendo que este parâmetro é altamente correlacionado com a biomassa (NÆSSET, 2011). O uso de LiDAR de retorno discreto para o estudo em diferentes tipos de florestas é encontrado na literatura, como para floresta temperada (BALZTER et al., 2007; BANSKOTA et al., 2011; LIM; TREITZ, 2004; NELSON et al., 2007), floresta de coníferas (HAWBAKE et al., 2009), floresta decídua (LI et al., 2008), floresta boreal (BOUDREAU et al., 2008; NÆSSET, 2002;2016; NELSON et al., 2012; NYSTROM et al., 2012) e floresta tropical (CLARK et al., 2011; D'OLIVEIRA et al., 2012; KENNAWAY et al., 2008; LUCAS et al., 2008; MASCARO et al., 2011). Já o uso para estudos de florestas de mangue restringem-se a poucos trabalhos que serão discutidos posteriormente.

A utilização de métricas estatísticas derivadas da distribuição dos pulsos de retorno LiDAR referentes às alturas dos dosséis e estratos florestais é uma abordagem metodológica de extração de informações LiDAR utilizada para estimar os parâmetros estruturais florestais correlacionando com parâmetros estruturais das florestas obtidos *in situ*. Métricas descritivas, tais como o percentil da distribuição dos pontos referentes à altura do dossel, média da altura, altura máxima, mínima, densidade de pontos de acordo com a altura, coeficiente de variação e porcentagem de cobertura do dossel são utilizadas em relações alométricas na estimativa de parâmetros estruturais e AGB (ANDERSEN et al., 2005; JANSEN et al., 2008; NÆSSET; BJERKNES, 2001; NÆSSET, 2002;2011; NELSON et al., 1988, NELSON et al., 1984; POPESCU et al., 2011; RIAÑO et al., 2004; VINCENT et al., 2012; WANG; GLENN, 2008).

Nelson et al. (1984) utilizaram o sistema laser para estudar uma floresta com distintas condições de abertura do dossel. Os resultados indicaram que o fechamento do dossel está fortemente relacionado com a capacidade de penetração do pulso laser, pois os pulsos laser são atenuados mais rapidamente em dosséis densos. Nelson et al. (1988) desenvolveram equações para estimar a biomassa e o volume de floresta de *Pínus* por meio de informações extraídas de dados LiDAR. Métricas descritivas obtidas com dados LiDAR, como por exemplo, as referentes às alturas máximas em uma parcela, média das alturas incluindo e excluindo os pulsos obtidos do solo e densidade do dossel, foram correlacionadas com parâmetros estruturais obtidos *in situ*. Desta forma, os autores selecionaram as melhores equações alométricas para estimar a biomassa e o volume obtendo 53% e 65% de variância explicada, respectivamente.

Næsset (2002) estimou parâmetros estruturais de florestas na escala de bosque (*stand*) com distintos estágios sucessionais por meio de métricas descritivas obtidas com dados LiDAR do sistema laser *scanning* ALTM 1210. O autor utilizou as seguintes métricas descritivas (obtidas acima de 2 m do solo): os percentis de 0, 10, ..., 90 da distribuição de pontos, valor máximo, valor médio, coeficiente de variação e derivações das medidas de densidade do dossel. Foram gerados modelos de regressão para cada estrato vegetal por meio da correlação das informações LiDAR com parâmetros estruturais obtidos *in situ* tais como: a altura média das árvores, altura dominante, diâmetro médio do tronco, número de troncos, área basal e volume da parcela, para 144 parcelas de 200 m². Os melhores resultados para os bosques jovens foram as estimativas da altura dominante ($R^2=0,93$) e altura média (*Lorey's mean height*) ($R^2=0,95$) ambos utilizando as variáveis explicativas altura máxima e quantil de 90. Para bosques maduros (em condição ruim) foram as estimativas da altura média (*Lorey's mean height*) ($R^2=0,86$) utilizando as variáveis quantil 90 e 50. Para floresta madura (boa condição), a altura dominante foi a melhor estimativa ($R^2=0,85$), utilizando percentil 80, altura máxima e densidade do dossel correspondente à proporção dos últimos pulsos acima de 10 quantil e para a altura média (*Lorey's mean height*) ($R^2=0,82$) utilizando percentil 90 e altura máxima. O interessante desta abordagem metodológica é a estimativa dos parâmetros estruturais de bosques florestais com distintos estágios sucessionais e vitalidade.

Næsset (2011) estimou a AGB de florestas jovens de coníferas e decíduas (*spruce, pinus e birch*) na Noruega utilizando métricas derivadas de dados LiDAR do sistema laser *scanning* ALTM 1210. Os resultados destacam que distintas espécies têm significativa influência nos modelos de biomassa. Isto ocorre devido à forma e tamanho das copas, uma vez que os modelos utilizam variáveis explicativas derivadas da distribuição dos pontos LiDAR que são relativos à altura e densidade do dossel. Desta forma, estes parâmetros são influenciados pela estrutura da copa e dossel florestal.

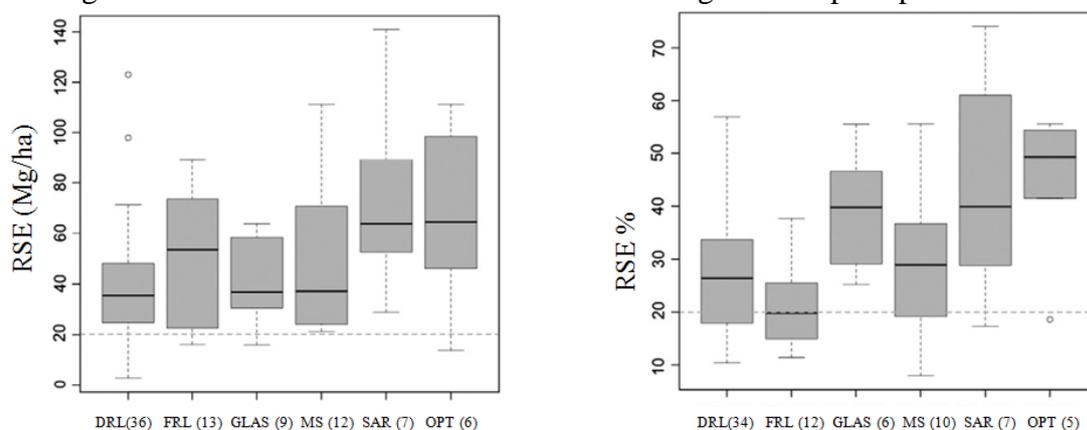
Mascaro et al. (2011b) analisaram o potencial uso de dados LiDAR para estimar a densidade de carbono florestal acima do solo. Os autores correlacionaram a estimativa LiDAR da altura média do perfil de altura do dossel (MCH do inglês *mean canopy profile height*) com dados de campo obtendo $R^2=0,84$ e também examinaram a variação estrutural referente à densidade do dossel florestal baixo e médio por meio da altura padronizada dos pontos LiDAR. Foi observado que a porcentagem de variação explicada pela correlação aumenta conforme a resolução espacial diminui, em função da menor variação associada à inclusão ou exclusão de árvores ou *gaps* (clareiras). A declividade do solo foi uma variável preditora influente no modelo juntamente com a idade da floresta.

Asner et al. (2012) desenvolveram um modelo universal para estimar densidade de carbono acima do solo em florestas tropicais utilizando informações do *mean canopy profile height* (MCH) obtido de pontos LiDAR do sistema CAO-Alpha. O modelo apresentou $R^2=0.80$ e $RMSE=27,60$ Mg C/ha e necessita apenas de informações da densidade da madeira e área basal referentes à região de estudo para calibrar as informações obtidas com dados LiDAR. Este modelo universal é interessante como base para estimativas globais de biomassa e carbono, dando suporte para as políticas de conservação das florestas.

Zolkos et al. (2013) analisaram a acurácia de estimativas de biomassa por sensoriamento remoto LiDAR, óptico e SAR em mais de 70 trabalhos publicados na literatura. Com uso de dados LiDAR foram analisados aproximadamente 37 estudos de retorno discreto (DRL do inglês *discrete return lidar*) e 16 estudos de *full return* LiDAR (FRL). Para cada estudo os autores reportaram o tipo de sensor, tipo de floresta,

tamanho das parcelas e acurácia dos modelos analisando o R^2 , o erro padrão residual (RSE) e o erro padrão residual normalizado pela biomassa média (RSE%). De acordo com esses autores, sensores capazes de modelar a biomassa com $RSE \leq 20$ Mg/ha são os mais adequados para estudos sobre o armazenamento de carbono. Os resultados indicaram que o desempenho de modelos de estimativa da biomassa baseados em dados LiDAR ou em dados de multi-sensores (MS) foi similar (R^2 médio para DRL=0,76, FRL=0,80, MS=0,78) e mais consistente do que com dados SAR ou ópticos ($R^2=0,50$ e $0,59$, respectivamente). O valor médio RSE dos modelos baseados em dados DRL foi o mais baixo (39,4 Mg/ha), e dos modelos baseados em dados SAR e óptico foram os mais altos (~70,0 Mg/ha) (Figura 2.6). O estudo de Zolkos et al. (2013) demonstra a consistência dos modelos de estimativa de biomassa com uso de dados DRL. Os autores também observaram uma significativa correlação entre o desempenho dos modelos e o tamanho das parcelas sendo que o valor de RSE% diminui com o aumento do tamanho da parcelas (Figura 2.7).

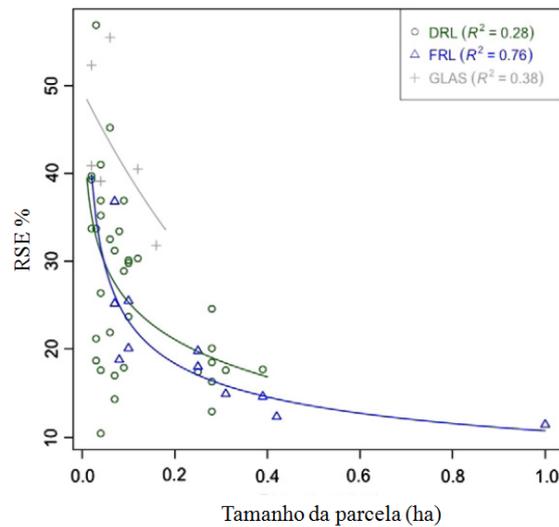
Figura 2.6 - Valores médios de RSE e RSE% categorizados por tipo de sensor.



Resultado dos valores médios de RSE e RSE% categorizados por tipo de sensor, sendo DRL= LiDAR de retorno discreto; FRL= *full return* LiDAR; MS= multi-sensor, SAR= radar, OPT= óptico passivo.

Fonte: Adaptado de Zolkos et al. (2013).

Figura 2.7 - Relação entre os valores de RSE% e tamanho das parcelas.



Variabilidade dos valores de RSE% (RSE padronizado pela AGB média obtida em campo) em relação ao tamanho das parcelas para estudos utilizando dados LiDAR, sendo DRL=retorno discreto LiDAR; FRL= *full return* LiDAR.

Fonte: Adaptado de Zolkos et al. (2013).

Informações sobre a estrutura de dosséis florestais com uso de dados LIDAR podem ser obtidas por meio de outras abordagens como por exemplo, o uso de algoritmos específicos baseados em modelos tridimensionais de altura do dossel (CHM). Alguns métodos específicos são utilizados para a detecção de indivíduos arbóreos (escala da árvore), tais como: análise espacial *wavelet*, filtros de janela variável, filtragem do máximo local, métodos orientados a objetos, associação de feições e segmentação pela transformada *watershed* (FALKOWSKI et al., 2006; LECKIE et al., 2003; POPESCU; WYNNE, 2004; WULDER et al., 2004). Quando aplicados ao CHM, estes métodos possibilitam inferir a localização, diâmetro da copa e altura de indivíduos arbóreos, assim como a mensuração de outros parâmetros como a biomassa e volume entre outros (EDSON; WING, 2011; FALKOWSKI et al., 2008; HYYPPÄ; INKINEN, 1999; HYYPPÄ et al., 2001; LECKIE et al., 2003; POPESCU; WYNNE, 2004; POPESCU, 2007). Um exemplo da aplicação do algoritmo TreeVaW que convolveu um filtro de máximo local e janela variável é demonstrado em Popescu (2007). O algoritmo TreeVaW é baseado na identificação individual de árvores, utilizando filtragem do local máximo com a técnica de janela de tamanho variável (circular ou quadrada). O algoritmo é função da altura (valor *z*) do pixel do CHM e das medições de altura e largura do dossel obtidas *in situ*. A técnica assume que valores altos do laser (valor de *z*)

em relação a uma determinada vizinhança no espaço representam a ponta da copa da árvore. Desta forma Popescu (2007) estimou a biomassa de árvores de *Pínus* por meio do CHM e aplicou o algoritmo TreeVaW para detecção de altura e largura da copa das árvores individualmente. A partir das medidas de altura e largura da copa obtidas com LiDAR e os valores específicos dos parâmetros estruturais das espécies obtidos *in situ* foram estimadas as biomassas das árvores por meio de análise de regressão. Segundo os autores o filtro tem um melhor resultado para árvores com um cume único e definido, como o de coníferas.

2.4.2.2 LiDAR e manguezal

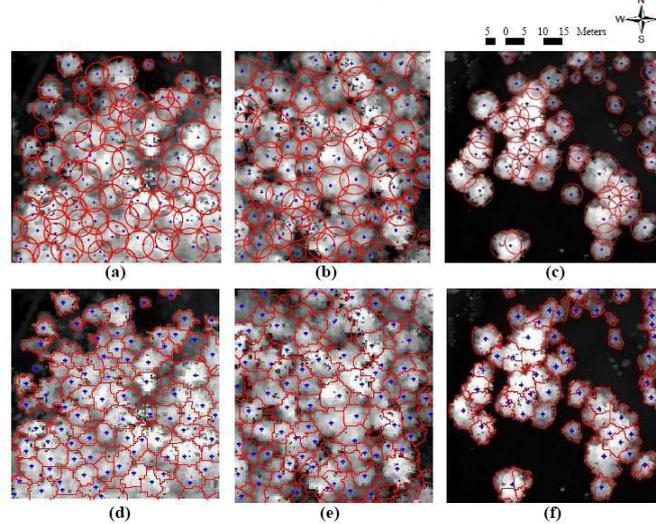
Os manguezais são ecossistemas costeiros alagados diariamente pela influência da variação da maré. Como enfatizado anteriormente, são ecossistemas de extrema importância para a manutenção da vida de muitas espécies terrestres e marinhas. Por isto, seu monitoramento e conservação são considerados de grande importância. Devido às condições ambientais peculiares deste ecossistema, com sedimentos finos, lamosos e áreas alagadas, seu monitoramento e estimativas estruturais ao nível de campo não são triviais se comparados a uma floresta de solo firme. Desta forma, a estimativa de parâmetros estruturais e a biomassa de manguezais por meio de sensoriamento remoto, em especial com uso de dados LiDAR, é extremamente relevante para o monitoramento quantitativo e qualitativo deste ecossistema. A estimativa de parâmetros estruturais e biomassa com uso de dados LiDAR tem sido investigada utilizando distintas abordagens metodológicas, como por exemplo, para a calibração e validação de mapeamentos da altura e biomassa de manguezais (SIMARD et al., 2006;2008), aplicação de algoritmos específicos para localização da copa e estimativa de altura e biomassa de árvores de mangue (GALVINCIO; POPESCU, 2016; WANNASIRI et al., 2013), estimativa de biomassa utilizando dados de sistema LiDAR terrestre (FELICIANO et al., 2014; OLAGOKE et al., 2016), classificação e mapeamento de manguezal com o auxílio de dados LiDAR (ABREU, 2014; ARASATO et al., 2015; CHADWICK, 2011; DAVID; BALLADO, 2015; KAMAL et al., 2015) e detecção de clareiras (ZHANG et al., 2006).

Dados LiDAR já foram utilizados em conjunto com outros tipos de dados de sensoriamento remoto para a estimativa de biomassa de grandes extensões de manguezais na África, Américas do Norte e do Sul (FATOYINBO; SIMARD, 2013; FATOYINBO et al., 2008; SIMARD et al., 2006; 2008). Simard et al., (2008) estimaram a biomassa do manguezal da Ciénaga Grande de Santa Marta na Colômbia com o uso conjunto de dados LiDAR do tipo *waveform* do sensor *Ice, Cloud, and Land Elevation Satellite/Geoscience Laser Altimeter System* (ICESat/GLAS), dados de elevação SRTM e dados de campo. Com uso de dados ICESat/GLAS e de campo foram calibradas as informações do SRTM e produzido um mapa da altura do dossel do manguezal. O sistema *waveform* do ICESat/GLAS pode ser utilizado na caracterização estrutural de florestas, como um manguezal, e o perfil de altura do dossel (*Canopy Height Profile - CHP*) mostra a distribuição relativa da superfície do dossel florestal. Simard et al. (2008) utilizaram o parâmetro da média ponderada pela copa (*crown weighted mean*) obtido com dados LiDAR para calibrar os dados de altitude do SRTM e posteriormente relacionar com a biomassa. Segundo os autores, a altura média do manguezal estudado foi de 7,7 m e a maior parte da biomassa estava concentrada no mangue com altura de aproximadamente 9 m. Simard et al. (2006) utilizaram dados LiDAR do sistema Optech ALTM 1233 para calibrar a altura da floresta de mangue obtida com dados SRTM gerando um mapa de altura do manguezal no Parque Nacional dos Everglades, Florida, EUA. O mapa final com resolução de 30 m apresentou 2 m de erro de altura média (RMSE). Posteriormente, com o auxílio de informações de campo e equações alométricas foi estimada a biomassa para toda a área de manguezal utilizando o mapa de altura como fonte de informações desta variável estrutural. Ainda que estas abordagens utilizando dados LiDAR para calibrar outros tipos de dados de sensores remotos permitam mapear áreas relativamente grandes de manguezais, elas apresentam uma acurácia e resolução reduzidas quando comparadas com estimativas de biomassa obtidas diretamente dos dados LiDAR de retorno discreto.

Wannasiri et al. (2013) investigaram dois métodos para detecção da localização de indivíduos arbóreos, estimativa do diâmetro do dossel e altura da árvore do manguezal dominado pelo gênero *Avicennia*. O método de segmentação *inverse watershed segmentation* (IWS) e o método de filtragem do local máximo e janela variável

(*variable window filtering* -VWF) do algoritmo TreeVaW desenvolvido por Popescu e Wynne (2004) foram aplicados na imagem derivada do CHM. O método IWS determina a localização e altura do dossel pela inversão do CHM, na qual os topos das árvores viram depressões. Desta forma, a segmentação pode ser efetuada para delinear a base do dossel da imagem invertida utilizando estatística zonal para sobrepor ao CHM os vetores delimitados representativos do dossel e atribuir o valor mais alto de pixel para cada copa individualmente. Assim, este valor atribuído e obtido no CHM vem a ser a altura da árvore (z) e a localização do tronco da árvore (EDSON; WING, 2011; WANNASIRI et al., 2013). Os dois métodos, VWF e IWS, identificam a árvore (Figura 2.8) e estimam a altura e a largura do dossel. Os resultados foram avaliados com dados de campo por meio da raiz quadrada do erro quadrático médio (RMSE), estimativa dos erros de omissão, de comissão e índice $kappa$. Ambos os métodos utilizados por Wannasiri et al. (2013), VWF e IWS, apresentaram erros de comissão na detecção de árvores individualmente. Quanto à posição da árvore (em metros) observaram-se erros devido à localização em campo ser tomada no tronco, enquanto que no processamento digital a localização se faz a partir do ponto mais alto (valor z). Quanto à extração da medida do diâmetro do dossel e altura da árvore, os melhores resultados foram obtidos com o modelo VWF com $R^2=0,75$ e $RMSE=1,65$ m para o diâmetro do dossel e $R^2=0,80$ e $RMSE= 1,42$ m para a altura da árvore. O método IWS apresentou resultado inferior com $R^2=0,71$ e $RMSE=1,87$ m para o diâmetro do dossel $R^2=0,77$ e $RMSE=1,65$ m para a altura da árvore. Em geral, os erros tendem a aumentar para locais com dosséis mais densos, sobrepostos e com galhos inclinados, subestimando a altura. O modelo VWF apresentou melhor eficiência para estimar parâmetros estruturais em florestas de mangue e este desempenho pode ser relacionado com os dados de entrada no modelo, que incluem medições *in situ* das espécies específicas existentes na área de estudo.

Figura 2.8 - Extração de copas de árvores por meio dos métodos VWF e IWS.



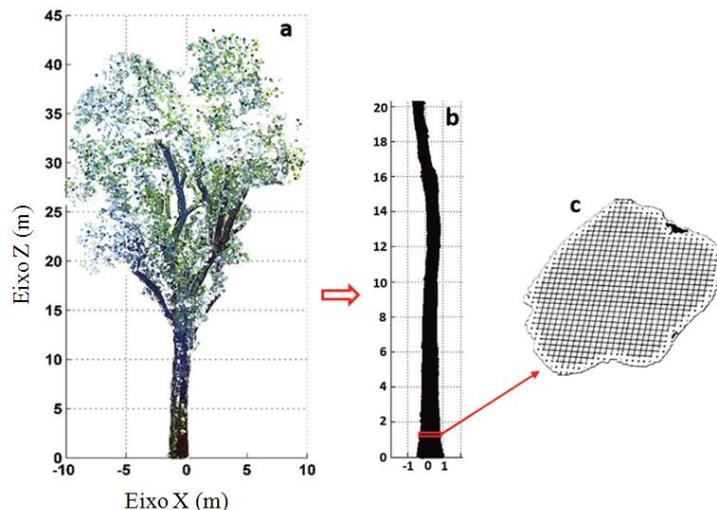
Extração do dossel de árvores de mangue (em vermelho) por meio dos métodos *variable window filtering* (VWF) (a), (b), (c) e *inverse watershed segmentation* (IWS) (d), (e), (f) sobre o modelo de altura do dossel. Os pontos representam a localização baseada em campo.

Fonte: Wannasiri et al. (2013).

O uso de nuvens de dados LiDAR terrestre adquiridos no interior da floresta permite capturar com alta resolução a estrutura tridimensional de indivíduos arbóreos com menor custo de trabalho e tempo (OLAGOKE et al., 2016). Dados LiDAR terrestre do sistema FARO Focus3D X330 foram utilizados por Olagoke et al. (2016) para a estimativa de volume e biomassa de mangue da espécie *A.germinans* na Guiana Francesa. O processamento dos dados consistiu basicamente em unir os múltiplos escaneamentos efetuados, filtrar ou remover a vegetação no entorno e gerar a nuvem de pontos da árvore de interesse. O volume do tronco foi estimado diretamente com a nuvem de pontos a partir da altura e diâmetro da base e topo da árvore. Uma segunda abordagem de processamento, chamada método baseado no pixel (Figura 2.9), consiste em decompor as formas dos troncos em várias secções. Nesta segunda abordagem cada secção é convertida em imagens binárias de duas dimensões obtendo uma projeção do tronco no plano. Desta forma, o volume é obtido como o produto da área da superfície do tronco (plano do tronco) pela espessura do tronco. Ambos os métodos de estimativa do volume foram comparados. O melhor resultado foi obtido com o uso do método baseado no pixel que assim foi utilizado na estimativa de biomassa. O resultado da estimativa de biomassa apresentou $R^2=0,96$ e $RMSE=48,50$ kg (13,5%) demonstrando

ser um bom método de estimativa de biomassa de indivíduo arbóreo diretamente em campo com alta precisão.

Figura 2.9 - Técnica utilizada com um sistema LiDAR terrestre para obtenção do volume da árvore.



Exemplo de técnica utilizada com um sistema LiDAR terrestre com a segmentação e seção do tronco para computação do volume. (a) Típica árvore de mangue relativamente grande. (b) Tronco com diâmetro na altura do peito de 93,5 cm. (c) Projeção achatada típica de uma seção de tronco extraída a 1,3 m de altura.

Fonte: Olagoke et al. (2016).

Feliciano et al. (2014) apresentaram um dos trabalhos pioneiros para estimar o volume e biomassa das árvores de mangue utilizando dados de LiDAR terrestre. Naquele trabalho foi utilizado o sistema LiDAR *Leica-ScanStation-C10 Terrestrial Laser Scanner (TLS)* para estudar o manguezal do Parque Nacional dos Everglades, Florida. O processamento dos dados envolveu basicamente registrar e mesclar a nuvem de pontos obtida sucessivas vezes, e posteriormente modelar as superfícies geométricas dos troncos e raízes aéreas. Em seguida, o volume foi calculado multiplicando-se a área transversal do tronco pela altura para várias secções do tronco. Com os resultados de estimativa de biomassa de indivíduos arbóreos (mínimo de $3,9 \pm 0,4$ kg e máximo de $1.756,5 \pm 189,7$ kg por árvore de mangue) foi possível desenvolver equações alométricas específicas para a área de estudo. Os trabalhos de Feliciano et al. (2014) e Olagoke et al. (2016) sugerem que o uso de LiDAR terrestre constitui uma ferramenta promissora para

estimar a biomassa de indivíduos arbóreos em campo de forma alternativa às amostragens destrutivas.

Abreu (2014) estimou os parâmetros estruturais e a biomassa do manguezal da Ilha dos Guarás em Curuçá, Pará, com uso do modelo digital de vegetação (MDV) representativo da altura do dossel obtido com dados LiDAR aerotransportado *Laser Scanner 60*, e modelos de elevação da superfície obtidos por dados SRTM e ortofotos. As alturas de amostras arbóreas obtidas em campo validaram o LiDAR com RMSE=1,10 m. Foi feito um modelo de calibração entre o MDV do LiDAR e dados de altura de campo obtendo $R^2=0,91$ e RMSE=0,98 cm. O resultado da calibração do SRTM em relação à altura média apresentou $R^2=0,91$ e RMSE=2,2 m. Foi observado que com os dados LiDAR ocorreu superestimativa da altura em áreas onde a vegetação é dominada por mangue jovem e ao contrário para bosques com dossel alto ocorreu uma subestimativa da altura da árvore. Com os dados SRTM ocorreu subestimativa da altura do dossel para todo tipo de bosque.

Modelos de altura do dossel derivados da subtração do modelo digital de terreno do modelo digital de superfície são utilizados como preditores da altura do dossel florestal. Chadwick (2011) reporta que com uso de pulsos LiDAR emitidos no infravermelho-próximo não foi possível obter valores de elevação do terreno em áreas florestadas com solos alagados devido à absorção de parte dos pulsos pela água. Isto é particularmente relevante para o caso dos manguezais, que apresentam características peculiares como os solos alagados e raízes escoras ou rizóforos. A reflexão dos pulsos proveniente das raízes aéreas pode ser também erroneamente classificada como proveniente do solo e assim, superestimar valores do modelo digital de terreno. Desta forma, os modelos de altura do dossel em ambientes com presença de *Rhizophoras* podem ser muitas vezes subestimados. A utilização de dados LiDAR de retorno discreto para a estimativa de biomassa por meio da abordagem metodológica da distribuição da altura dos pontos e métricas estatísticas é ainda pouco utilizada para estudos de manguezais, diferentemente do que ocorre em outros tipos de florestas (HANSEN et al., 2015; NÆSSET; GOBAKKEN, 2008; NÆSSET, 2002; VINCENT et al., 2012; ZOLKOS et al., 2013). Apesar da menor largura de faixa de imageamento e maior custo em relação a outros sistemas sensores como por exemplo de imagens ópticas, os dados LiDAR podem ser

úteis para mapeamento da biomassa e parâmetros estruturais, calibração da altura de bosques de mangue, estimativa da altura do dossel florestal e estimativas de biomassa aérea com melhor precisão (ZOLKOS et al., 2013).

2.5 Modelos de regressão e métodos de análise de incertezas

Métodos de regressão multivariada são normalmente utilizados em estudos de ciências naturais. Em estudos florestais por sensoriamento remoto, os métodos de regressão são utilizados para estimar e modelar parâmetros biofísicos florestais. Determinados métodos de regressão têm sido indicados para os casos em que se têm muitas variáveis preditoras e relativamente poucas amostras. Exemplos destes métodos são o *Random Forest* (RF) (BREIMAN, 2001), *Partial Least Squares (PLS) Regression* (MEVIK e WEHRENS, 2007; WOLD et al., 2001) e *Partial Least Squares regression with backward selection of predictors* (AutoPLS) (SCHMIDTLEIN et al., 2012).

Random Forest

Random Forest é um conjunto de técnicas de classificação e regressão baseadas em métodos de árvores de decisão combinando um grande conjunto de árvores de decisão desenvolvido por Breiman (2001). Este autor define o método Random Forest como um classificador consistindo em uma coleção de classificadores estruturados em árvores $\{h(x, \Theta_k), k=1, \dots\}$ onde $\{\Theta_k\}$ são vetores aleatórios independentes e identicamente distribuídos e cada árvore lança um voto único para a classe mais popular da entrada x (BREIMAN, 2001). O método de regressão RF é um método de regressão múltipla não linear, sendo que o preditor assume um valor numérico, em oposição aos rótulos de classes. Desta forma, o método RF pode ser utilizado como um classificador ou como método de análise de regressão. A distinção entre a classificação e a regressão é que para a classificação obtém-se um voto único da classe para cada árvore e finalmente classifica-se utilizando a classe mais votada. No caso da regressão, ajusta-se a árvore de regressão muitas vezes com os conjuntos amostrais de treinamento obtidos aleatoriamente e com reposição (*bootstrap*) e calcula-se a média do resultado. A predição obtida para o ponto x é função do valor médio de predição para cada árvore

(HASTIE et al., 2009). O RF é um método no qual cada árvore é formada selecionando um conjunto aleatório de variáveis e amostras dos dados de calibração. O método de regressão RF apresenta algumas características, como (i) o número de árvores de regressão aumenta baseado na reamostragem aleatória com reposição (*bootstrap*) das observações; (ii) as amostras do conjunto amostral da interação *bootstrap* são aleatoriamente selecionadas com reposição a partir do conjunto de dados de calibração e os outros elementos não incluídos na interação *bootstrap* ($\sim 1/3$) são utilizados como dados *out-of-bag* (OOB) para aquela amostragem; (iii) o número de variáveis preditoras amostradas aleatoriamente como candidatas para cada divisão é de $\sim 1/3$ do total do número de variáveis (x) no caso da regressão e raiz quadrada de (x) na classificação; (iv) a importância de cada preditor é medida calculando-se o aumento do erro de predição quando o dado OOB para cada variável é permutado, enquanto os outros dados não mudam, e este valor da importância da variável é utilizado para "ranquear" os preditores em relação à força de sua relação nas variáveis de resposta.

Outra característica do RF é o uso do método *out-of-bag* (OOB) para a estimativa da acurácia do modelo preditivo, com uso da medida de erro de acordo com o *Mean Square Error* (MSE) e pseudo R^2 . O erro estimado pelo método OOB pode ser comparado com o obtido pelo método de validação cruzada (CV do inglês *cross-validation*) chamado *N-fold cross-validation*, pois são semelhantes (HASTIE et al., 2009). O *K-fold cross-validation* utiliza parte dos dados disponíveis para ajustar o modelo e outra parte para testá-lo. Maiores detalhes do método de validação cruzada são apresentados adiante nesta seção. Para a classificação é obtida a taxa de erro e para a regressão obtém-se o valor MSE.

Maiores informações sobre o método de classificação e regressão Random Forest e o funcionamento do algoritmo podem ser encontradas em Hastie et al. (2009), Breiman (2001), Liaw e Wiener (2002).

PLS e AutoPLS

A Regressão PLS é um método para relacionar duas matrizes X e Y através de um modelo linear multivariado, mas vai além da regressão tradicional na medida em que a

estrutura de X e Y é modelada (WOLD et al., 2001). A Regressão PLS permite analisar um conjunto de dados com alta correlação, ruído e muitas variáveis preditoras. O modelo de regressão PLS é desenvolvido de um conjunto de dados de treinamento com N observações de K X-variáveis denotadas por \mathbf{x}_k ($k=1,\dots,K$) e M Y-variáveis \mathbf{y}_m ($m=1,2,\dots,M$) que formam duas matrizes X e Y de dimensões ($K*N$) e ($N*M$). O modelo de regressão PLS encontra um subconjunto contendo novas variáveis que são estimativas das Variáveis Latentes (LV do inglês *Latent Variables*) ou suas rotações. Estas novas variáveis são chamadas de X-scores e são preditores de Y e também modelam X. Os X-scores são poucos em número e são ortogonais, estimados como uma combinação linear das variáveis originais com o coeficiente de peso. A técnica PLS constrói um conjunto linear de combinações dos dados de entrada para a regressão, mas diferente da regressão em componentes principais (PCR do inglês *principals component regression*) que decompõe os dados originais da matriz X em componentes principais e utiliza os escores desta matriz na regressão, o método PLS decompõe também os dados da matriz Y além da matriz X. No método PCR a aproximação da matriz X é efetuada pela primeira principal componente obtida com a decomposição do valor singular (*singular value decomposition* - SDV). Para a regressão PLS as componentes chamadas Variáveis Latentes são obtidas iterativamente, começando com o SVD e depois incluindo informações sobre a variação de X e Y e a correlação entre estas (MEVIK e WEHRENS, 2007).

A partir do método PLS, Schmidtlein et al. (2012) desenvolveram o método AutoPLS, no qual foi introduzido o método *backward selection of bands*, que foi baseado na importância da variável na projeção, significância para *jackknifing* ou remoção das bandas correlacionadas, iniciando no máximo local de coeficientes de regressão ponderado, removendo bandas correlacionadas.

O método PLS e AutoPLS utilizam o método de validação *cross-validation* e *root mean squared error of prediction* (RMSEP) e coeficiente de determinação R^2 para avaliar a acurácia do modelo. Detalhes sobre os cálculos e algoritmo PLS e AutoPLS podem ser encontrados em Mevik e Wehrens (2007), Wold et al. (2001), Hastie et al. (2009) Schmidtlein et al. (2012).

Ao gerar diferentes modelos de regressão, torna-se necessário analisar a acurácia destes na escolha do modelo mais apropriado. Desta forma, serão destacados resumidamente alguns métodos para escolha dos modelos descritos acima (RF, PLS e AutoPLS).

O coeficiente de múltipla determinação denominado R^2 mensura a fração da variação total de Y explicada pela regressão. O R^2 pode ser interpretado como a redução proporcional da variação total associada com o uso da variável preditora X. Desta forma, um alto R^2 ocorre quanto mais a variação total de Y é reduzida pela introdução de variáveis preditoras X. O R^2 pode variar de $0 \leq R^2 \leq 1$, assumindo o valor 1 quando todas as observações Y se ajustam diretamente na superfície de regressão. É definido segundo a Equação 2.1 (NETER et al., 1996):

$$R^2 = \frac{SQReg}{SQTO} = 1 - \frac{SQE}{SQTO} \quad \text{Equação 2.1}$$

Sendo SQE=soma dos quadrados dos resíduos, SQReg=soma dos quadrados da regressão; SQTO=soma dos quadrados total

Para avaliar o desempenho dos modelos de regressão pode-se utilizar como métrica estatística padrão o *mean squared error of prediction* (MSEP) ou sua raiz quadrada, o *root mean square error* (RMSE). O *mean squared error of estimation*, que utiliza o conjunto de dados de treinamento L como o conjunto de teste, também chamado de *mean square error of calibration*, pode ser definido segundo a Equação 2.2 encontrada em Mevik e Cederkvist (2004):

$$MSEP = \frac{1}{n_L} \sum_{i=1}^{n_L} (f_L(x_i) - y_i)^2 \quad \text{Equação 2.2}$$

Assumindo um conjunto de dados de treinamento $L=\{(x_i, y_i)\}$ de n observações e o preditor f_L treinado no conjunto de dados de treinamento L.

O MSE é um estimador da variância de um modelo de regressão, enquanto sua raiz quadrada o RMSE é uma métrica para estimar o desvio padrão do modelo (NETER et al., 1996).

Ao gerar um modelo preditivo, se faz necessário validá-lo antes de ser largamente utilizado na previsão de novos eventos. A melhor validação de um modelo é quando este estima precisamente valores de resposta (Y) a partir de novos valores de preditores X. Porém, um conjunto de dados para validação que seja representativo e independente é raro. Na ausência deste conjunto de dados para validação, um método comumente utilizado é o método de validação cruzada (CV) (HASTIE et al., 2009). O método de validação cruzada é amplamente utilizado para estimar erros preditivos utilizando um conjunto de dados para validação. No caso do *K-fold Cross-Validation* utiliza-se parte dos dados avaliados para ajustar o modelo e outra parte dos dados para testar o modelo. Dividindo o conjunto de dados de treinamento L aleatoriamente em K segmentos L_k ($k=1, \dots, k$) de mesmo tamanho e assumindo que f_k sejam os preditores de treinamento (não sendo as observações em L_k), a estimativa do erro obtido pela *k-fold cross-validation* pode ser expressa segundo a Equação 2.3 encontrada em Mevik e Cederkvist (2004):

$$MSEP_{CV.K} = \frac{1}{n_L} \sum_{k=1}^K \sum_{i \in L_k} (f_k(x_i) - y_i)^2 \quad \text{Equação 2.3}$$

Sendo: L_k o conjunto de dados de treinamento L em K segmentos, n é o número de observações.

O método *Leave-one-out cross-validation* (CV-LOO) é o *k-fold cross-validation* com k igual ao número de observações n , sendo $k(i)=i$ e para a *ith* (enésima) observação o ajuste é computado utilizando todos os dados exceto o *ith*.

Estimativas estatísticas da AGB e sua média para uma população são inferidas por amostras. As incertezas na escala da paisagem podem ser estimadas por métodos de inferência da AGB total da população e sua variância. Algumas técnicas são utilizadas para estimar a variância como *jackknife*, *bootstrap*, *balanced half-samples*. Métodos

específicos para avaliação das incertezas dos modelos de estimativa podem ser baseados no modelo estatístico, como o método *model-based* ou baseados no desenho amostral empregado para adquirir os dados amostrais, como método *design-based* (GREGOIRE et al., 2016). Segundo Gregoire et al. (2016), o modo de inferência afeta as propriedades estatísticas dos estimadores. A inferência *design-based* é apresentada em Särndal et al. (1992) e a *model-based* pode ser encontrada em Chambers e Clark (2012), ambas podem ser encontradas em Gregoire et al. (2016).

O método *model-based* de inferência no contexto da amostragem da AGB considera as observações de campo como sendo realizações de variáveis aleatórias com a média e variância estipuladas pelo modelo. O modelo provê a base para determinar o estimador B e seu estimador de variância (GREGOIRE et al., 2016). O método de inferência *model-based* não depende de uma amostra probabilística. Por isto pode ser utilizado com dados adquiridos de variados desenhos de amostragens, bem como, para áreas externas à área de interesse (GREGOIRE et al., 2016).

A amostragem baseada na probabilidade é essencial para a inferência *design-based* (GREGOIRE et al., 2016). As propriedades estatísticas de uma estimativa, como média e variância, por exemplo, são avaliadas pela média de todas as possíveis amostras do desenho amostral (SÄRNDAL et al., 1978). Nos trabalhos de Gregoire et al. (2016) e Särndal et al. (1992) a equação do estimador geral de regressão pelo método de inferência *design-based* para estimar a biomassa total \hat{B} é apresentada na Equação 2.4 e o estimador *design-based* da variância $\hat{V}(\hat{B})$ é dado pela Equação 2.5.

$$\hat{B} = \sum_{k=1}^N \hat{y}_k + \frac{N}{n} \sum_{k \in S} e_k \quad \text{Equação 2.4}$$

$$\hat{V}(\hat{B}) = N^2 \left(\frac{1}{n} - \frac{1}{N} \right) \sum \frac{(y_k - \hat{y}_k)^2}{n-1} \quad \text{Equação 2.5}$$

Sendo N o número de células (pixels) da região de estudo Y_k ($k= 1, \dots, N$), \hat{B} denota a AGB total estimada, $e_k = y_k - \hat{y}_k$ e \hat{y}_k estimado de y_k proveniente do modelo ajustado e n número amostral (parcelas de campo).

3 ÁREA DE ESTUDO

3.1 Baía de Guanabara

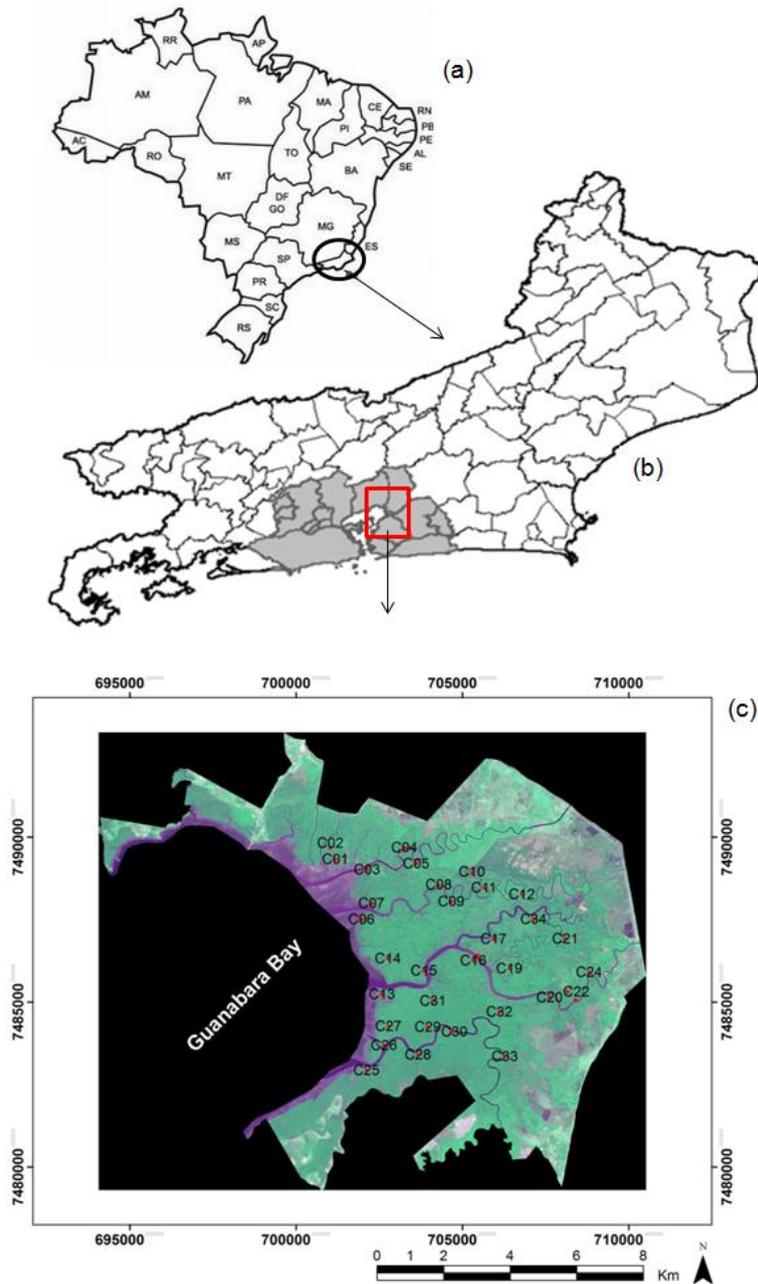
A região da Baía de Guanabara (Figura 3.1) localiza-se no segmento VII segundo a classificação de Schaeffer-Novelli et al. (1990), o qual é caracterizado pela planície costeira de formação quaternária entre a Serra do Mar e o oceano. O clima típico é tropical Atlântico quente e úmido, ou Aw segundo a classificação de Köppen, com estação chuvosa no verão e invernos mais secos. A APA de Guapimirim apresenta pluviosidade mínima anual de 1.155 mm, pluviosidade máxima anual de 2.396 mm e temperatura média anual de 23°C (PELLENS et al., 2001). Para o período de 1961-2009, junho é o mês mais seco com 109 mm e o mais úmido é dezembro com 249 mm (INMET, 2016). A região apresenta pouca variação de maré com amplitude média menor que 2 metros.

A região costeira no entorno da Baía de Guanabara, no estado do Rio de Janeiro, era ocupada por restingas, lagoas e manguezais no início da colonização (PIRES, 2010). Ao longo das décadas, com a crescente urbanização dos municípios litorâneos, muitos ecossistemas costeiros foram sendo fortemente impactados com o aumento da poluição, aterros e desflorestamentos. A Baía de Guanabara, devido à sua posição estratégica, possibilitou a fundação e o desenvolvimento da cidade do Rio de Janeiro e de outros municípios a sua volta, compreendendo um dos maiores centros industriais do Brasil com intensa urbanização. Atualmente, a microrregião do Rio de Janeiro possui uma população de 11.868.032 habitantes, de acordo com o Censo 2015 (IBGE, 2015). Os níveis de poluição das águas da Baía de Guanabara são decorrentes de fontes poluidoras líquidas e sólidas, tais como resíduos industriais, terminais marítimos de produtos oleosos, portos, estaleiros, refinarias de petróleo, além da poluição dos rios decorrente da intensa urbanização das cidades da região metropolitana do Estado do Rio de Janeiro (INEA, 2014). Pires (2010) demonstra a acentuada redução de áreas cobertas por manguezais ao longo da história de ocupação do litoral oriental da Baía de Guanabara. Segundo Soares et al. (2003; 2011) a principal característica dos manguezais da Baía de Guanabara é o acentuado nível de degradação da cobertura vegetal e a forte pressão

urbana em seu entorno. Apesar do processo histórico de destruição, os manguezais ainda desempenham suas funções básicas e essenciais à vida de muitas espécies e ao sustento de muitas comunidades tradicionais. Em 1984, foi criada a Área de Proteção Ambiental de Guapimirim (Decreto 90225/84) que tem como principal objetivo proteger os remanescentes de manguezais no recôncavo da Baía de Guanabara e assegurar a permanência e sobrevivência das comunidades locais (ICMBIO, 2016). Na mesma região, o Decreto Federal s/nº 15/02/2006 criou a Estação Ecológica (ESEC) da Guanabara, com área de 1.935 ha. Seu plano de manejo aprovado pelo Instituto Chico Mendes de Conservação da Biodiversidade (ICMBio) estabelece o zoneamento, as normas de uso da área e o manejo dos recursos naturais. A APA de Guapimirim engloba parte dos municípios que bordeiam o leste da Baía de Guanabara, tais como: Magé, Guapimirim, Itaboraí e São Gonçalo. Estes 4 municípios apresentaram um aumento populacional de 236.032 habitantes em 15 anos, estimados com 1.322.380 habitantes segundo o Censo 2000 (IBGE, 2000), para 1.558.412 habitantes de acordo com o Censo 2010 (IBGE, 2010). A região onde está inserida a APA de Guapimirim se caracteriza pela pressão urbana e demográfica com aglomerados populacionais periféricos sem infraestrutura adequada, falta de tratamento de esgoto, presença de estradas federais, transporte da população, de carga, material químico industrial, presença de indústrias metalúrgicas, construção civil, bem como indústrias baseadas na exploração de recursos naturais, como pescado e caranguejo. A APA também é influenciada pela água proveniente da Baía de Guanabara e dos rios que desaguam trazendo lixo, esgoto e espécies exóticas de peixes (PELLENS, 2001).

A existência da APA de Guapimirim tem contribuído eficazmente para a conservação dos manguezais daquela área. Segundo Cavalcanti et al. (2009) bosques de mangue inseridos na APA de Guapimirim apresentaram maior desenvolvimento estrutural do que bosques de mangue da região adjacente fora da área de conservação da APA, demonstrando a eficácia de políticas públicas que visam a proteção e conservação deste ecossistema. O manguezal estudado no presente trabalho está inserido na APA de Guapimirim (Figura 3.1).

Figura 3.1 - Localização do manguezal de estudo.



Localização do manguezal de estudo. a) Brasil; b) Estado do Rio de Janeiro com destaque para a micro-região do Rio de Janeiro, e em vermelho indica a localização da APA de Guapimirim a NE da Baía de Guanabara; c) APA de Guapimirim, imagem WorldView-2 R5G6B3 de 01/Octubro/2012 com a localização das 34 parcelas de campo (ver texto).

3.2 Características gerais do manguezal da APA de Guapimirim

Os remanescentes florestais dos manguezais da Baía de Guanabara tem sido alvo de estudos para a caracterização estrutural, estimativa da biomassa, dinâmica do ecossistema, monitoramento e mapeamento da vegetação (ARASATO et al., 2015; ARAUJO; MACIEL, 1979; CAVALCANTI et al., 2009; PETROBRAS, 2012; PELLENS et al., 2001; PIRES, 1986; SOARES et al., 2003).

A floresta de mangue da região da Baía de Guanabara apresenta alta diversidade estrutural como reflexo da ação humana direta ou indireta, apresentando diferentes graus de degradação e estágios de regeneração (SOARES et al., 2003). Na região são encontradas três espécies vegetais típicas de mangue: *Rhizophora mangle* L. (Rhizophoraceae), *Avicennia schaueriana* Stapf. & Leechman (Acanthaceae, Avicenniaceae), *Laguncularia racemosa* (L.) Gaertn. F. (Combretaceae). A delimitação de feições fitofisionômicas e a classificação do manguezal são baseadas em suas características estruturais e estado de preservação. Soares et al. (2003) analisaram o manguezal do entorno de toda a Baía de Guanabara e identificaram uma variabilidade estrutural dos bosques da região. Por meio da análise estrutural dos bosques de mangue foi averiguada a densidade de troncos, altura média, DAP, contribuição das espécies e percentual de indivíduos mortos. As características dos manguezais foram descritas relacionando-as com o nível de conservação e impactos de tensores, denominados como distúrbios. Ainda segundo Soares et al. (2003), a sobreposição das seguintes características permitiram a ocorrência da diversidade estrutural observada no manguezal da região, a saber: a natureza variável dos distúrbios, características dos distúrbios, variabilidade espacial na ação dos distúrbios, variabilidade temporal na ação dos distúrbios, variação na frequência de ocorrência dos distúrbios e capacidade do sistema em recuperar-se após um distúrbio. As características estruturais e de composição de espécies de um bosque podem indicar ocorrências de distúrbios, como por exemplo, no caso de um bosque apresentar estrutura homogênea monoespecífica de *L. racemosa* é um indício de bosque secundário. Esta espécie caracteriza-se como espécie pioneira em um processo de sucessão secundária, sendo típica de bosques degradados em processo de regeneração (SOARES et al., 2003). De acordo com o

relatório de monitoramento da APA de Guapimirim (PETROBRAS, 2012), o manguezal inserido na APA e ESEC apresenta um padrão de dominância de *R. mangle* principalmente no seu interior, em comparação com a borda da APA/ESEC que apresenta dominância da *L. racemosa*. Desta forma, este padrão de domínio da *R. mangle* reflete a melhor conservação dos remanescentes de manguezais no seu interior em comparação com outros manguezais no entorno da Baía de Guanabara. Cavalcanti et al. (2009) demonstraram que o desenvolvimento estrutural das florestas é significativamente superior no interior da APA de Guapimirim. Outro indicador de preservação dos bosques dentro da APA pode ser obtido da análise do DAP. De acordo com PETROBRAS (2012), o percentual de troncos mortos é baixo e concentrado nas classes inferiores de DAP, o que indica um processo de desbaste natural associado ao amadurecimento da floresta. Soares et al. (2003) identificaram padrões estruturais e da dinâmica das comunidades vegetais baseados nas análises dos parâmetros estruturais, tais como: (a) curva do tipo "J" invertido, (b) distribuição normal, (c) mortalidade massiva, (d) sobreposição de eventos, (e) recolonização/clareiras, (f) falhas na recolonização, (g) clareiras e (h) invasão por *Acrostichum aureum*. No padrão "J" invertido apresenta distribuição exponencial negativa, com padrão típico de mortalidade natural associada ao amadurecimento do bosque, indicado pela mortalidade de indivíduos com classe inferior de DAP, queda da densidade de indivíduos e aumento da área basal de árvores mais desenvolvidas. O bosque com o padrão normal é dominado por indivíduos de porte intermediário, relativamente mais homogêneo com baixo desvio padrão da altura. Nestes casos a contribuição de troncos mortos se concentra nas classes inferiores e intermediárias de DAP. O padrão mortalidade massiva apresenta alta contribuição de indivíduos mortos em todas as classes de DAP, quando causada por poluição ou derramamento de hidrocarbonetos, por exemplo. O padrão sobreposição de eventos sugere a ocorrência de algum distúrbio que tenha causado a mortalidade de todas as classes de DAP seguida de um processo de regeneração que pode ser representado pela maior contribuição de indivíduos vivos nas classes inferiores de DAP. O bosque com padrão recolonização/clareira se caracteriza por ter sido submetido a distúrbios, quando ocorre a manutenção de grandes árvores vivas, com ocorrência de clareiras que posteriormente passaram a ser recolonizadas por espécies de mangue. O padrão falha na recolonização se caracteriza pelo alto recrutamento de novos indivíduos,

representado por grande contribuição de indivíduos nas classes inferiores de DAP. Porém, esses indivíduos não se desenvolvem causando uma baixa contribuição de indivíduos nas classes superiores de DAP. Os padrões clareira e invasão por *Acrostichum aureum* são reflexos da degradação dos manguezais da região, bastante comum na Baía de Guanabara (SOARES et al., 2003). No estudo do manguezal da APA (PETROBRAS, 2012) foi observado que os bosques de mangue com maior desenvolvimento estrutural se localizam em áreas de menor salinidade, e os com desenvolvimento estrutural mais baixo se localizavam em áreas caracterizada com alta salinidade, ocorrendo uma relação inversa entre salinidade e desenvolvimento estrutural. A presença de espécies invasoras (ex. *Acrostichum aureum*) ocorrem principalmente em áreas com menor salinidade e também ocorrem em áreas com menor influência da maré.

Uma caracterização do manguezal inserido na APA de Guapimirim foi pioneiramente apresentada por Araujo e Maciel (1979) e por Pires (1986). O manguezal desta região foi enquadrado por Araujo e Maciel (1979) no tipo ribeirinho (*riverine*) segundo a classificação de Lugo et al. (1974). A floresta de manguezal do tipo ribeirinho ocorre ao longo dos rios e drenagens e é banhada por marés diárias (LUGO et al., 1974). Ainda de acordo com os mesmos autores, algumas vezes a borda da vegetação próxima a água está ocupada pela franja que se caracteriza por raízes escoras densas e bem desenvolvidas. Araujo e Maciel (1979) caracterizaram a distribuição das comunidades vegetais do manguezal da região de estudo em distintas regiões a partir de uma seção perpendicular à margem dos rios. A primeira zona apresentou plantas emergentes como a *Spartina alterniflora*, eretas ou flutuantes que podem ficar submersas na preamar. A segunda zona localizou-se em terrenos mais elevados, constantemente atingidos pela preamar, possuindo as espécies de mangue e ervas. A terceira zona ocorreu distante das margens dos rios, atingidas pelas preamares máximas e possuindo árvores como a *Avicennia schaueriana*. Para a caracterização das comunidades vegetais dos trechos em relação à extensão dos rios, Araujo e Maciel (1979) descreveram 3 trechos descritos a seguir. O primeiro inicia-se na desembocadura dos rios onde abundam as três espécies arbóreas de mangue além da espécie associada *Spartina*. Este trecho acaba quando as condições ambientais limitam a ocorrência de *Spartina*. O segundo trecho intermediário

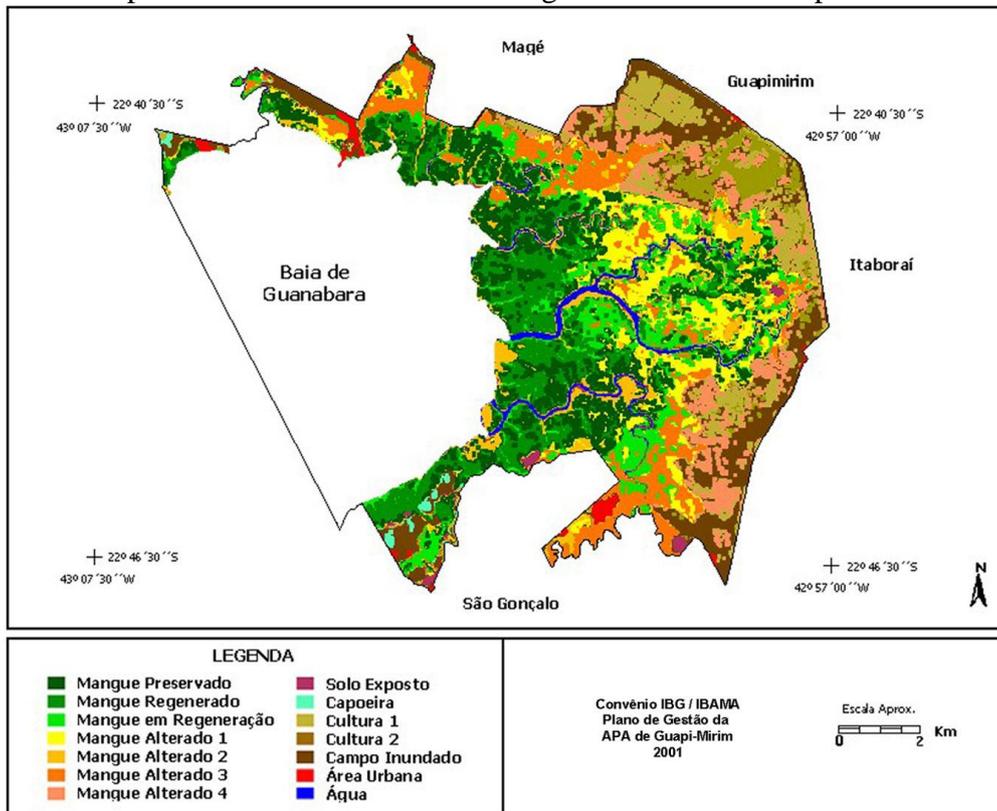
apresenta vegetação dos dois outros trechos, mas com ausência de *Spartina* e com grande acréscimo de espécies como o *Hibiscus* e *Acrostichum*. No último trecho já alcançando a rodovia, a vegetação está degradada e alterada antropicamente, ocorrendo ocasionalmente as três espécies de mangue e com predomínio de gramíneas e plantas aquáticas emergentes.

A aplicação de diferentes técnicas de sensoriamento remoto para o estudo e análise do ecossistema manguezal é de grande valia e pode contribuir para a conservação e monitoramento deste ecossistema (CUNHA-LIGNON et al., 2011; DAHDOUH-GUEBAS, 2002). O manguezal da área de estudo exhibe variabilidade em sua estrutura e composição florística, o que pode ser relacionado aos fatores antrópicos, salinidade das águas e características estruturais. Pires (1986) com uso de imagens datadas do ano de 1976 obtidas do sensor *MultiSpectral Scanner* (MSS) a bordo do satélite Landsat 1, fotografias aéreas pancromáticas e fotografias coloridas infravermelhas com maior resolução e detalhamento, e trabalho *in situ* classificou a região florestada da APA de Guapimirim em 4 classes e 6 subclasses, a saber: "mangue preservado", "mangue em regeneração", "mangue desmatado" e "solo exposto". A classe "mangue preservado" foi subdividida em duas subclasses sendo a subclasse 1 com domínio das três espécies arbóreas de mangue principais, ocupando grandes áreas principalmente próximas a baía. A subclasse 2 conta com a presença de *Avicennia schaueriana*, disseminada no manguezal como manchas isoladas, dossel mais alto do que a vegetação ao seu entorno e com solo exposto. Na classe "mangue em regeneração" observou-se a presença de espécies invasoras entre as espécies de mangue e gramíneas, apresentando dossel mais baixo que as classes anteriores e vegetação arbustiva. A classe "mangue desmatado" foi subdividida em duas subclasses sendo a subclasse 1 caracterizada por mangue desmatado ocupado por gramíneas e tufo isolados de vegetação arbustiva aparecendo em áreas mais próximas a terra firme. A subclasse 2 foi caracterizada por mangue desmatado e áreas de solo exposto periodicamente inundado com a presença de tufo de vegetação isolada. A classe "solo exposto" desprovida de vegetação correspondeu aos apicuns e áreas de desmatamento (PIRES, 1986).

Segundo o Plano de Manejo da APA de Guapimirim (PELLENS, 2001), a variação da vegetação de mangue presente ocorre em relação ao grau de conservação e regeneração

com padrão heterogêneo dominado pelas três espécies. As classes de cobertura vegetal da APA de Guapimirim mapeadas e descritas em Pellens et al. (2001) foram baseadas na classificação da imagem do sensor *Thematic Mapper* do satélite Landsat 7 do ano de 2000 (Figura 3.2) e em trabalhos de campo e informações pré existentes como o trabalho de Pires (1992). As classes mapeadas foram: "mangue preservado", "mangue regenerado", "mangue em regeneração", "mangue alterado 1", "mangue alterado 2", "mangue alterado 3", "mangue residual", "solo exposto" e outras classes como "capoeira", "cultura 1", "cultura 2", "área urbana", "campo inundado" e "água". A classe "mangue preservado" representa feições de mangue com domínio das três espécies arbóreas, *Rizophora mangle*, *Avicennia schaueriana* e *Laguncularia racemosa*, apresentando árvores de 8 a 15 m de altura, DAP de 7,5 a 25 cm e ocupando principalmente regiões da franja e da mesozona. Esta classe apresenta dossel irregular com alguns bosques ou árvores maiores de *Avicennia*. A classe "mangue regenerado" é caracterizada por feições dominadas pelas três espécies de mangue em áreas anteriormente desmatadas. Os bosques são mais densos e estruturalmente menores com altura média de 5,5 a 7 m e DAP de 5 a 7 cm. A classe "mangue em regeneração" apresenta predomínio de apenas uma ou outra espécie de mangue com bosques estruturalmente menores com altura média de 3 a 3,8 m e DAP de 2,5 a 3 cm. A classe "mangue alterado 1" é caracterizada por áreas de manguezal ocupadas por espécies invasoras apresentando substrato alterado e solo exposto. A classe "mangue alterado 2" é caracterizada por gramíneas, feições arbustivas esparsas, água e solo exposto. A classe "mangue alterado 3" é totalmente ocupada por gramíneas. A classe "mangue residual" é caracterizada por feições de manguezal com domínio de uma ou outra espécie encontradas isoladas devido à atividade de uso agropastoril do solo. A classe "solo exposto" não apresenta cobertura vegetal e é caracterizada por apicuns e áreas desmatadas. Segundo o Plano de Manejo da APA de Guapimirim (PELLENS et al., 2001) a área ocupada por manguezal dentro da APA é de 61,8 km² sendo 16,72 km² de mangue preservado.

Figura 3.2- Mapa do uso do solo e cobertura vegetal da APA de Guapimirim em 2000.

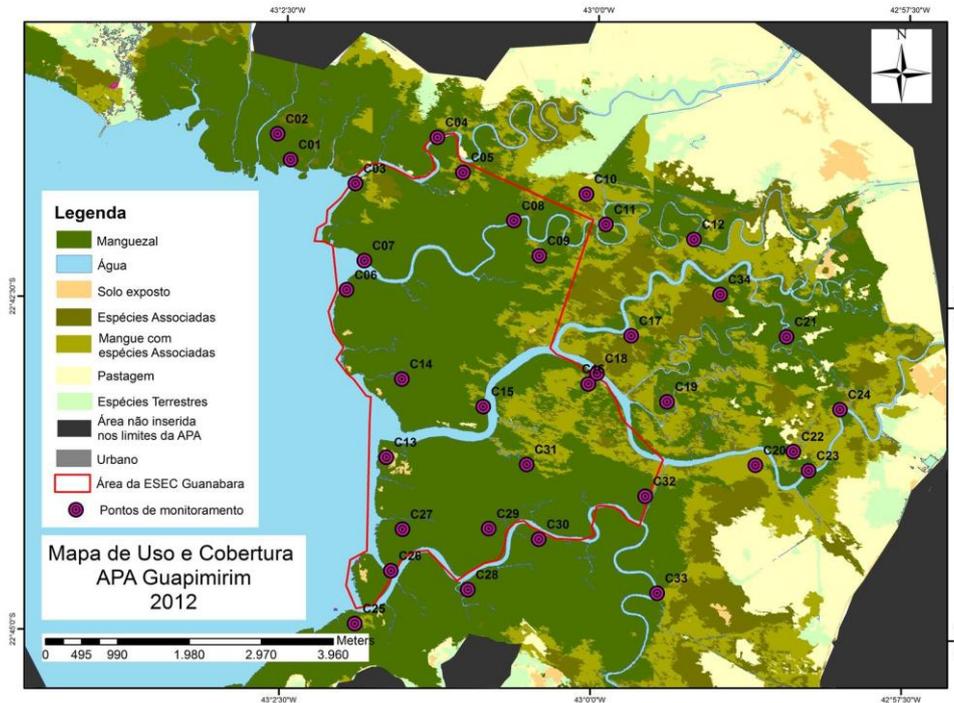


Mapa do uso do solo e cobertura vegetal da APA de Guapimirim (com base na imagem Landsat de 2000). Descrição das classes está descrita no texto.

Fonte: Pellens (2001).

Trabalhos mais recentes de caracterização e mapeamento do manguezal da APA de Guapimirim foram apresentados por Arasato et al. (2015) e PETROBRAS (2012). O mapeamento das principais fisionomias da APA e ESEC foi realizado no âmbito do programa de monitoramento de manguezais (PETROBRAS, 2012) (Figura 3.3) com uso de imagem de alta resolução GeoEye de 2011 e 2012. A área da APA de Guapimirim foi classificada em: "manguezal", "mangue com espécies associadas", "espécies associadas", "pastagem", "espécie terrestre", "solo exposto", "água" e "urbano". Segundo os autores, a classe "mangue com espécies associadas" e outras classes não-mangue são encontradas principalmente mais a montante dos rios em função dos gradientes de salinidade, ou seja, com menor salinidade quanto mais próximo da montante dos rios. Este padrão pode ser observado nos mapeamentos de Arasato et al. (2015) e Pellens et al. (2001).

Figura 3.3 - Mapa das fisionomias da APA de Guapimirim e ESEC Guanabara em 2012.

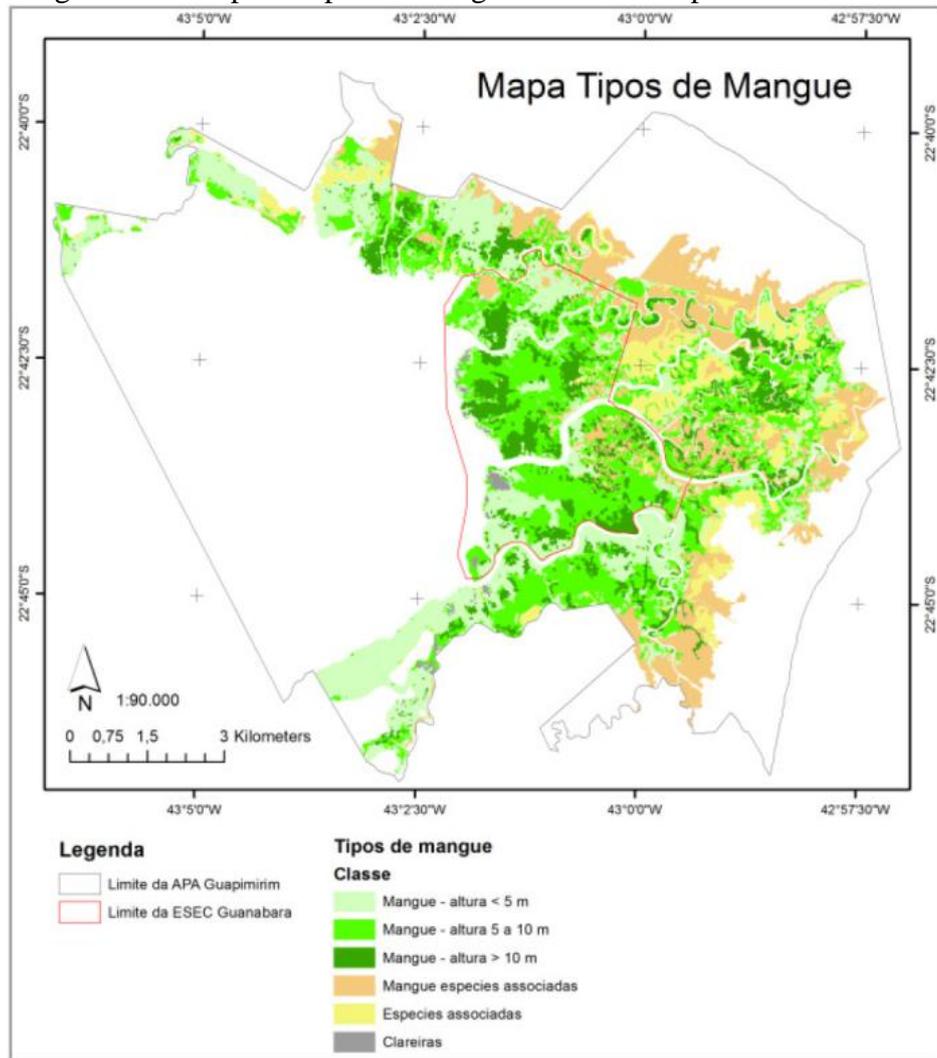


Mapeamento das fisionomias da APA de Guapimirim e ESEC Guanabara em 2012. As classes estão descritas no texto.

Fonte: PETROBRAS (2012).

O mapa dos tipos de cobertura de mangue da APA de Guapimirim foi realizado recentemente por Arasato et al. (2015) utilizando técnicas de sensoriamento remoto. Naquele trabalho os autores utilizaram dados LiDAR adquiridos em dezembro de 2012 e uma imagem óptica WorldView-2 adquirida em 01/10/2012. Foi utilizada uma classificação orientada a objeto para a caracterização quantitativa e qualitativa das áreas de manguezal, bem como, detecção e mapeamento de espécies. O resultado do mapeamento de tipos de mangue (Figura 3.4)) discriminou as seguintes classes: "mangue", "mangue com espécie associada", "espécie associada" e "clareiras". A classe mangue foi subdividida de acordo com a altura dos bosques de mangue utilizando o valor médio da altura da vegetação obtido com um modelo digital de altura derivado dos dados LiDAR.

Figura 3.4 - Mapa de tipos de mangue na APA Guapimirim em 2012.



Mapeamento de tipos de mangue na APA Guapimirim em 2012. As classes estão descritas no texto.

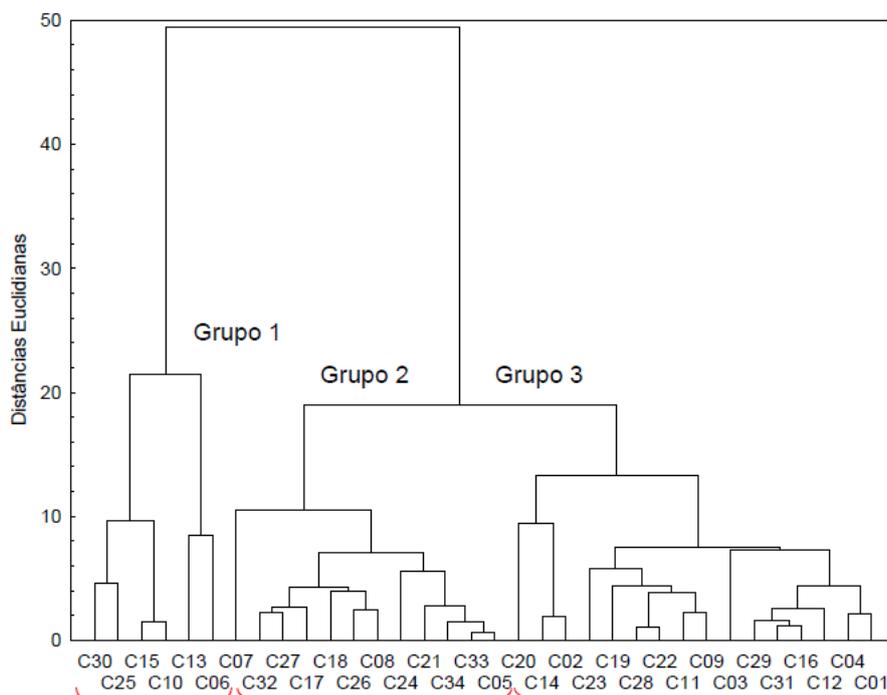
Fonte: Arasato et al. (2015).

4 MATERIAL E MÉTODOS

4.1 Dados de campo

Os dados de estrutura dos bosques de mangue da APA de Guapimirim utilizados no presente estudo foram obtidos em colaboração com o "Programa de Caracterização e Monitoramento dos Manguezais da APA de Guapimirim e Estação Ecológica (ESEC) Guanabara", em atendimento à licença de instalação do Complexo Petroquímico do Rio de Janeiro (COMPERJ) (PETROBRAS, 2012). As informações estruturais de bosques de mangue foram obtidas em 34 parcelas de campo localizadas em diferentes estações amostrais (Figura 3.1). Segundo informações do relatório PETROBRÁS (2012), das 34 parcelas de campo 17 são dominadas pela espécie *Rhizophora mangle*, 9 parcelas são dominadas pela espécie *Laguncularia racemosa*, 3 parcelas são dominadas pela espécie *Avicenia shaueriana* com presença da *Laguncularia*, 2 parcelas contam com dominância de indivíduos mortos de *Avicennia* e 3 parcelas com presença das 3 espécies arbóreas com dominância proporcional. A Figura 4.1 retirada do relatório PETROBRAS (2012) mostra a análise de agrupamento das 34 parcelas de estudo com os parâmetros que definem o grau de desenvolvimento estrutural das florestas, quais sejam: DAP médio, altura média e contribuição em área basal viva de troncos com DAP > 10 cm. Os resultados do agrupamento indicam 3 grupos de desenvolvimento estrutural sendo: grupo 1 com baixo desenvolvimento estrutural (altura média de 4,43 a 7,92 m; DAP médio de 4,71 a 8,41 cm; contribuição em área basal viva de troncos com DAP maior que 10 cm (%AB_{v>10}) de 4 a 34%); grupo 2 com desenvolvimento estrutural intermediário (altura média: 5,80 a 11,28 m; DAP médio: 7,81 a 11,12 cm; %AB_{v>10}: 51 a 69%); o grupo 3 com alto desenvolvimento estrutural (altura média: 3,88 a 14,32 m; DAP médio: 6,71 a 16,62 cm; %AB_{v>10}: 73 a 94%) (PETROBRAS, 2012).

Figura 4.1 - Análise de agrupamento dos parâmetros estruturais.



Análise de agrupamento considerando DAP médio, altura média e a contribuição em área basal viva de troncos com DAP maior que 10 cm (%ABv>10) das 34 parcelas de campo.

Fonte: PETROBRAS (2012).

A localização das parcelas de campo foi definida de modo a representar toda a área de manguezal dentro da APA de Guapimirim. Foram distribuídas ao longo dos quatro principais rios existentes na área de estudo: Guapimirim, Guaráí, Caceribu e Guaxindiba. As parcelas cobrem as principais variações de biomassa dos bosques de mangue e excluem as áreas com predomínio de espécie associada (espécies invasoras) e as áreas de não-mangue. Informações adicionais e fotografias referentes a cada uma das 34 parcelas de estudo podem ser encontradas na Tabela A1 do Apêndice A.

Os parâmetros estruturais obtidos em campo para cada indivíduo arbóreo e para cada parcela foram baseados na metodologia de Estrada (2013), Schaeffer-Novelli e Cintrón-Molero (1986) e Soares et al. (2005). A altura da árvore e diâmetro à altura do peito foram considerados para cada árvore; para cada parcela foram calculados o DAP médio, altura média, densidade e área basal. O tamanho de cada parcela foi baseado na representatividade das características estruturais de cada bosque de mangue. O tamanho

das parcelas variou de 121 m² a 560 m² dependendo da densidade de indivíduos e da homogeneidade das características estruturais e composição de espécies. O parâmetro DAP de todos os troncos dos indivíduos com altura acima de 1 m foi medido com trena graduada em unidade proporcional ao valor pi (3,14159), permitindo efetuar leituras diretas do diâmetro do tronco. As medidas de altura total das árvores, da base da árvore à extremidade superior da copa, foram obtidas com telêmetro ou com vara telescópica, conforme a altura das árvores, em função dos limites de detecção do telêmetro (de 2 a 30 m). A identificação das espécies e determinação da condição do indivíduo e número de troncos vivos e mortos foram também realizadas. Informações complementares sobre as metodologias empregadas na medição da altura dos indivíduos, altura média das parcelas, DAP dos indivíduos, DAP médio das parcelas, densidade das parcelas e área basal podem ser encontrados em Estrada (2013), Schaeffer-Novelli e Cintrón-Molero (1986) e Soares et al. (2005).

Os dados dos parâmetros estruturais das parcelas foram obtidos em campanhas de campo realizadas em 2011 e 2012 e reportadas no Relatório Final do Programa de Caracterização e Monitoramento Ambiental dos Manguezais da Área de Proteção Ambiental de Guapimirim e da Estação Ecológica da Baía de Guanabara - Fase I, Pré-Operação (PETROBRÁS, 2012). Estes dados consistem em: DAP médio (cm), altura média (m) e desvio padrão, densidade (troncos vivos/ha), área basal (m²/ha) e contribuição da área basal por espécie.

Os valores de biomassa de mangue para cada parcela foram calculados em colaboração com o Dr. Mario Luiz Gomes Soares, coordenador do Núcleo de Estudos em Manguezais da Faculdade de Oceanografia da Universidade do Estado do Rio de Janeiro. Para o cálculo da biomassa foram utilizadas as equações alométricas de estimativa de biomassa de mangue específicas para cada espécie e específicas para indivíduos vivos e mortos. Foi calculado o valor de biomassa total de cada indivíduo e pela soma destes, calculou-se o valor de biomassa para cada parcela. As equações foram desenvolvidas por Estrada (2013), Estrada et al. (2014) e Soares et al. (2005). Foram utilizadas as equações das espécies que utilizam o DAP em sua formulação e estão apresentadas na Tabela 2.1.

Para o presente estudo, foi feito o reconhecimento *in loco* de todas as parcelas, bem como do manguezal em geral com o seu entorno. As coordenadas geográficas dos vértices de cada parcela de campo foram obtidas a partir de levantamento de precisão realizado com sistema de posicionamento por satélite, com o método estático relativo (NATURAL RESOURCE CANADA, 1995). Neste método foram utilizados dois receptores GPS Sokkia, modelo Stratus L1, ocupando os pontos para determinação de suas coordenadas, e um terceiro receptor GPS Topcon Hiper L1L2 ocupando um ponto de referência com coordenadas conhecidas, chamado de base. As medições obtidas com este método foram efetuadas para a localização das 34 parcelas de campo dentro do manguezal de estudo (Figura A1 do Apêndice A). Em um segundo levantamento de campo, foram obtidos pontos em ruas e áreas urbanas no entorno da APA de Guapimirim para auxiliar o georreferenciamento das imagens ópticas. A precisão máxima admitida na horizontal foi de 0,20 m, e na vertical de 0,30 m. A precisão média obtida foi de RMS horizontal=0,04 m; RMS vertical=0,07 m.

4.2 Dados de sensoriamento remoto

Os dados de sensoriamento remoto utilizados no presente estudo contemplam dados referentes à nuvem de pontos do sistema LiDAR de retorno discreto e imagens ópticas de alta resolução do satélite WorldView-2. As especificações dos dados de sensoriamento remoto são descritas a seguir.

Os dados LiDAR foram obtidos com o sistema aerotransportado Riegl 560 e pré-processados pela empresa Hansa Geofísica e Aerolevramento. As principais especificações do sistema LiDAR Riegl 560 estão apresentadas na Tabela 4.1 e Tabela 4.2. Os produtos disponibilizados consistem na nuvem de pontos LiDAR no formato LAS recobrando toda a área da APA de Guapimirim.

Tabela 4.1– Principais especificações do sistema LiDAR RIEGL 560 utilizado neste estudo.

Sensor	Sistema aerotransportado Riegl 560
Faixa de medição (1)	≥ 850 m $\rho = 0.2$; ≥ 1500 m $\rho = 0.8$
Precisão (desvio padrão)	± 20 mm
Intervalo de amostragem da onda	1ns
Intervalo do espectro	infravermelho
Altura de vôo	600 m AGL
Captura da onda na faixa dinâmica	16 bit
Resolução multi-alvo	Maior que 0,6 mm
Taxa de repetição do pulso LASER (PRR) (2)	Acima de 100000 Hz
Divergência do feixe de laser	0,5 mrad
Classe de segurança	Classe 1
Digitalização da série de ângulos	+/- 22,5°
Velocidade de digitalização	5-160 line scans/s
Verificador de exatidão do ângulo	0,0025°

(1) Tamanho do alvo em excesso do footprint, ρ representa a refletividade difusa do alvo; (2) Taxa de medição média ≤ 66 kHz; .

Tabela 4.2 - Informações técnicas dos produtos gerados no pré-processamento dos dados LiDAR obtidos com o sistema RIEGL 560.

Produtos	
Nuvem de pontos	Formato LAS
Área total	90 km ²
Sistema de referência geodésico	WGS84
Sistema de projeção	Universal Transversa de Mercator – UTM
Densidade de pontos	5 pulsos/m ² e ~ 6 pontos/m ²
Precisão altimétrica	15 cm
Precisão planimétrica	50 cm
Ângulo de visada	60° ($\pm 30^\circ$)
Dias e horários de Vôo:	11/12/2012 - 17:20 - 19:02 UTC 12/12/2012 - 15:29 - 18:10 UTC
Altura da maré	11/12/2012 - 17:20 UTC ~0,86 m e 19:02 UTC ~0,34 m 12/12/2012 - 15:29 UTC ~0.89 m, 13:53hs ~ 1.1 m - 18:10 UTC ~ 0.9 m

As imagens ópticas de alta resolução foram obtidas pelo satélite WorldView-2, lançado em 2009 pela Digital Globe com oito bandas multiespectrais e uma banda pancromática. Maiores informações podem ser encontradas em *digitalglobe.com*. A Tabela 4.3 apresenta as principais características das cenas WorldView-2 utilizadas no presente estudo.

A área total coberta pelas imagens (mosaico de 2 cenas) é de 234,9 km² que corresponde à parte terrestre da APA Guapimirim e mais uma faixa de 3 km no entorno

desta Unidade de Conservação. No horário de aquisição da imagem (13:30 GMT) a maré era de 0,34 m na estação Porto do Rio de Janeiro, Ilha Fiscal (MARINHA DO BRASIL, 2012) próxima da APA de Guapimirim.

Tabela 4.3 - Características da imagem original WorldView-2 utilizada neste trabalho.

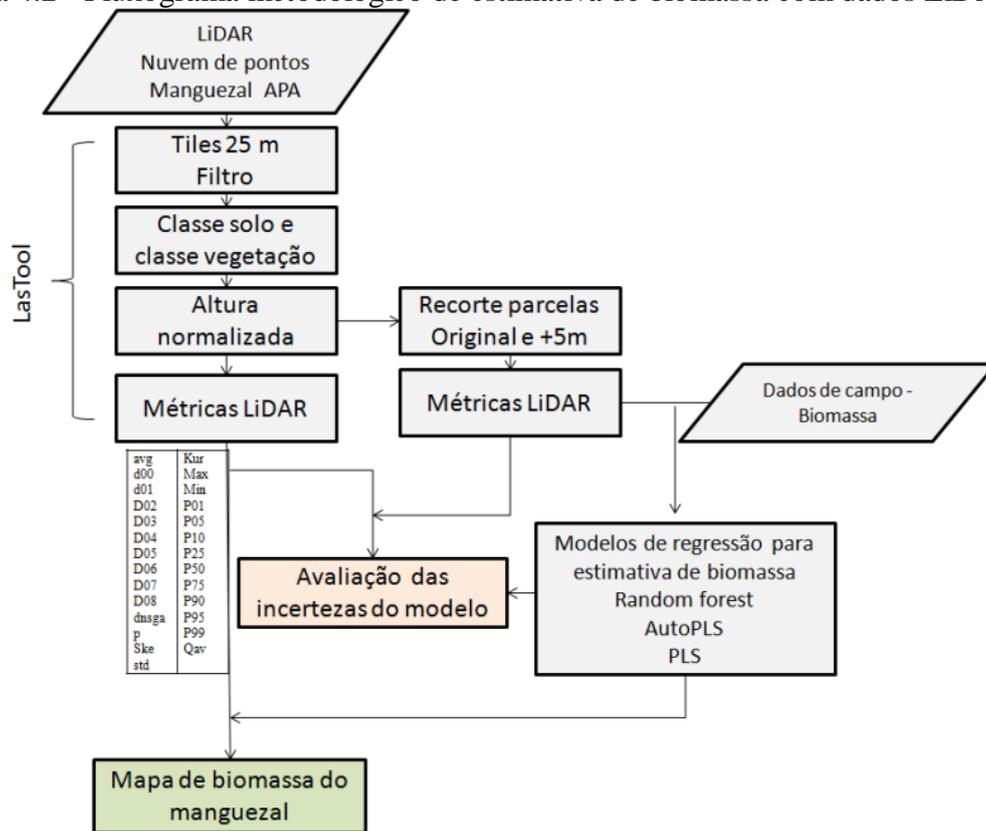
Satélite	WorldView-2
Bandas e Comprimentos de onda (nm)	Azul costeiro 400 - 450
	Azul 450 - 510
	Verde 510 - 580
	Amarelo 585 - 650
	Vermelho 630 - 690
	Borda-vermelho 705 - 745
	NIR1 770 - 895
	NIR2 860 - 1040
	Pancromática 450 - 800
Data do imageamento	01/10/2012
Horário de passagem	13:30 GMT
Resolução espacial	Pancromática: ~0,5 m
	Multiespectral: ~ 2,0 m
Resolução radiométrica	16 bits
Largura da faixa de imageamento	16,4 km no nadir

4.3 Processamento de dados LiDAR

O método empregado no presente estudo para estimar a biomassa dos bosques de mangue da APA de Guapimirim baseia-se na extração de métricas descritivas derivadas da distribuição da altura (z) da nuvem de pontos LiDAR. Esta abordagem foi adotada por trabalhos anteriormente realizados em diversos tipos florestais, como floresta tropical (ASNER; MASCARO, 2014; D'OLIVEIRA et al., 2012; HANSEN et al., 2015; VINCENT et al., 2012), floresta boreal (HYYPÄ et al., 2008; NÆSSET; GOBAKKEN, 2008; YU et al., 2011), floresta temperada e de coníferas (FRAZER et al., 2011; HUDAK et al., 2012; LEFSKY et al., 2002; LIM; TREITZ, 2004b; MEANS; ACKER, 2000; MEANS et al., 1999; NÆSSET, 2002;2011; POPESCU et al., 2011) floresta plantada (BEETS et al., 2012; MAGNUSSEN; BOUDEWYN, 1998). Entretanto, até onde vai o nosso conhecimento, esta abordagem ainda não foi aplicada em floresta de mangue com a extensão da APA de Guapimirim (~58,2 km² de floresta de mangue).

As principais etapas desenvolvidas no presente estudo para a estimativa da biomassa de bosques de mangue com uso de dados LiDAR são resumidas a seguir: (i) a partir de dados de campo, estimativa da biomassa de mangue para cada indivíduo e parcela; (ii) extração da altura normalizada dos pontos LiDAR; (iii) derivação das métricas estatísticas LiDAR para cada parcela; (iv) ajuste de modelos preditivos de biomassa de bosque de mangue; (v) avaliação de desempenho dos modelos; (vi) análise das incertezas ao nível das parcelas e das incertezas preditas ao nível de paisagem. As etapas do processamento LiDAR e estimativa de AGB são descritas mais detalhadamente a seguir. A Figura 4.2 apresenta o fluxograma metodológico do processamento LiDAR e estimativa da AGB.

Figura 4.2 - Fluxograma metodológico de estimativa de biomassa com dados LiDAR.



A nuvem de pontos LiDAR em formato LAS (arquivo binário que contém as informações dos retornos LiDAR) foi pré-processada pela empresa Hansa Geofísica e Aerolevantamento utilizando o software Terrascan, desta forma a nuvem de pontos foi filtrada e classificada nas seguintes classes: solo, vegetação, ruído e não-classificada. A

classificação dos pontos pertencentes ao terreno foi refinada por inspeção visual, refinamento por filtragem e classificação supervisionada de forma a garantir que pontos fora do nível do solo não estivessem sendo incluídos na classe solo e modelo digital de terreno. A nuvem de pontos recobrindo toda a área de estudo foi dividida em 137 áreas quadradas de $\sim 1 \text{ km}^2$ cada (aqui chamada *frame*) para facilitar o processamento dos dados.

A partir da nuvem de pontos LiDAR (*frames*), objetivando obter a altura normalizada para posteriormente extrair as métricas estatísticas Lidar, os *frames* referentes às áreas de interesse do manguezal foram processados seguindo algumas etapas detalhadas a seguir. Todas as etapas do processamento dos dados LiDAR foram executadas no programa *LasTools* 2.1 (<http://www.lastools.org/>). Primeiramente (utilizando o algoritmo *Lastile*), foram gerados *buffers* de 25 m em torno de cada *frame* da nuvem de pontos. Esta etapa permitiu ampliar e sobrepor as bordas dos *frames* durante os processamentos da nuvem de pontos. Posteriormente estas bordas são suprimidas para evitar duplicidade de dados. Com a finalidade de eliminar alguns poucos pontos presentes acima da vegetação e identificados como ruído, foi aplicado um filtro utilizando o algoritmo *Lasnoise* que elimina os pontos de acordo com os parâmetros *stepxy=4*; *stepz=5* e *isolate=6*. A partir dos pontos classificados como solo e vegetação, foram gerados pontos referentes à altura normalizada utilizando o algoritmo *Lasheight*. Este algoritmo computa a altura de cada ponto LiDAR (pontos referentes à classe vegetação) acima do solo, assumindo que os pontos referentes ao solo podem ser identificados e utilizados gerando-se uma grade triangular irregular (TIN) do solo como referência. Ou seja, para áreas de floresta a altura normalizada de cada ponto representa a altura do ponto da classe vegetação em relação ao solo.

A partir da altura normalizada foram extraídas as informações referentes às 34 parcelas de campo utilizando os respectivos polígonos (em formato *shapefile*) nas mesmas localizações geográficas (x,y) e tamanhos originais com áreas variando de 121 a 560 m². Ao se delimitar a parcela em medições com LiDAR, as copas das árvores são recortadas exatamente no limite da parcela. Porém, no levantamento de campo as árvores são consideradas somente se >50% da base enraizada estiver contida dentro da parcela (MASCARO et al., 2011). Neste caso, mesmo que alguma parte da copa da árvore

esteja fora do limite ou borda da parcela, esta árvore é incluída no cálculo de AGB da parcela em campo. Por isso, no presente estudo também foram extraídas as informações para cada área da parcela utilizando seus respectivos polígonos acrescidos de um *buffer* de 5 metros em seu perímetro. Desta forma, as áreas das parcelas aumentaram, variando de 361 a 1.053 m². Este aumento de área dos polígonos referentes às parcelas possibilitou capturar mais informações das árvores ali contidas incluindo as copas das árvores localizadas no limite das bordas das parcelas. Assim, foram gerados 2 conjuntos de dados representativos das 34 parcelas: um grupo com os tamanhos originais de cada parcela medidos em campo, e o outro grupo com as áreas maiores incluindo os *buffers* de 5 metros nos respectivos perímetros. Adicionalmente, objetivando complementar o mapeamento das áreas não-mangue, foram gerados outros 10 polígonos de 25 x 25 m referentes às classes não-mangue, tais como: água, áreas com vegetação não-mangue (somente presença de espécie invasiva ou associada), solo exposto. Estes 10 polígonos adicionais não foram utilizados no modelo final preditivo para estimativa de biomassa da floresta de mangue, sendo apenas utilizados para modelar as áreas com valor nulo de biomassa de mangue e mapear estas áreas também.

A partir dos pontos referentes à altura normalizada foram extraídas as métricas estatísticas LiDAR (Tabela 4.4) utilizando o algoritmo *Lascanopy*. As métricas LiDAR foram obtidas em duas escalas distintas - parcela e paisagem. Na escala da paisagem foi englobada toda a área do manguezal, sendo geradas grades com resolução de 25 x 25 m para cada métrica. Para a escala da parcela foram extraídas as mesmas métricas LiDAR dos respectivos polígonos como mencionados acima, ou seja, 34 polígonos com as áreas de tamanho original e outros 34 polígonos com as áreas maiores. Foram também geradas as métricas dos 10 polígonos referentes às classes não-mangue. As métricas LiDAR foram obtidas a partir da altura normalizada, utilizando um limiar de corte igual a 0,5 m acima do solo (LEE; LUCAS, 2007; LUCAS et al., 2006). As métricas que descrevem a distribuição da altura são: *canopy density gap* (dns-gap) que corresponde ao inverso da densidade do dossel computada como o número de todos os pontos acima do *cutoff* dividido pelo valor total de retornos; altura máxima (max); altura mínima (min); altura média (avg); desvio padrão (std); assimetria (*skewness*, ske); curtose (kur); média quadrática (qav); percentis da altura p01, p05, p10, p25, p50, p75, p90, p95, p99;

e densidade de pontos para os estratos das alturas em metros: d00 (0.5 a 2 m), d01 (2 a 4 m), d02 (4 a 6 m), d03 (6 a 8 m), d04 (8 a 10 m), d05 (10 a 12 m), d06 (12 a 14 m), d07 (14 a 16 m), d08 (16 a 18 m). A densidade de pontos é a densidade relativa da altura computada pela quantidade de pontos do estrato dividido pelo total de pontos em porcentagem.

Tabela 4.4 - Parâmetros estatísticos descritivos utilizados como métricas LiDAR para a modelagem da AGB de mangue.

Parâmetros LiDAR	
avg	Altura média
d00	Densidade de pontos - 0,5 a 2 m
d01	2 - 4 m
d02	4 - 6 m
d03	6 - 8 m
d04	8 -10 m
d05	10 -12 m
d06	12 -14 m
d07	14 -16 m
d08	16 - 18 m
dns_gap	Inverso da densidade de dossel (%)
kur	Curtose
max	Altura máxima
min	Altura mínima
p01	Percentil de 1% referente à altura dos pontos
p05	Percentil 5%
p10	Percentil 10%
p25	Percentil 25%
p50	Percentil 50%
p75	Percentil 75%
p90	Percentil 90%
p95	Percentil 95%
p99	Percentil 99%
qav	Média quadrática
ske	Assimetria
std	Desvio Padrão

4.3.1 Modelos preditivos de biomassa aérea de bosques de mangue obtidos a partir de métricas LiDAR

Foram utilizados os métodos RF, PLS e AutoPLS para gerar modelos preditivos da AGB de bosques de mangue da APA de Guapimirim. As métricas obtidas a partir dos

dados LiDAR foram utilizadas como variáveis explicativas nos modelos de regressão, e os valores de biomassa das 34 parcelas calculados a partir dos dados de campo foram utilizados para calibração e validação. Os modelos preditivos foram gerados considerando os dois tamanhos de parcelas explicados anteriormente, da seguinte forma (Tabela 4.5): Modelo 1 (M1) - utilizando 34 parcelas com os respectivos tamanhos originais medidos em campo; Modelo 2 (M2) - utilizando 34 parcelas com os tamanhos maiores pela adição dos *buffers* de 5 m; Modelo 3 (M3) - utilizando um total de 44 parcelas composto pelas 34 parcelas do M2 e as outras 10 parcelas das classes não-mangue. O modelo M3 foi gerado para auxiliar no mapeamento das áreas de não-mangue. O modelo M2ssp. é semelhante ao modelo M2 (34 parcelas aumentadas com *buffers* de 5m), porém com informações referentes às porcentagens de dominância das espécies presentes em cada parcela obtidas em campo (PETROBRÁS, 2012). Os modelos de estimativa de biomassa M1, M2, M2ssp. e M3 foram gerados utilizando os três métodos Random Forest, PLS e AutoPLS implementados em pacotes específicos na linguagem R (R CORE TEAM, 2015) tais como: pacote Random Forest (LIAW, WIENER, 2002), pacote PLS (MEVIK et al., 2015) e pacote AutoPLS (SCHMIDTLEIN et al., 2012).

A escolha do melhor modelo para gerar o mapa final da AGB do manguezal da área de estudo baseou-se na análise da acurácia de cada modelo. A acurácia dos modelos testados foi comparada em termos do *Root Mean Square Error* (RMSE) e coeficiente de determinação entre a predição e observação (R^2). Ambos são reportados para o conjunto de calibração (PLS e AutoPLS) bem como para o conjunto de validação (PLS, AutoPLS, RF). Para os métodos PLS e AutoPLS a estatística de validação (R^2 val, RMSE val) utiliza o procedimento *Leave-One-Out (LOO) cross-validation* na qual obtém-se o *Root Mean Square Error* (RMSE (LOO)). Para o método RF foi utilizado o *bootstrap Out-Of Bag error* (OOB) na qual se obtém o *Mean of Squared Residuals* (MSR). A estimativa do erro OOB é quase idêntica à obtida por *N-fold cross-validation* (HASTIE et al., 2009). Desta forma, o RMSE (LOO) pode ser comparado com a raiz quadrada do *Mean of Squared Residuals* (MSR) obtido com o erro OOB. A porcentagem de variância explicada (*% variance explained*) obtida na regressão RF pode ser comparada com o R^2 (LOO) obtido com os modelos AutoPLS e PLS.

Tabela 4.5 - Modelos preditivos de estimativa de biomassa com uso de dados LiDAR.

Modelo	AutoPLS (a)	Random Forest (b)	PLS (c)
M1- (34 parcelas originais)	M1a	M1b	M1c
M2 - (34 parcelas aumentadas com <i>buffer</i> 5m)	M2a	M2b	M2c
M2ssp. - (34 parcelas aumentadas com <i>buffer</i> 5m) e informações da % dominância de espécies	M2ssp.a	M2ssp.b	M2ssp.c
M3 - (34 parcelas aumentadas com <i>buffer</i> 5m) + 10 parcelas área não mangue	M3a	M3b	M3c

4.3.2 Mapeamento da biomassa na escala da paisagem com uso de dados LiDAR

O mapeamento da AGB do manguezal da APA de Guapimirim foi obtido utilizando o melhor modelo entre os propostos - M1a, M1b, M1c, M2a, M2b, M2c, M2ssp.a, M2ssp.b, M2ssp.c. A escolha foi definida de acordo com o melhor desempenho em termos do RMSE e R^2 . A partir do modelo de predição de biomassa e das métricas LiDAR obtidas na escala da paisagem foi estimada e mapeada a AGB do manguezal da APA de Guapimirim. O mapeamento da biomassa foi realizado com resolução de 25 x 25 m e contemplou somente a área de cobertura por floresta de mangue. Para limitar o mapeamento às áreas de mangue foi utilizada uma máscara gerada a partir do mapa de uso e cobertura da terra e tipos de mangue desenvolvido por Arasato et al. (2015).

4.3.3 Avaliação da cobertura da amostragem das parcelas para os dados LiDAR

Com a finalidade de avaliar o quão bem as 34 parcelas com as métricas LiDAR utilizadas como amostras de treinamento para gerar o modelo de predição capturam a variabilidade estrutural da área de manguezal, foi utilizada a metodologia anteriormente aplicada por Fekety et al. (2015) e White et al. (2013). O método consistiu em algumas etapas: (i) Extraíram-se as componentes principais das métricas LiDAR para toda a área de estudo. Para isso, foi feita uma análise de principais componentes das métricas LiDAR de toda a área de floresta de mangue na escala da paisagem, utilizando a função "*prcomp*" do pacote "*stats*" do programa R (R CORE TEAM, 2015), e foram calculados os valores das coordenadas de cada componente desta PCA por meio da função "*predict*" do programa R. (ii) Da mesma forma, tendo como base de dados o resultado da PCA da escala da paisagem anterior, foram calculados os valores das coordenadas

das componentes da PCA referentes às métricas LiDAR das 34 parcelas de campo por meio da função "*predict*". (iii) Os valores das componentes PCA1 e PCA2 referentes às 34 parcelas, foram sobrepostos no plano formado pelas componentes PCA1 e PCA2 obtidas da PCA na escala da paisagem. O resultado é a distribuição das parcelas de campo no plano PCA1 *versus* PCA2, obtido com o conjunto de métricas LiDAR referentes à floresta de mangue. Este tipo de análise permite identificar pixels no espaço de preditores que estão fracamente representados no conjunto das amostras de treinamento do modelo e que poderiam, conseqüentemente, ser mal preditos pelo modelo de estimativa de biomassa.

4.3.4 Análise da incerteza no nível da paisagem

As métricas LiDAR foram utilizados como variáveis auxiliares do melhor modelo de regressão treinado com as amostras de campo. O melhor modelo foi então utilizado para gerar a predição da AGB da área de estudo (escala da paisagem). Para estimar a incerteza da estimativa da biomassa ao nível da paisagem, foi utilizada a abordagem de avaliação baseada no estimador de regressão geral da AGB com o método de inferência *design-based* (SÄRDNAL et al., 1992; GREGOIRE et al., 2016). O estimador de regressão geral da AGB e sua variância foram calculados pelas Equações 4.1 e 4.2 obtidas de Gregoire et al. (2016). O resultado desta análise expressa a AGB total e sua variância em termos da incerteza da predição referente à AGB média/ha sobre toda a floresta de mangue.

$$\hat{B} = \sum_{k=1}^N \hat{y}_k + \frac{N}{n} \sum_{k \in S} y_k - \hat{y}_k \quad \text{Equação 4.1}$$

$$\hat{V}(\hat{B}) = N^2 \left(\frac{1}{n} - \frac{1}{N} \right) \sum \frac{(y_k - \hat{y}_k)^2}{n-1} \quad \text{Equação 4.2}$$

Onde \hat{B} é a AGB total obtida na escala da paisagem e $\hat{V}(\hat{B})$ é sua variância, N é o tamanho da população (N=84.800 pixels de 25 x 25 m), n é o número de unidades do

conjunto amostral S (34 parcelas de campo) e $\sum_{k \in S} \frac{(y_k - \hat{y}_k)^2}{n-1}$ é o erro estimado do modelo de predição na escala da parcela. Desta forma, o resultado aqui obtido mostra a AGB média estimada por hectare na escala da paisagem (\hat{B}/N) e sua incerteza é expressa com o desvio padrão do erro ($\sqrt{\frac{\hat{V}(\hat{B})}{N^2}}$).

Para testar a consistência dos resultados, foi também aplicada uma abordagem alternativa de reamostragem para estimar a incerteza da predição na escala da paisagem. As 34 unidades amostrais foram aleatoriamente divididas em dois subconjuntos pela estratificação do conjunto amostral, de modo que cada subconjunto cobrisse o maior intervalo de biomassa estimada em campo. As unidades amostrais (parcelas) foram primeiramente ordenadas de acordo com o valor crescente de AGB. O conjunto de dados foi então dividido em 17 pares de duas observações consecutivas. Uma observação de cada par foi aleatoriamente alocada para o subconjunto de amostras I e II, assim criando dois subconjuntos de amostras de igual tamanho e balanceados em relação aos valores de AGB. Cada subconjunto de dados de campo foi utilizado no ajuste do modelo de predição da biomassa na escala da paisagem. A diferença da AGB média por hectare predita pelos modelos pareados foi registrada. Este processo, desde a divisão aleatória, ajuste do modelo e obtenção da diferença da predição na escala da paisagem foi repetida 100 vezes. A AGB média e o desvio padrão obtido entre os grupos pareados são analisados e podem refletir a incerteza na predição para o nível da paisagem.

4.4 Processamento da imagem óptica de alta resolução e análise textural

As imagens ópticas de alta resolução do satélite WorldView-2 foram utilizadas no presente estudo objetivando avaliar seu potencial para estimar a AGB de bosques de mangue com distintos graus de alteração através das informações texturais obtidas com os métodos FOTO e GLCM. Estes dois métodos de extração de informações texturais foram aplicados às imagens ópticas pancromáticas da área de manguezal estudada. Os processamentos aplicados às imagens são descritos a seguir.

Duas cenas pancromáticas de alta resolução espacial (0,5 m) foram utilizadas para cobrir a área de estudo. As imagens foram georreferenciadas separadamente e posteriormente mosaicadas. O georreferenciamento foi efetuado no programa ENVI 5. utilizando o método do vizinho-mais-próximo e uma função polinomial de 1ª ordem. As cenas foram projetadas no sistema de coordenadas Universal Transversa de Mercator (UTM), *World Geodetic System* (WGS) 84, zona 23S. Para o georreferenciamento foram utilizados 33 pontos de controle de campo referentes às áreas urbanas próximas do manguezal obtidos durante campanha realizada em 02/2015. A primeira imagem, que cobre uma faixa pequena do manguezal, foi georreferenciada utilizando 10 pontos de controle com RMS de 0,59 (pixel). Para a segunda imagem, que engloba a maior parte do manguezal, foram utilizados 25 pontos de controle obtendo um RMS de 1,05 pixel. Após o georreferenciamento as duas imagens foram mosaicadas utilizando também o programa ENVI 5. O mosaico final foi recortado utilizando uma máscara da área de manguezal, de acordo com o mapeamento obtido de Arasato et al. (2015), excluindo as áreas urbanas e corpos de água. O mosaico pancromático do manguezal da APA de Guapimirim foi utilizado para extrair as informações texturais pela aplicação dos métodos FOTO e GLCM, que serão descritos a seguir.

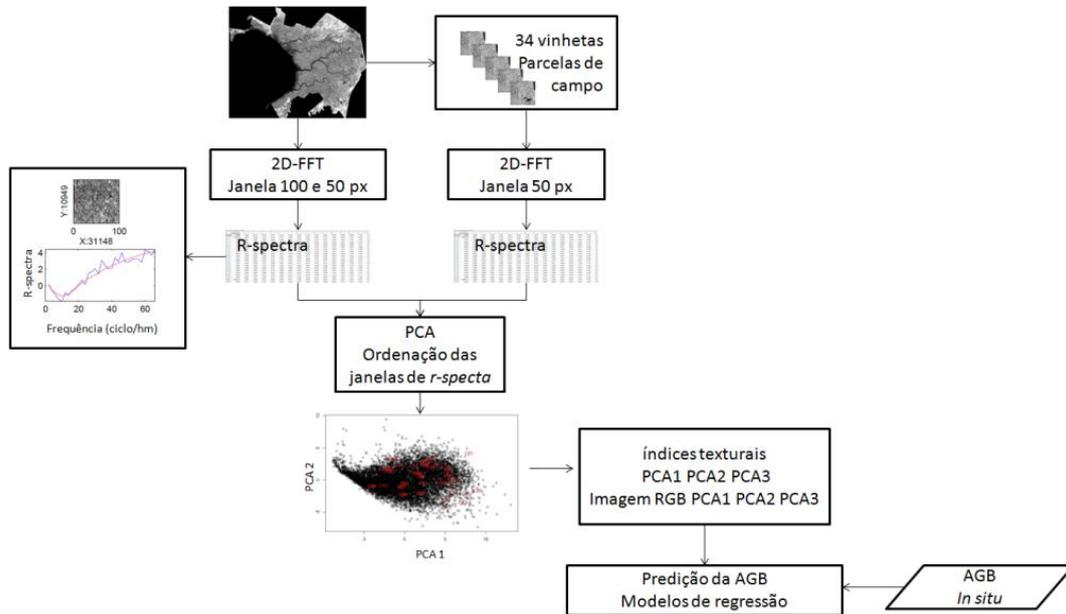
4.4.1 *Fourier-based textural ordination* (FOTO)

A análise espectral bidimensional pela transformada de Fourier, utilizada para descrever padrões espaciais em imagens ópticas, foi descrita com detalhes em Renshaw e Ford (1984) enquanto Couteron (2002) e Mugglestone e Renshaw (1998) apresentam a aplicação da técnica em imagens aéreas. O método FOTO (COUTERON, 2002; COUTERON et al., 2005; PROISY, 2007) é uma abordagem que utiliza índices de textura do dossel extraídos da imagem e baseia-se na ordenação textural, fundamentada na transformada rápida de Fourier discreta e análise de componentes principais.

No presente estudo o método FOTO foi aplicado em duas escalas distintas, uma referente à imagem pancromática para toda a área do manguezal na escala da paisagem, e de forma distinta, o método FOTO foi aplicado separadamente para 34 recortes de imagens de 50 x 50 m (vinhetas) que contemplavam as 34 parcelas de campo. O

fluxograma metodológico com as duas abordagens do processamento FOTO pode ser visto na Figura 4.3.

Figura 4.3 - Fluxograma metodológico das etapas de processamento do método FOTO para a escala da paisagem e escala de parcela (34 vinhetas).



A aplicação do método FOTO, implementado no programa Matlab R2012a, foi efetuada seguindo algumas etapas gerais de processamento: (i) Inicia-se com a especificação do tamanho da janela de análise para processamento da imagem pancromática. O tamanho mínimo da janela deve incluir repetições das maiores copas das árvores da área de estudo. (ii) Cada janela de análise da imagem é submetida à análise espectral bidimensional baseada na transformada rápida de Fourier discreta (FFT). Isto significa que a radiância (nível de cinza) expressa no domínio espacial pela função $I(x,y)$ da coluna (x) e linha (y) da imagem é transposta no domínio da frequência com a função $F(p,q)$ onde p e q são frequências espaciais ao longo das direções XY (PROISY, 2007). (iii) Como resultado da FFT, para cada janela de análise obtém-se o *radial spectrum* (*r-spectrum*). Os *r-spectra* computados para cada janela são agrupados numa tabela, onde cada linha é o *r-spectrum* de uma dada janela e cada coluna contém os valores espectrais relativos a um dado número de onda. As imagens (janelas) com textura mais rugosa se expressam em *r-spectra* com baixa frequência espacial, e imagens com

textura fina se expressam em *r-spectra* com frequência espacial mais alta. (iv) A etapa seguinte é a ordenação textural baseada nos *r-spectra*. A tabela com os valores de *r-spectra* é então submetida a uma análise de principais componentes (PCA). Assim as componentes mais proeminentes da PCA (PCA1, PCA2 e PCA3) são utilizadas como índices texturais (índices texturais FOTO), permitindo a ordenação das janelas ao longo do gradiente textural. (v) Posteriormente, os índices texturais podem ser utilizados como variáveis preditoras nos modelos de regressão de estimativa de AGB dos bosques de mangue. Além destes índices, o algoritmo FOTO faz um agrupamento pelo método *k-médias* com os valores de *r-spectra*.

Para a escala da paisagem, foi aplicado o algoritmo FOTO, implementado no programa Matlab R2012a conforme o método explicado acima, na imagem pancromática referente à área do manguezal. Foram testados variados tamanhos de janelas, sendo escolhidas as janelas de 50 x 50 pixels e 100 x 100 pixels, o que equivale a 25 e 50 metros respectivamente. Os produtos resultantes do método FOTO, tais como a tabela contendo os *r-spectra* para cada janela de análise e as componentes PCA1, PCA2 e PCA3, foram utilizados para a estimativa de AGB de bosques de mangue e também para a classificação dos tipos de cobertura do solo na área do manguezal.

Para a escala de parcela, foi aplicado o método FOTO com uma segunda abordagem, objetivando reduzir a influência de outras coberturas do solo próximas às parcelas, como água e áreas de não-mangue. As etapas desta abordagem foram: (i) Foi aplicado o algoritmo FOTO, implementado no programa Matlab R2012a conforme o método explicado acima, na imagem pancromática que fora anteriormente recortada em 34 vinhetas de 50 x 50 m, de forma a contemplar os bosques de mangue referentes às 34 parcelas de campo. Foi utilizado um tamanho de janela de análise de 50 x 50 pixels, que é aproximadamente o tamanho das parcelas de campo (~25 x 25 m). Com isto, foram obtidas as tabelas de *r-spectra* referentes às 34 vinhetas. (ii) Da mesma forma, foi aplicado o algoritmo FOTO na imagem pancromática da área total de floresta de mangue na escala da paisagem (excluindo corpos d'água e áreas de não mangue), utilizando janela de análise com 50 x 50 pixels, sendo assim obtida a tabela de *r-spectra* para a escala da paisagem somente para floresta de mangue. (iii) A partir da tabela de *r-spectra* obtida na etapa (ii) extraiu-se as componentes principais com uma técnica

diferente. Nesta tabela foi aplicada uma análise de principais componentes utilizando a função "prcomp" do pacote "stats" do programa R (R CORE TEAM, 2015) e a partir do resultado desta PCA foram calculados os valores das coordenadas de cada componente desta PCA por meio da função "predict" do programa R. (iv) Com esta mesma técnica e tendo como base de dados o resultado da PCA obtido na etapa (iii), foram calculados os valores das coordenadas das componentes da PCA referentes aos dados das tabelas de *r-spectra* (obtidos na etapa (i)) representativos das 34 parcelas de campo também por meio da função "predict" do programa R. Desta forma, foram obtidos os índices de textura FOTO, que são as componentes (PCA1, PCA2, PCA3...) relativas à escala da parcela. Estes índices de textura foram utilizados como variáveis preditoras nos modelos para a estimativa da AGB dos bosques de mangue.

4.4.2 *Gray-Level Co-occurrence Matrix (GLCM)*

Os índices texturais obtidos com o método GLCM contêm informações sobre as características texturais da imagem. Nesta abordagem a obtenção das características texturais parte do pressuposto de que a informação textural de uma imagem está contida na relação espacial global que os tons de cinza da imagem têm uns com os outros. Supõe-se, portanto, que a informação textural pode ser adequadamente especificada por um conjunto de matrizes de dependência espacial dos tons de cinza que são computadas por várias relações angulares e de distância entre pares de pixels vizinhos na imagem (HARALICK et al., 1973). Desta forma, todos os índices texturais GLCM são derivados destas matrizes de dependência espacial de tons de cinza dos vizinhos angulares próximos. A extração de informações texturais é feita por meio da aplicação de equações específicas que definem medidas relativas às características texturais específicas da imagem. Estas equações estão apresentadas em Haralick et al. (1973) e também estão implementadas em programas específicos de processamento de imagens, como o ENVI 5 e o pacote "glcm" (ZVOLEFF, 2016) do programa R CORE TEAM (2015).

No presente estudo a extração de índices texturais baseada no método GLCM (HARALICK et al., 1973) foi realizada na imagem óptica pancromática de alta resolução na escala da paisagem e em 34 vinhetas de 100 x 100 m referentes às

localidades das parcelas de campo. Os índices texturais aqui utilizados foram: média, variância, homogeneidade, contraste, dissimilaridade, entropia, segundo momento e correlação.

Para a escala da paisagem, foi utilizada uma janela de 49 x 49 pixels (~25 x 25 m) na direção (X, Y) de deslocamento para o cálculo da matriz de co-ocorrência igual a (1,1) e quantização de nível de cinza de 32 bits, executados no programa ENVI 5. Após esta etapa, as imagens resultantes dos índices texturais que eram de 0,5 m de resolução espacial foram reamostradas para 25 x 25 m de modo que todos os dados - índices texturais FOTO, GLCM e variáveis métricas LiDAR - ficassem com a mesma resolução para as análises na escala da paisagem.

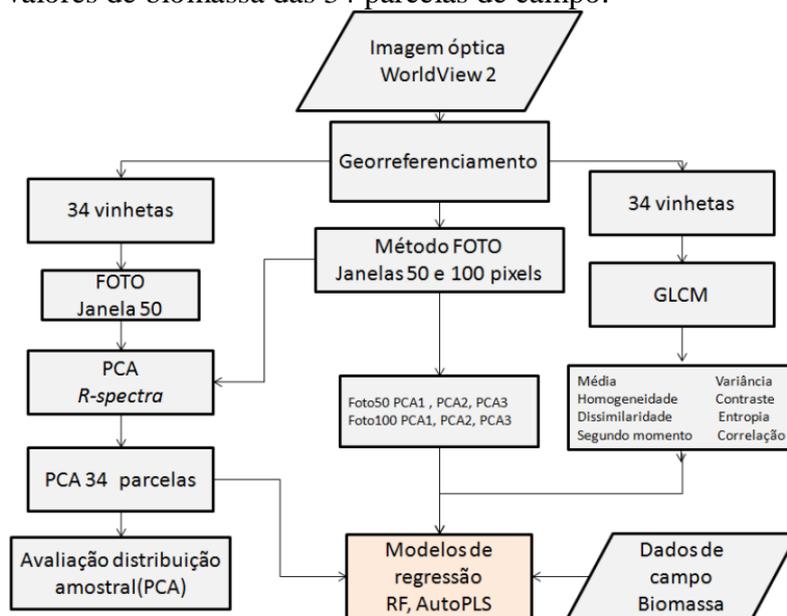
A obtenção dos índices texturais para a escala da parcela foi realizada com uso do pacote “gldm” (ZVOLEFF, 2016) do programa R CORE TEAM (2015) diretamente nas 34 vinhetas de 100 x 100 m. Foram obtidos os mesmos índices texturais: média, variância, homogeneidade, contraste, dissimilaridade, entropia, segundo momento e correlação. Foram testados distintos tamanhos de janelas (15 x 15 m e 35 x 35 m), níveis de cinza (32 e 64 bits) e foi utilizada a média de todas as direções (x, y) ((0,1), (1,1), (1,0), (1,-1)). Os índices texturais derivados da aplicação do GLCM na escala da parcela foram utilizados na aplicação de modelos para a estimativa de biomassa de bosques de mangue com as 34 parcelas de campo como dados de referência da biomassa. Desta forma, para cada vinheta da imagem (referentes às 34 parcelas de campo) foram obtidos os valores dos 8 índices texturais que serviram de entrada como variáveis explicativas nos modelos de regressão de estimativa de AGB de bosques de mangue.

4.4.3 Modelos preditivos de biomassa aérea de bosques de mangue obtidos a partir dos índices texturais

Objetivando averiguar o potencial uso de índices texturais para estimar a biomassa de bosques de mangue com distintos graus de alteração, foram testados os métodos de regressão multivariada RF e AutoPLS, utilizando como conjunto de dados preditores os índices texturais na escala da parcela e os valores de biomassa das 34 parcelas como

verdade de campo. Os modelos preditivos foram analisados de acordo com as medidas de incertezas do RMSE e R^2 . Os grupos de índices texturais que foram utilizados como variáveis predictoras foram: (i) (modelos M4 e M4.all) índices texturais obtidos pelo método FOTO (PCA1, PCA2, PCA3...) na escala da parcela (34 vinhetas); (ii) (modelos M5) índices texturais obtidos pelo método GLCM (média, variância, homogeneidade, contraste, dissimilaridade, entropia, segundo momento e correlação), para janelas de 15 x 15 e 35 x 35 pixels e quantização de nível de cinza com 32 e 64 bits e média angular das direções (X, Y); (iii) (modelos M6) índices texturais FOTO e GLCM. O fluxograma metodológico das aplicações dos métodos FOTO e GLCM para estimativa de biomassa é apresentado na Figura 4.4.

Figura 4.4 - Fluxograma metodológico da estimativa de biomassa de bosques de mangue com índices texturais obtidos pelos métodos FOTO e GLCM e valores de biomassa das 34 parcelas de campo.



4.4.4 Avaliação da cobertura da amostragem das parcelas para o método FOTO

Com a finalidade de avaliar o quão bem os índices texturais FOTO das 34 parcelas utilizados como amostras de treinamento para gerar o modelo de predição capturam a

variabilidade estrutural da floresta de mangue, foi utilizada a metodologia anteriormente aplicada por Fekety et al. (2015) e White et al. (2013).

Nesta análise foram utilizadas as mesmas componentes PCA1 e PCA2 da escala da parcela e da paisagem, obtidas anteriormente pela aplicação do método FOTO conforme está descrito na seção 4.4.1 FOTO no parágrafo relativo à escala da parcela. Os valores das PCA1 e PCA2 referentes às 34 parcelas foram sobrepostos no plano formado pelas PCA1 *versus* PCA2 obtidas na escala da paisagem. O resultado é a distribuição das parcelas de campo no plano formado pelas componentes PCA1 *versus* PCA2, obtidas com o método FOTO e referentes à escala da paisagem. Este tipo de análise permite identificar pixels no espaço de preditores que estão fracamente representados no conjunto das amostras de treinamento do modelo e que poderiam, conseqüentemente, ser mal preditos pelo modelo de estimativa de biomassa.

4.5 Simulação da estimativa da biomassa do manguezal com uso de índices texturais FOTO e GLCM e valores da AGB do mapeamento obtido com LiDAR

Com uma abordagem diferente da anteriormente testada, buscou-se aqui ampliar a representatividade estrutural e de biomassa dos bosques de mangue e o número de parcelas para calibração dos modelos preditivos como forma de averiguar o potencial uso dos índices texturais para capturar a variabilidade estrutural do manguezal decorrente do grau de alteração. Foram extraídos os valores de AGB do mapa resultante do modelo gerado com os dados LiDAR obtido no presente estudo. Isto permitiu aumentar o número de parcelas consideradas como "verdade de campo". Foram gerados 2.000, 100 e 50 pontos aleatórios na floresta de mangue da área de estudo e extraídos os valores referentes aos índices texturais FOTO (componentes principais PCA1, PCA2, PCA3), e aos índices texturais do GLCM (média, variância, homogeneidade, contraste, dissimilaridade, entropia, segundo momento e correlação) utilizados como variáveis preditoras nos modelos. Da mesma forma, com os mesmos 2.000, 100 e 50 pontos aleatórios foram extraídos os valores de AGB utilizados para a calibração dos modelos preditivos. Foram gerados modelos de predição utilizando distintos conjuntos de dados de entrada como variáveis preditoras: (i) modelo M7 utilizando índices texturais FOTO

(ii) modelo M8 utilizando índices texturais GLCM e (iii) M9 utilizando todos os índices texturais (FOTO+GLCM). Os modelos de predição (M7, M8 e M9) foram baseados nos métodos RF e AutoPLS e as incertezas foram analisadas em função do RMSE e R². Um resumo metodológico pode ser visualizado no fluxograma da Figura 4.5. Todos os modelos de predição utilizando os índices texturais são mostrados na Tabela 4.6.

Figura 4.5 - Fluxograma metodológico para a estimativa de biomassa do manguezal utilizando variáveis predictoras provenientes dos índices texturais FOTO e GLCM e AGB obtida do mapa de biomassa do manguezal gerado com dados LiDAR.

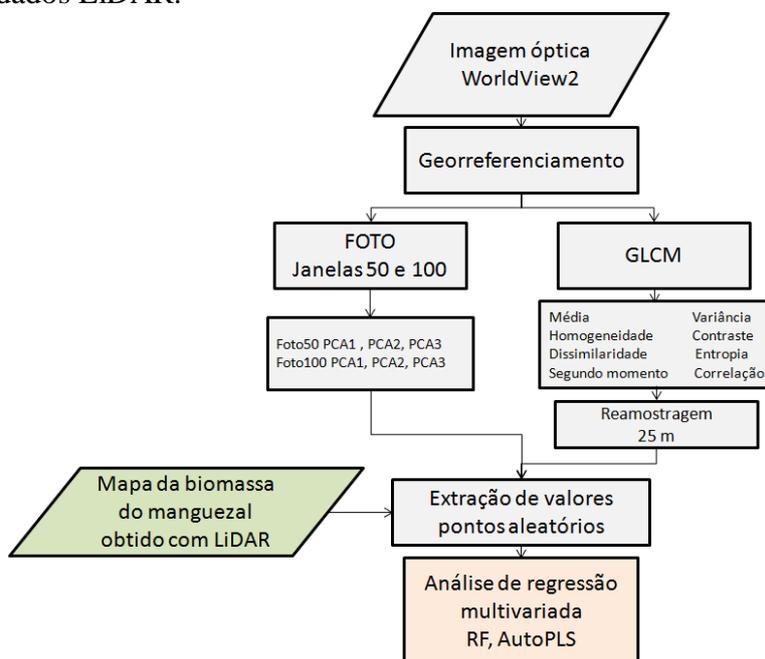


Tabela 4.6 - Modelos preditivos de estimativa de biomassa com uso de índices texturais estimados pelos métodos FOTO e GLCM.

Modelo	AutoPLS (a)	Random Forest (b)	Biomassa
M4 - 34 parcelas - FOTO	M4a	M4b	Dados de campo
M5 - 34 parcelas - GLCM	M5a	M5b	Dados de campo
M6 - 34 parcelas - FOTO+GLCM	M6a	M6b	Dados de campo
M7 - pontos aleatórios - FOTO	M7a	M7b	Mapa de biomassa LiDAR 2000, 100, 50 pontos
M8- pontos aleatórios- GLCM	M8a	M8b	Mapa de biomassa LiDAR 2000, 100, 50 pontos
M9- pontos aleatórios- GLCM + FOTO	M9a	M9b	Mapa de biomassa LiDAR 2000, 100, 50 pontos

4.6 Classificação dos tipos de mangue

Com o objetivo de averiguar o potencial uso dos índices texturais para discriminar diferentes tipos de cobertura do solo na área de estudo, com ênfase em áreas com mangue alterado, foram utilizados os produtos LiDAR, FOTO e GLCM obtidos na escala de paisagem descritos anteriormente. Foi utilizado o método de classificação Random Forest do pacote "randomForest" (LIAW; WIENER, 2002) implementado no programa R. O Random Forest é um classificador estruturado em árvores de decisão, no qual para cada árvore é obtido um voto para a classe mais popular. A classificação final é definida pela classe com a maioria dos votos (BREIMAN, 2001). A taxa de erro da classificação é baseada no método *Out-Of-Bag* (OOB) anteriormente descrito. O método RF utiliza o índice Gini (*Mean decrease GINI*) como uma medida de seleção das variáveis. Este índice mensura a pureza/impureza da variável em relação a uma classe. Assim, fornece a contribuição de cada variável no resultado da classificação.

Foram selecionadas 3 classes de análise baseadas no mapeamento do uso, cobertura e tipos de mangue da APA de Guapimirim gerado por Arasato et al. (2015) e PETROBRÁS (2012). As classes foram: “mangue-denso”, “mangue-alterado” e “não-mangue”. A classe “mangue-denso” é caracterizada pela presença predominante de espécies de mangue e um dossel mais denso e fechado. A classe “mangue-alterado” é caracterizada pela presença de espécies de mangue e espécies associadas entre clareiras maiores. A classe “não-mangue” é caracterizada pela presença de outros tipos de vegetação com dominância da espécie associada *Acrostichum*, invasoras e solo exposto. Na Figura A2 do Apêndice A pode-se observar alguns tipos de cobertura vegetal encontrados no manguezal da APA de Guapimirim.

Com auxílio do modelo de altura do dossel (CHM) obtido com os dados LiDAR e o mapeamento da cobertura do manguezal da APA de Guapimirim (ARASATO et al., 2015; PETROBRÁS, 2012) foram definidos polígonos representativos para cada classe de análise. Dentro destes polígonos foram definidos pontos objetivando posteriormente extrair os valores dos pixels dos produtos LiDAR, FOTO e GLCM. Desta forma, foram totalizados 2.241 pontos representativos sendo 708 da classe “*mangue-alterado*”, 1.026 da classe “*mangue-denso*” e 507 da classe “*não-mangue*”.

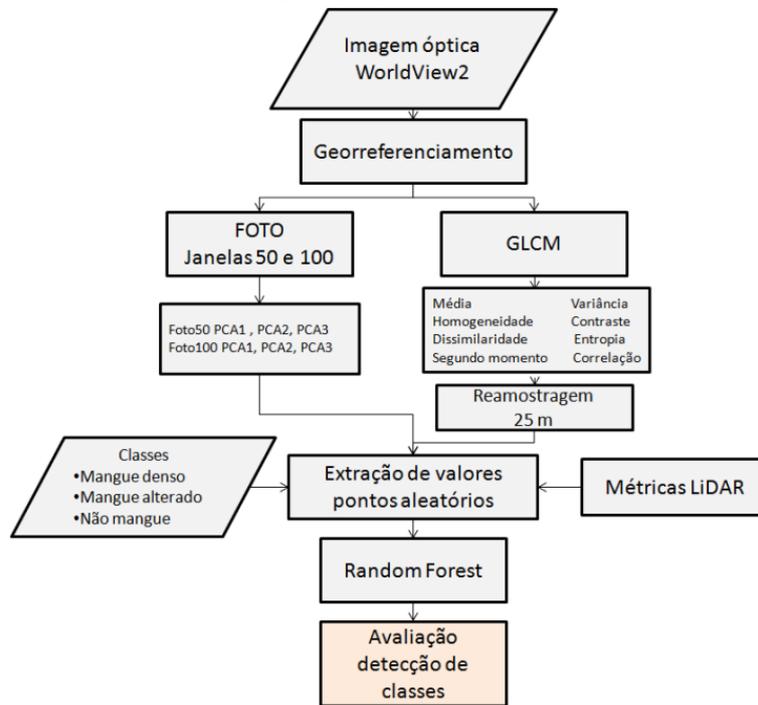
Os valores extraídos dos produtos LiDAR foram referentes às métricas estatísticas na escala de paisagem. Dos produtos gerados pelo método FOTO foram extraídos os valores dos índices texturais referentes às componentes PCA1, PCA2 e PCA3 utilizando janelas de 50 e 100 pixels na escala de paisagem para toda a área de manguezal. Dos produtos gerados pelo método GLCM foram extraídos os valores dos índices texturais - média, variância, homogeneidade, contraste, dissimilaridade, entropia, segundo momento e correlação - na escala de paisagem. Todos os valores extraídos e utilizados como dados de entrada no classificador foram obtidos com resolução reamostrada para 25 x 25 metros.

O conjunto de dados de entrada foi organizado de diferentes formas para entrada no classificador. A Tabela 4.7 apresenta todas as variáveis de entrada que compuseram os diferentes grupos. Os grupos foram: (i) as métricas LiDAR; (ii) índices texturais do método FOTO PCA1, PCA2, PCA3; (iii) os 8 índices texturais GLCM; (iv) todos os índices texturais FOTO+GLCM; (v) todos as variáveis (LiDAR, FOTO e GLCM). A Figura 4.6 mostra o fluxograma metodológico da classificação.

Tabela 4.7 - Todos os parâmetros utilizados na classificação Random Forest: métricas LiDAR, índices texturais Foto e GLCM.

Métricas LiDAR			
d00	d01	d02	d03
d04	d05	d06	d07
d08	p01	p05	p10
p25	p50	p75	p90
p95	p99	max	min
qav	kur	std	ske
dns_gap	avg		
Índices texturais FOTO			
foto2550_PCA1	foto2550_PCA2	foto2550_PCA3	
foto100_PCA1	foto100_PCA2	foto100_PCA3	
Índices texturais GLCM			
Média	Variância	Homogeneidade	Contraste
Dissimilaridade	Entropia	Segundo momento	Correlação

Figura 4.6 - Fluxograma metodológico da classificação de tipos de cobertura do solo do manguezal utilizando método Random Forest, as métricas LiDAR e os índices texturais FOTO e GLCM.

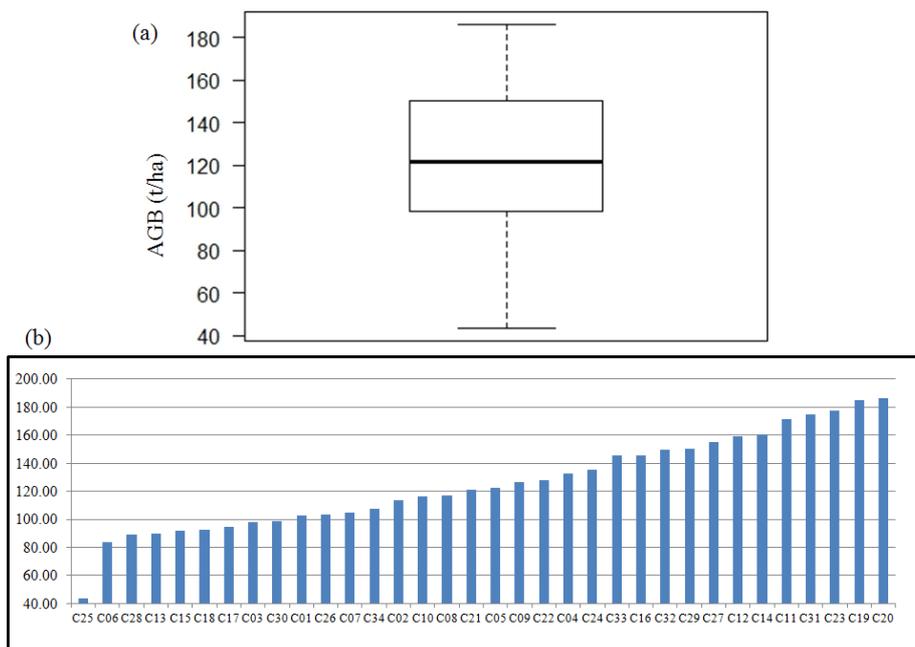


5 RESULTADOS E DISCUSSÕES

Os resultados estão ordenados de acordo com as perguntas científicas norteadoras deste estudo que foram apresentadas na Introdução. Inicialmente, respondendo à pergunta 1- *O quão precisa é a estimativa de biomassa de bosques de mangue com distintos graus de alteração com uso de dados LiDAR?* pretende-se apresentar e discutir os resultados dos modelos preditivos de AGB de bosques de mangue que foram obtidos com os dados LiDAR de retorno discreto, as análises das incertezas e o mapa de AGB do manguezal da APA de Guapimirim. Com o intuito de buscar responder à questão 2- *Qual o potencial da análise textural aplicada a imagens ópticas de alta resolução espacial para estimar a biomassa de floresta de mangue com distintos graus de alteração?* são apresentados os resultados dos modelos preditivos de AGB de bosques de mangue obtidos por meio de índices texturais dos métodos FOTO e GLCM. Por fim, para complementar a investigação sobre o uso de dados texturais para caracterizar e distinguir bosques de mangue com distintos graus de alteração, buscou-se responder à questão 3- *É possível distinguir tipos de bosques de mangue em diferentes estágios de alteração por meio de análise textural?* São apresentados os resultados referentes à aplicação do método de classificação Random Forest para distinguir tipos de mangue como *mangue-denso*, *mangue-alterado* e áreas de *não-mangue*.

Para calibrar e validar os modelos preditivos gerados no presente estudo, foram utilizados os valores de AGB das 34 parcelas de campo calculados em colaboração com o Dr. Mario Soares a partir dos dados obtidos em campo. A biomassa estimada (total) inclui a biomassa viva e a biomassa morta de troncos em pé. A Figura 5.1 mostra o diagrama de caixas (*Boxplot*) da variação de biomassa de mangue acima do solo (AGB, t/ha) e a variação dos valores de biomassa calculados para cada uma das 34 parcelas de estudo. O valor médio da AGB das 34 parcelas de campo é 125,71 t/ha, o valor mínimo é de 43,56 t/ha, o valor máximo é de 186,10 t/ha, a mediana é de 121,92 t/ha, o 1º quartil é de 99,71 t/ha e o 3º quartil é de 150,29 t/ha.

Figura 5.1 - Variação de biomassa de mangue acima do solo (AGB, t/ha)



(a) Diagrama de caixas (*boxplot*) da variação de biomassa de mangue acima do solo (AGB, t/ha) referente às 34 parcelas de campo, indicando o valor da mediana da AGB, os quartis 1º e 3º e os limites dos valores inferior e superior da AGB. (b) Variação da AGB referente a cada parcela de campo.

5.1 Avaliação dos modelos de estimativa de biomassa com uso de dados LiDAR

Os modelos preditivos da AGB dos bosques de mangue aqui avaliados foram gerados utilizando 26 métricas LiDAR (Tabela 4.4) como variáveis preditoras, e para sua calibração e validação foram utilizados os valores de AGB das 34 parcelas de campo representativas de manguezais com distintos graus de alteração (Figura 5.1). Estes modelos se diferenciam em função de 3 características: o tamanho dos polígonos de recorte dos dados LiDAR referentes às parcelas de campo (polígonos no tamanho original de cada parcela ou aumentados com a adição de 5 metros de *buffer* nas bordas); o método de regressão utilizado (AutoPLS, Random Forest ou PLS); e informação adicional (com informações sobre as espécies dominantes de cada parcela, ou sem adição destas informações). Os métodos de regressão AutoPLS, Random Forest e PLS foram comparados e suas incertezas avaliadas de acordo com os valores de RMSE e R². Deste modo, foram gerados 9 modelos (M1a, M1b, M1c; M2a, M2b, M2c; M2ssp.a,

M2ssp.b, M2ssp.c) cujas características e resultados são apresentados na Tabela 5.1 a seguir. O modelo M3, por incluir 10 áreas de não-mangue, não foi considerado nesta avaliação.

Tabela 5.1 - Resultados dos modelos preditivos de AGB de bosques de mangue para o manguezal da APA de Guapimirim. Sendo o RMSE(CAL) de calibração e RMSE(LOO) de validação, RMSE em t/ha.

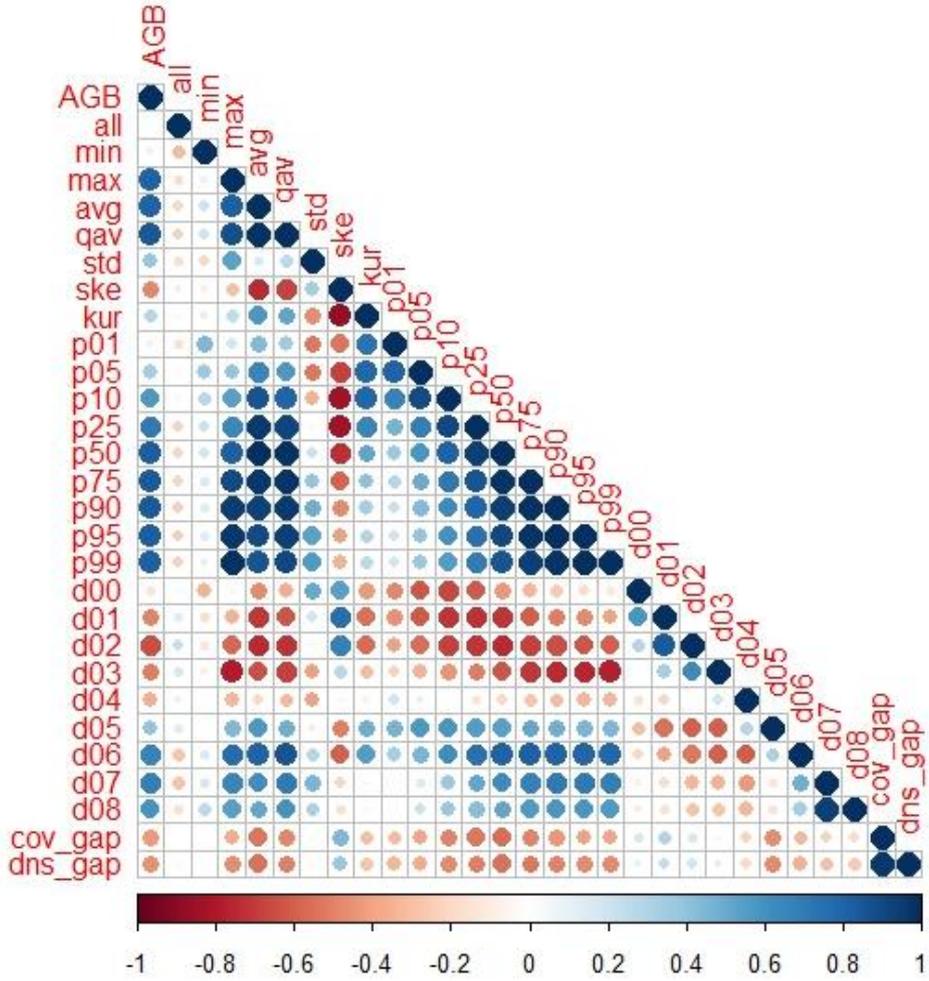
Modelo	AutoPLS (a)	Random Forest (b)	PLS (c)
M1 34 parcelas (tamanho original)	RMSE(CAL) = 14,70 RMSE(LOO) = 17,30 R ² (CAL) = 0,80 R ² (LOO) = 0,73	RMSE = 18,60 R ² = 0,68	RMSE(CAL) = 13,30 RMSE(LOO) = 17,30 R ² (CAL) = 0,85 R ² (LOO) = 0,73
M2 34 parcelas (com buffer de 5 m)	RMSE(CAL) = 11,17 RMSE(LOO) = 14,80 R ² (CAL) = 0,89 R ² (LOO) = 0,80	RMSE = 17,86 R ² = 0,71	RMSE (CAL) = 12,22 RMSE (LOO) = 16,00 R ² (CAL) = 0,86 R ² (LOO) = 0,77
M2ssp. 34 parcelas (com <i>buffer</i> de 5m e informações espécies)	RMSE(CAL) = 15,30 RMSE(LOO) = 18,00 R ² (CAL) = 0,79 R ² (LOO) = 0,71	RMSE = 17,62 R ² = 0,72	RMSE(CAL) = 12,13 RMSE(LOO) = 19,68 R ² (CAL) = 0,86 R ² (LOO) = 0,65
M3 44 parcelas (com 10 parcelas não-mangue) (com buffer de 5 m)	RMSE(CAL) = 11,32 RMSE(LOO) = 14,40 R ² (CAL) = 0,96 R ² (LOO) = 0,94	RMSE = 16,79 R ² = 0,92	RMSE(CAL) = 11,90 RMSE (LOO) = 15,00 R ² (CAL) = 0,96 R ² (LOO) = 0,93

De modo geral, os modelos M2 que utilizaram tamanhos maiores das parcelas de campo com a adição de 5 metros de *buffer* nas bordas apresentaram melhores resultados que os modelos M1 com tamanho original das parcelas (Tabela 5.1). Possivelmente esta melhora na estimativa da AGB se deve à inclusão dos retornos LiDAR referentes às árvores maiores com copas próximas ao limite da parcela e que foram computadas nas estimativas de AGB em campo.

O melhor modelo para a estimativa de biomassa de bosques de mangue com distintos graus de alteração foi o M2a, obtido com o método de regressão AutoPLS, com R²(CAL)= 0,89, R²(LOO)=0,80; RMSE(LOO)=14,80 t/ha e RMSE(CAL)=11,20 t/ha. As métricas LiDAR que mais contribuíram para este modelo foram: avg, min, max, d02, d03, d04, d05 e d08. Para o modelo M2b com o método RF obteve-se um R²=0,71 e RMSE=17,90 t/ha. As variáveis de entrada no modelo RF foram avaliadas de acordo com sua importância na estimativa da AGB (Figura B1 no Apêndice B). As 8 variáveis

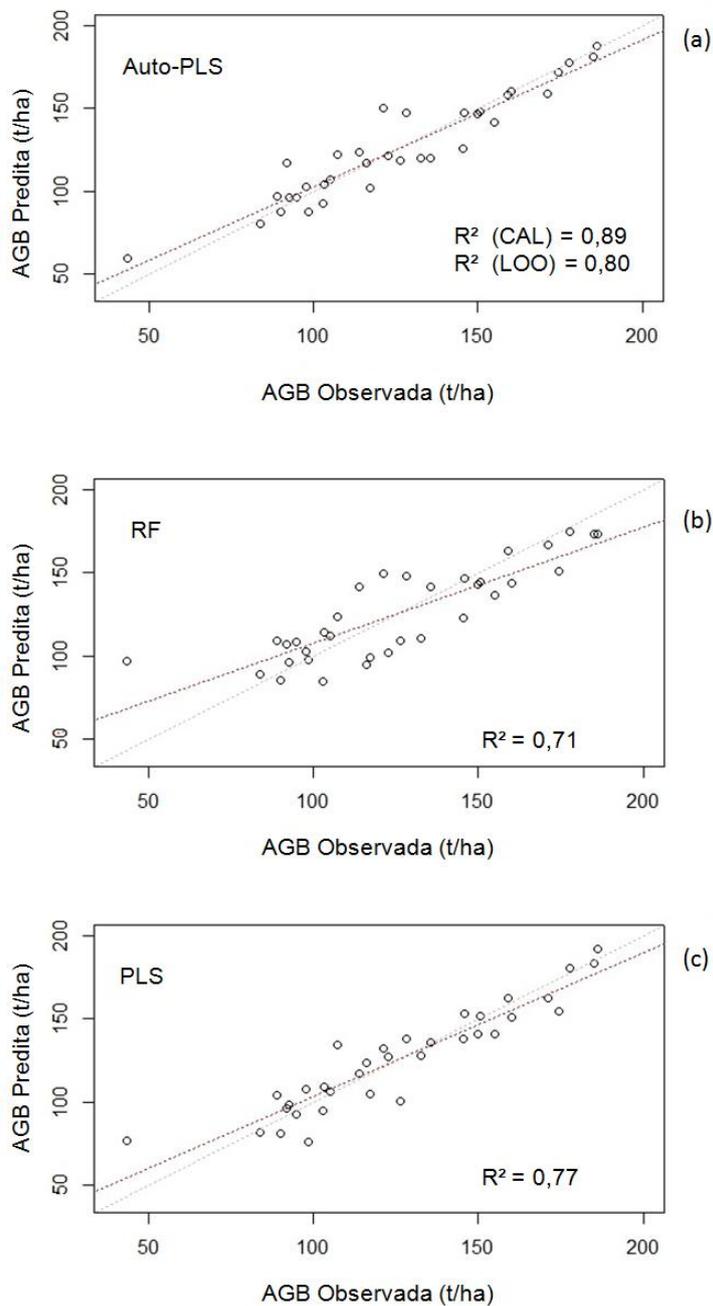
que mais contribuíram para o M2b foram: percentils p99, p50, max, d06, p95, d08, avg e qav. Para o modelo M2c com o método PLS obteve-se um $R^2=0,77$ e $RMSE=16,00$ t/ha. O método de regressão AutoPLS demonstrou ser o mais eficiente para estimar a AGB utilizando métricas LiDAR visto que muitas destas apresentam forte correlação entre si. A correlação entre todas as variáveis LiDAR utilizadas nos modelos M2 é apresentada na Figura 5.2. A Figura 5.3 mostra os diagramas de dispersão entre os valores de AGB preditos pelos modelos M2a (AutoPLS), M2b (RF) e M2c (PLS) *versus* os valores observados. Observa-se que o modelo M2a apresentou o melhor ajuste. O modelo M2ssp resultante da adição de informações sobre as espécies dominantes de cada parcela não apresentou melhoria na sua acurácia quando comparado ao modelo M2a. Apesar de haver diferença entre as densidades de madeira das espécies dominantes *Avicennia schaueriana*=0,68 g/cm³ (ESTRADA et al., 2014), *Laguncularia racemosa*=0,62 g/cm³, *Rhizophora mangle* =0,89 g/cm³ (ZANNE et al., 2009), a adição destas informações não foi suficiente para melhorar o desempenho do modelo, talvez porque as espécies diferentes podem alterar a estrutura da vegetação e esta diferença pode ter sido incorporada no modelo M2.

Figura 5.2 - Correlação entre as variáveis LiDAR.



Correlação entre as variáveis LiDAR utilizadas nos modelos de regressão M2 (34 parcelas com *buffer* de 5 metros) para estimativa da AGB. Os círculos maiores indicam maior correlação entre as variáveis e as cores indicam correlação negativa (vermelho) e positiva (azul).

Figura 5.3 - Diagramas de dispersão do valor da biomassa (AGB) predita *versus* observada.



Diagramas de dispersão do valor da biomassa (AGB) predita *versus* a biomassa de referência observada nas 34 parcelas de campo, para os modelos (a) M2a (AutoPLS), (b) M2b (Random Forest) e (c) M2c (PLS).

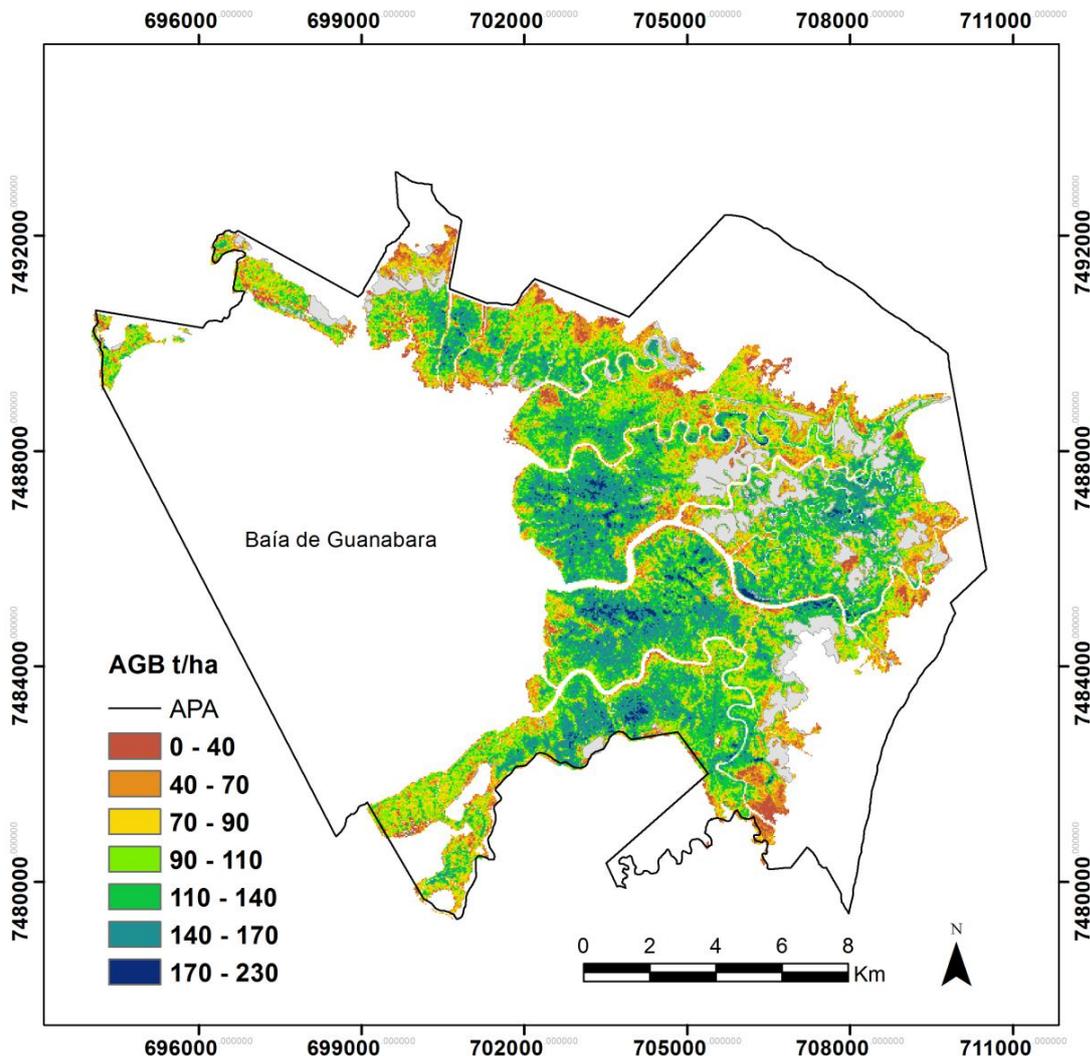
O mapa da AGB do manguezal da APA de Guapimirim foi obtido a partir do melhor modelo gerado M2a (Figura 5.4). O mapeamento apresentou contabilizou 561.374,0 toneladas de AGB de mangue para uma área de 5.432,0 hectares de floresta de mangue,

o que equivale a uma AGB média de 103,40 t/ha. As áreas com maiores valores de AGB (verde escuro na Figura 5.4) estão localizadas principalmente no interior dos bosques, dentro da ESEC da Guanabara e próximo à Baía de Guanabara. As áreas com menores valores de AGB localizam-se mais próximas da montante dos rios em direção à estrada (lado direito do mapa na Figura 5.4), que são regiões mais impactadas por desmatamentos e próximas de áreas urbanas. As áreas com valores de AGB próximos de zero (tons avermelhados na Figura 5.4) são bosques de mangue mais alterados com solo exposto, clareiras, vegetação rasteira não-mangue ou predomínio de *Acrostichum* entre os bosques de mangue. As áreas referentes somente à classe "espécie associada" do mapeamento de Arasato et al. (2015) mostrado na Figura 3.4 foram mascaradas em cor cinza claro na Figura 5.4 e não foram incluídas na modelagem da AGB do mangue pois representam áreas degradadas sem a presença de espécies de mangue.

A equação do modelo M2a gerado pode ser vista na Equação 5.1. Ressalta-se que os parâmetros deste modelo são relativos ao presente caso de estudo, pois com diferentes parâmetros de aquisição de dados LiDAR e AGB provavelmente será obtida uma outra equação do modelo de predição. As estatísticas de avaliação das variáveis do modelo são encontradas na Tabela B1 do Apêndice B.

$$AGB = 168,49 + 8,67*avg -9,01*d02 + 13,77*d03 -8,39*d04 + 8,86*d05 + 9,10*d08 + 14,21*max -8,31*min \quad \text{Equação 5.1}$$

Figura 5.4 - Mapa de AGB (t/ha) do manguezal da APA de Guapimirim.



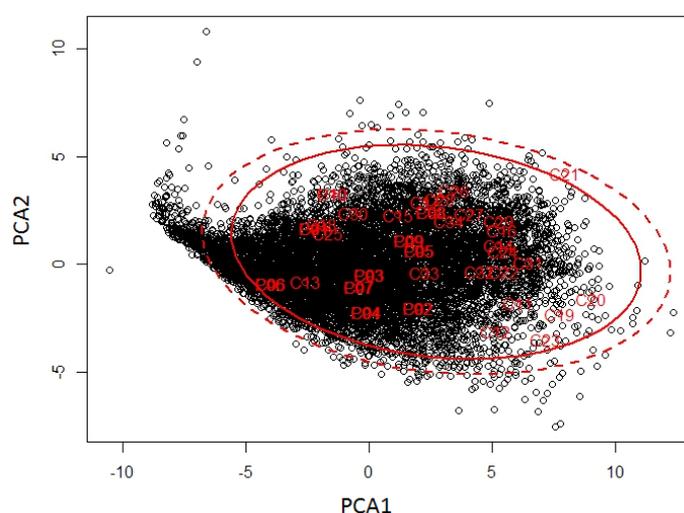
Mapa de AGB em toneladas por hectare (t/ha) do manguezal da APA de Guapimirim utilizando o modelo M2a (AutoPLS). Em cinza claro estão indicadas as áreas degradadas sem presença de espécies de mangue e não incluídas na estimativa da AGB do manguezal.

5.1.1 Avaliação da cobertura amostral das métricas Lidar

Com objetivo de avaliar a cobertura amostral capturada pelas métricas LiDAR referentes às 34 parcelas foi aplicado o método anteriormente utilizado por Fekety et al. (2015) e White et al. (2013), onde a cobertura amostral das parcelas foi avaliada graficamente. A Figura 5.5 mostra o intervalo de variabilidade estrutural da floresta de mangue capturada pelas métricas LiDAR na escala da paisagem indicado em preto (10.000 pixels aleatoriamente selecionados como amostras de floresta de mangue) e em

vermelho observa-se a variabilidade estrutural capturada pelas métricas LiDAR referentes às 34 parcelas de campo (com mais 5 metros de *buffer*). A proporção de variância acumulada para o conjunto das métricas LiDAR para a área de floresta de mangue foi de 64% para PCA1+PCA2. Pode-se observar que as métricas LiDAR referentes às 34 parcelas cobrem quase toda a extensão da variabilidade estrutural apresentada na floresta de mangue da área de estudo, como capturado pelo primeiro plano da PCA. Para 95% de confiança a elipse sólida cobre 88% dos pixels. Para 98% de confiança a elipse pontilhada cobre 96% dos pixels da área de mangue.

Figura 5.5 – Distribuição das PCA1 e PCA2 das métricas LiDAR.

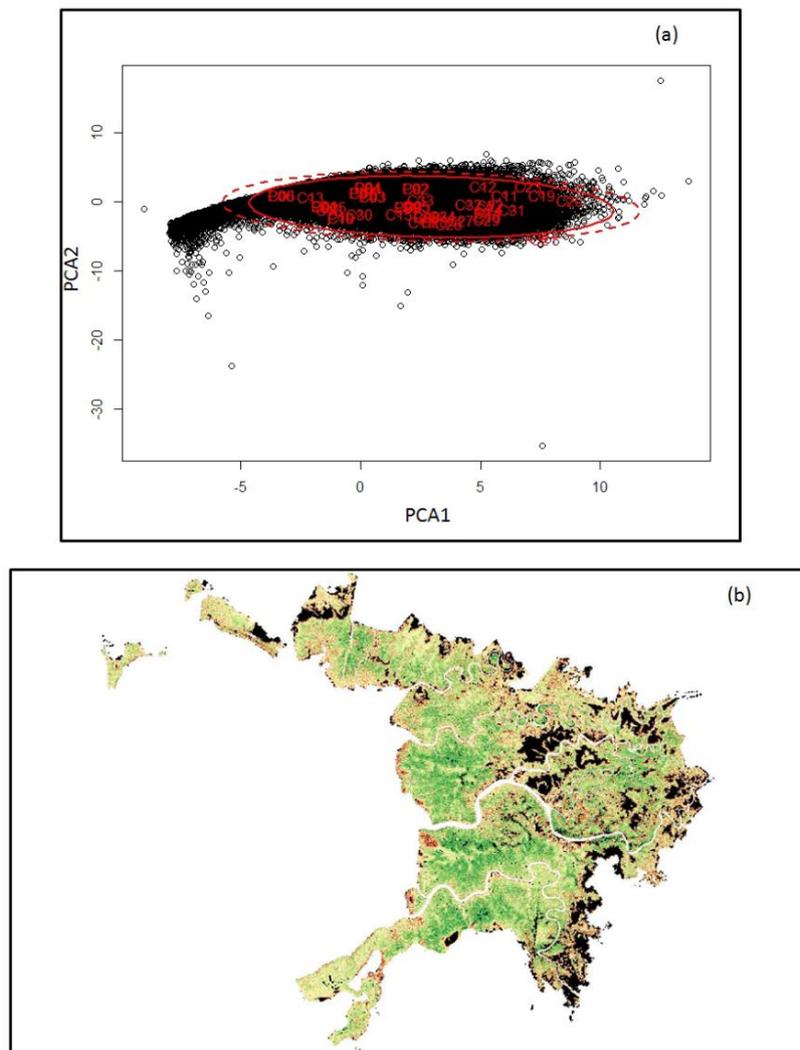


Distribuição das PCA1 e PCA2 das métricas LiDAR referentes às 34 parcelas de campo (em vermelho) sobre o espaço do Plano PCA1 *versus* PCA2 obtido com o conjunto de métricas LiDAR para a área de floresta de mangue. Elipses representam os intervalos de confiança de 98% (linha pontilhada) e 95% (linha sólida).

A distribuição das parcelas no plano do espaço formado pela PCA1 *versus* PCA2 obtidas com o conjunto de métricas LiDAR para toda a área do manguezal, neste caso incluindo vegetação não-mangue e solo exposto, é mostrado na Figura 5.6a. A Figura 5.6b destaca as áreas (pixels em preto) que estão fora da elipse do intervalo de 95% de confiança. A partir do conhecimento de campo, pode-se observar que estes são pixels localizados em áreas de solo exposto e domínio de vegetação de outras espécies principalmente áreas dominadas por *Acrostichum* e *Hibiscus*. Os resultados mostrados

pelas Figura 5.6a e b indicam que os dados LiDAR referentes às 34 parcelas contemplam a variabilidade estrutural da floresta de mangue e que os pixels fora da elipse de 95% de confiança não fazem parte da floresta de mangue. Este bom resultado indicando que os dados LiDAR referentes às 34 parcelas contemplam a variabilidade estrutural reflete positivamente na modelagem da AGB de bosques de mangue, o que pode ser comprovado pelo bom desempenho do modelo M2a.

Figura 5.6 –Distribuição das PCA1 e PCA2 das métricas LiDAR para todo o manguezal.



(a) Distribuição das PCA1 e PCA2 das métricas LiDAR referentes às parcelas de campo (em vermelho) sobre o espaço do plano PCA1 *versus* PCA2 obtido com o conjunto de métricas LiDAR para a área total de manguezal da APA de Guapimirim (incluindo vegetação não-mangue e solo exposto). Elipses representam os intervalos de confiança de 98% (linha tracejada) e 95% (linha sólida). (b) Representação do modelo de altura do dossel (CHM) obtido com dados LiDAR. Áreas em preto correspondem a classes de não-mangue onde se localizaram os pixels fora do intervalo de confiança.

5.1.2 Avaliação da incerteza na escala da paisagem

O estimador de regressão geral da população da AGB média e sua variância (para a escala da paisagem) foram obtidos através das equações baseadas no método de inferência *design-based* descrito em Gregoire et al. (2016). O método de reamostragem aleatória que ajusta o modelo repetitivamente para uma amostragem de 17 parcelas também foi utilizado para avaliar as incertezas. A Tabela 5.2 apresenta os valores de AGB média estimados e as incertezas (desvio padrão) em termos de AGB média t/ha para a escala da paisagem (AGB acumulada) para os dois métodos de avaliação utilizados. A estimativa da AGB média obtida pelo método de reamostragem foi maior do que a estimativa obtida pelo método de inferência *design-based*.

Tabela 5.2 - AGB média (t/ha) e desvio padrão do erro na escala da paisagem utilizando um estimador de regressão de inferência *design-based* e técnica de reamostragem.

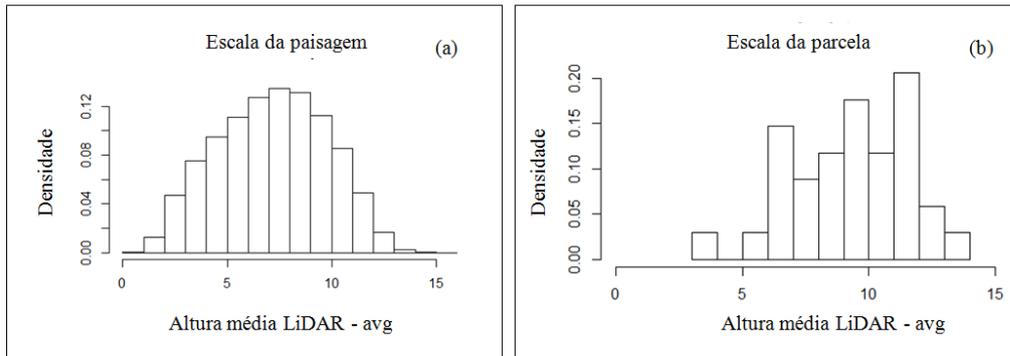
Modelo	AGB média (<i>design-based</i>)	Desvio padrão (<i>design-based</i>)	AGB média (reamostragem)	Desvio padrão (reamostragem)
M2a (AutoPLS)	103,8	2,5	106,6	6,9

O erro estimado da predição da AGB na escala de paisagem utilizando o estimador de regressão geral de inferência *design-based* foi de 2,5% (Tabela 5.2). No entanto a incerteza estimada pelo estimador de regressão geral de inferência *design-based* pode estar ligeiramente subestimada. Praticamente qualquer tendência no modelo na escala de parcela se traduzirá em um erro na escala de paisagem que não é contabilizado pelo estimador de regressão geral. A abordagem de reamostragem fornece uma estimativa da biomassa média na escala de paisagem um pouco maior (106,6 *versus* 103,8 t/ha) e com maior desvio padrão (6,9% *versus* 2,5%) do que com o estimador de regressão geral. Uma única parcela (C25) pode ser a responsável pela maior parte da diferença entre as duas estimativas. De fato, a parcela C25 que possui o menor valor de AGB é responsável pela ligeira tendência aparente no modelo na escala da parcela (Figura 5.3) visto que a AGB desta parcela é superestimada por todos os modelos, embora para o modelo M2a um pouco menos. Observa-se com a técnica de reamostragem que as predições obtidas são sensíveis à influência desta observação (C25) em particular. De fato, a predição média dos 100 subconjuntos aleatórios que incluem a parcela C25 é

103,1 t/ha (desvio padrão = 7,9), enquanto que a média dos 100 subconjuntos aleatórios sem a C25 é 110,1 t/ha (desvio padrão = 2,8).

Apesar da boa cobertura amostral (Figura 5.5) e da amostragem balanceada entre as classes de altura de vegetação, a sub-representação de mangue com menor estatura (Figura 5.7) pode provavelmente ter prejudicado a acurácia da estimativa na escala da paisagem. Neste sentido, o uso de informações obtidas com dados LiDAR pode ser útil como orientação prévia à definição de parcelas durante campanha de campo. A disponibilização de um mapa da altura do dossel para orientar a campanha de campo poderia ter contribuído para uma verificação estrutural preliminar mais precisa do manguezal, permitindo assim a inclusão na cobertura amostral de maior número de bosques jovens e/ou estruturalmente menos desenvolvidos (como os bosque de bacia), mesmo que este tipo fisiográfico de bacia e bosques mais jovens não sejam encontrados com muita frequência no manguezal da APA de Guapimirim, que se caracteriza mais por apresentar bosques maduros do tipo franja. Semelhante precaução provavelmente teria reduzido as incertezas da AGB na escala da paisagem. A amostragem de campo visa capturar o conjunto das possíveis variações estruturais encontradas na área de estudo. Para obter uma boa relação entre as variáveis LiDAR e a estrutura florestal exige-se uma amostragem representativa da diversidade de condições estruturais (ASNER et al., 2012). Embora sendo pequenas, o tamanho das parcelas de campo utilizadas não comprometeu o desempenho dos modelos M2. Ao se estender a borda dos polígonos (perímetro) representativos das parcelas de onde as estatísticas LiDAR foram derivadas melhorou-se a previsão. Isto sugere que parcelas de campo e polígonos representativos menores do que os utilizados devem provavelmente ser evitadas, principalmente para manguezais estruturalmente mais desenvolvidos do que os encontrados na APA de Guapimirim.

Figura 5.7 - Distribuição da altura média LiDAR.



(a) Densidade da altura média LiDAR (avg) para a escala da paisagem, e (b) Densidade da altura média LiDAR (avg) para as parcelas amostrais (34), altura média LiDAR em metros.

5.1.3 Discussão do desempenho da estimativa da AGB com dados LiDAR

Para os modelos preditivos M2a e M2b as variáveis altura máxima (max), altura mínima (min) e altura média (avg) foram variáveis influentes na estimativa de AGB. As variáveis referentes às métricas de densidade de pontos (d02, d03, d04, d05, d08) também foram as variáveis preditoras que mais contribuíram para o modelo M2a, demonstrando influência na detecção da variabilidade estrutural em floresta de mangue com distintos graus de alteração. Segundo Næsset (2002) a taxa de penetração do pulso LiDAR é maior em áreas florestais decadentes (baixa qualidade) do que em florestas saudáveis. Métricas de densidade de pontos foram utilizadas no trabalho de Vega et al. (2016) para a predição da distribuição vertical da altura florestal. No trabalho de Hansen et al. (2015), para a estimativa de AGB em floresta tropical úmida, as variáveis de densidade do dossel apresentaram melhores resultados do que as variáveis da altura do dossel, como no presente estudo. Para Næsset e Gobakken (2008) as variáveis relacionadas à altura do dossel e densidade de dossel (similar à densidade de pontos) foram as melhores variáveis independentes para estimar a biomassa de floresta boreal. Como frisado anteriormente, o modelo M2a apresentou o melhor desempenho com $R^2(\text{CAL})=0,89$, $R^2(\text{LOO})=0,80$, $\text{RMSE}(\text{LOO})=14,70$ t/ha e $\text{RMSE}(\text{CAL})=11,20$ e foi utilizado para gerar o mapa de biomassa do manguezal da APA de Guapimirim (Figura

5.4). Este modelo M2a apresentou boa acurácia para a estimativa de biomassa de bosques de mangue da APA de Guapimirim quando comparado com os resultados de estimativa de biomassa com uso de dados LiDAR de pontos de retorno discreto obtidos para outros tipos de florestas, como por exemplo: Asner et al. (2009) com $R^2=0,78$; D'Oliveira et al. (2012) com $R^2=0,72$, $RMSE=40,20$ t/ha e $RSE%=17,40$; Mascaro et al. (2011) com $R^2=0,85$, $RMSE=35,40$ t/ha e $RSE%=17,60$; Næsset (2011) R^2 entre 0,80-0,83, $RMSE = \sim 8,9$ t/ha e $RSE% = \sim 25\%$.

Zolkos et al. (2013) analisaram e compararam a acurácia obtida para a estimativa de biomassa terrestre em mais de 70 trabalhos que utilizaram diferentes técnicas e dados de sensoriamento remoto. Destes estudos, os baseados em LiDAR de retorno discreto e LiDAR de retorno contínuo obtiveram R^2 médio de 0,76 e 0,80, respectivamente e um erro padrão residual (RSE) médio de 39,40 t/ha para DRL e 50,20 t/ha para FRL (o valor de RSE pode ser comparado com RMSE do presente estudo). O valor médio do erro padrão residual relativo (RSE%) que é calculado com o RSE padronizado pela média da AGB de campo foi de $RSE%=27,0\%$ e $22,3\%$ para DRL e FRL, respectivamente (ZOLKOS et al., 2013). No presente estudo o modelo M2a apresentou RSE% igual a 8,9%, valor inferior à média para os estudos com DRL, indicando um ótimo resultado. O RSE refere-se ao erro absoluto do modelo, enquanto RSE% expressa a performance do modelo em relação à média da biomassa obtida em campo. Como visto, o modelo M2a apresentou acurada estimativa da AGB, com menor RMSE(LOO) (14,70 t/ha) do que o RSE médio (39,40 t/ha) dos estudos utilizando DRL, e com $RSE% = 8,9\%$ que é menor que o limiar de 20% (Figura 2.7). Este limiar de 20% ou ± 20 t/ha é considerado a acurácia requerida nas missões de mapeamento da biomassa florestal global para no mínimo 80% das células do *grid* (ZOLKOS et al., 2013). Comparado com os trabalhos que utilizaram LiDAR de retorno discreto apresentados por Zolkos et al. (2013), o presente modelo M2a apresentou resultados melhores do que os obtidos para floresta temperada em Balzter et al. (2007), utilizando parcelas de campo de 0,04 ha, com $RSE=71,20$ t/ha; em Banskota et al. (2011), com $R^2=0,64$ e $RSE=28,5$ t/ha; em Hawbaker et al. (2009) para floresta de coníferas, com parcelas de 0,09 ha, $R^2=0,75$ e $RSE=45,60$ t/ha; em Hawbaker et al. (2009) para floresta decídua $R^2=0,71$ e $RSE=39,30$ t/ha; em Li et al. (2008) para floresta de coníferas com parcelas de 0,25 ha e

$R^2=0,76$; para floresta boreal em Boudreau et al. (2008) com parcelas de 0,04 ha, $R^2=0,65$ e $RSE=25,50$ t/ha; em Næsset (2002) com parcelas de 0,02 ha, $R^2=0,77$ e $RSE=8,00$ t/ha; em Nelson et al. (2012), com parcelas de 0,03 ha, $R^2=0,54$ e $RSE=32,30$ t/ha; para floresta tropical em D'Oliveira et al. (2012) $R^2=0,72$, $RSE=40,20$ t/ha, $RSE\%=17,40\%$; em Kennaway et al. (2008) com parcelas de 0,07 ha, $R^2=0,36$ e $RSE=22,8$ t/ha. Comparado, porém, com outros estudos, o presente resultado foi inferior, como por exemplo para floresta tropical em Clark et al. (2011) com parcelas de 0,06 ha, $R^2=0,90$ e $RSE=38,30$ t/ha; em Lucas et al. (2008) com parcelas de 0,25 ha e $R^2=0,90$; em Mascaro et al. (2011) com parcelas de 0,31 ha, $R^2=0,85$ e $RSE=35,40$ t/ha; para floresta temperada em Lim e Treitz (2004) com parcelas de 0,04 ha, $R^2=0,90$ e $RSE=50,20$ t/ha; em Nelson et al. (2007) com $R^2=0,93$ e $RSE=33,90$ t/ha; para floresta boreal em Nystrom et al. (2012) com parcelas de 0,03 ha, $R^2=0,99$ e $RSE=2,80$ t/ha.

As diferenças nas performances de modelos de estimativa de biomassa, como por exemplo os apresentados em Zolkos et al. (2013), são influenciadas por vários fatores como o tipo de floresta a ser estimada, o impacto da topografia na estrutura do bosque florestal e tamanho das parcelas de campo. Os manguezais estão localizados em áreas com topografia quase plana e assim não apresentam muita influência da topografia nas estimativas de AGB (VÉGA et al., 2016). Já em áreas florestais com declives acentuados, a subtração dos valores de DTM do DSM referentes ao dossel florestal pode causar erros na geometria da nuvem de pontos (VÉGA et al., 2016). Estudos anteriores apresentaram relação entre a acurácia dos modelos e o tamanho das parcelas de campo (FRAZER et al., 2011; ZOLKOS et al., 2013). Outras fontes de erros também podem influenciar a relação entre dados LiDAR e a biomassa estimada em campo, como erros no posicionamento GPS, diferenças temporais entre os dados LiDAR e os dados de campo, e discordância entre as medições LiDAR e das parcelas de campo a respeito de quais árvores ou partes de árvores estão dentro das parcelas de calibração (MASCARO et al., 2011; MONTESANO et al., 2013; STEPHENS et al., 2012; VÉGA et al., 2016; ZOLKOS et al., 2013). Como observado anteriormente, os modelos M2 apresentaram desempenho melhor que os modelos M1. A adição, nos modelos M2, de um *buffer* de 5 metros ao redor do polígono representativo de cada parcela de campo,

foi realizada para incluir nestes polígonos todas as copas das árvores contidas nas parcelas, eliminando-se assim uma fonte de erro presente nos modelos M1.

Asner et al. (2010) observaram que as incertezas do mapeamento de carbono florestal com resolução de 0,1 ha diminuíram com a integração deste resultado para uma resolução de 5 ha. Mascaro et al. (2011) indicam que a acurácia de modelos preditivos da densidade de carbono florestal com uso de dados LiDAR aumenta com o decréscimo da resolução espacial. Segundo esses autores, ao se diminuir a resolução de análise de 0,04 ha para 6,25 ha, diminuiu-se o erro RMSE de 63,20 para 6,50 tC/ha. Estes autores também demonstraram que a predição da densidade de carbono florestal com uso do MCH do LiDAR, principalmente para a resolução espacial maior do MCH, foi mais acurada quando se utilizou, para calibração do modelo, o dado de campo referente à medida de densidade de carbono obtida com a distribuição da copa das árvores do que com a medida de densidade de carbono obtida com a localização dos troncos. No presente trabalho buscou-se extrair as métricas LiDAR da nuvem de pontos e gerar o mapa de AGB (pixel de 25 x 25 m) com resolução espacial compatível com o tamanho das parcelas amostrais de campo e com tamanho um pouco maior (5 metros nas bordas).

De acordo com Kennaway et al. (2008), o uso de dados LiDAR de retorno discreto com baixa resolução (~2,76 m de espaçamento entre cada ponto) e com isto a extração e utilização de variáveis da altura do dossel LiDAR com resolução de 30 m, não permitiram obter informações dos estratos florestais com boa acurácia. Naquele trabalho a estimativa da AGB de variados tipos de cobertura florestal em uma ilha no Caribe apresentou baixo valor para o $R^2=0,36$ e alto $RMSE=22,80$ t/ha. Porém, a estimativa da altura média das árvores dominantes e co-dominantes foi mais efetiva ($R^2=0,73$ e $RMSE=0,78$ m) no modelo que incluiu a variável ambiental precipitação além das variáveis preditoras LiDAR. No presente estudo a densidade de pontos LiDAR é de ~5 pontos m^{-2} o que permitiu a extração das métricas LiDAR referentes à altura dos bosques de mangue com mais exatidão contribuindo na acurácia da estimativa da AGB. Lucas et al. (2008) analisaram o uso de dados LiDAR para estimar a AGB de floresta mista com diferentes estados de degradação e regeneração na Austrália. A estimativa da AGB ao nível da parcela utilizando métricas LiDAR de estratos da altura e cobertura da copa apresentou o melhor resultado com $R^2=0,90$ e $RSE=11,80$ t/ha. Enquanto a

estimativa de AGB específica obtida com as variáveis de entrada “altura derivada do LiDAR” e “diâmetro do tronco” como entradas na equação da AGB específica de cada espécie e posteriormente somadas para o nível de parcela foi menos promissora com $R^2 = 0,56$ e $RSE = 25,3$ t/ha. A abordagem desses autores mostrou a eficácia da utilização de variáveis preditoras como os estratos da altura LiDAR em modelos de estimativa da AGB florestal ao nível da parcela, como no presente estudo.

A integração de informações de dados LiDAR com dados ópticos hiperespectrais foi averiguada para a modelagem da AGB de floresta tropical na Costa Rica (CLARK et al., 2011). O melhor resultado da estimativa da AGB ($R^2 = 0,90$ e $RMSE = 38,3$ t/ha) foi obtido utilizando as métricas LiDAR “altura média” e “altura máxima” como variáveis preditoras. As estimativas utilizando somente parâmetros hiperespectrais apresentaram baixa acurácia, bem como as estimativas com o uso conjunto de dados LiDAR e hiperespectrais. Estes trabalhos demonstram a eficácia de utilização das métricas LiDAR de retorno discreto para a estimativa de AGB com maior acurácia.

A utilização de variáveis preditoras que descrevem a distribuição vertical da altura dos pontos LiDAR tem sido efetiva em modelos de estimativa de AGB florestal. Véga et al. (2015) utilizaram as métricas percentil 0, percentil 99 e densidade de pontos médios, obtidos com uso de dados LiDAR de retorno discreto, obtendo $R^2_{adj} = 0,90$; $RMSE = 48,4$ t/ha e $RSE\% = 10,9$ para o melhor modelo de estimativa de biomassa de floresta tropical na Índia. No entanto, quando foram adicionadas informações da variabilidade horizontal do dossel florestal, por meio de métricas obtidas com o método FOTO e índices referentes à complexidade do terreno, o modelo final foi melhorado ($R^2_{adj} = 0,96$; $RMSE = 28,8$ t/ha e $RSE\% = 6,5$). Utilizando como variáveis preditoras o coeficiente de variação dos últimos retornos (CV1), as métricas de densidade (d40), a complexidade média do declive do terreno (TCIm) e a terceira componente principal do método FOTO aplicado sobre o modelo digital de superfície, os autores demonstraram que a variabilidade da AGB foi melhor capturada pela combinação das variáveis que descrevem a estrutura vertical e horizontal (VÉGA et al., 2015). No presente estudo, as variáveis preditoras do melhor modelo também descrevem a variabilidade vertical da altura do dossel (min, max, avg, d02, d03, d04, d05, d08). Mas não foram utilizadas variáveis que descrevem a topografia, visto que os manguezais não se localizam em

terrenos com alta declividade. No presente estudo o tamanho das parcelas de campo foi menor ($\sim 1/4$) porém em maior quantidade ($\sim 2x$) do que as utilizadas por Vége et al. (2015), o que pode ter contribuído para a acurácia na modelagem aqui obtida.

A acurácia nas estimativas de AGB é influenciada por vários fatores, como o tipo florestal, tamanho das parcelas de campo, tipo de dado de sensoriamento remoto e resolução espacial, variáveis preditoras utilizadas na modelagem, dentre outros. Com uso de dados LiDAR, Hansen et al. (2015) estimaram a AGB de floresta tropical submontana na Tanzânia em um terreno íngreme com $R^2 = 0,70$, $RMSE = 149,2$ t/ha e $RSE\% = 32,3$ no melhor caso utilizando apenas as variáveis LiDAR, com maior influência das variáveis de densidade de pontos. Ao adicionar variáveis relativas a informações texturais obtidas com o GLCM, os autores não observaram melhora no desempenho dos modelos preditivos. No estudo de Hansen et al. (2015) as parcelas de campo foram relativamente menores ($639 - 1.239$ m²) do que as utilizadas por Vega et al. (2015) (15 parcelas de 1 ha). No presente estudo as parcelas variam de 121 a 560 m², portanto menores do que nos trabalhos anteriores. Entretanto, a acurácia do modelo obtido no presente estudo foi boa.

As variáveis de densidade de pontos foram importantes no presente estudo para a estimativa de AGB de mangue com distintos graus de alteração, demonstrando que estas variáveis podem contribuir para o reconhecimento de áreas degradadas em florestas. Em D'Oliveira et al. (2012) a estimativa de biomassa e detecção de áreas degradadas e não degradadas da floresta tropical da Amazônia foi efetuada com dados LiDAR de retorno discreto. As áreas impactadas por exploração madeireira foram identificadas e quantificadas pelas variáveis referentes à densidade de pontos dos estratos florestais, e para a estimativa de AGB o melhor modelo utilizou as variáveis preditoras p25 (1º quartil da altura dos pontos) e variância da altura acima do solo (VAR) obtendo $R^2 = 0,72$; $RMSE = 40,2$ t/ha e $RSE\% = 17,4$.

As áreas florestadas dos manguezais são alagadas diariamente na sua maior parte. Desta forma, a presença de água cobrindo o solo pode afetar as informações obtidas com dados LiDAR no infravermelho próximo, pois a umidade diminui a reflectância nesta faixa espectral. Outro problema ocorre devido à reflexão do pulso LiDAR acima da

altura original do terreno quando este é coberto por água e sedimentos. Este comportamento pode causar sobrestimativa dos valores do modelo digital do terreno (DTM). Esta situação, durante a geração do modelo digital do dossel, pode acarretar a subestimativa do dossel florestal. No trabalho de Chadwick (2011), os valores de elevação referentes ao terreno abaixo de dosséis florestais alagados não indicaram a verdadeira altitude do terreno. Naquele estudo, para dosséis de mangue vermelho (*Rhizophora*) que estavam nestas condições de solo alagado, o valor do DTM gerado foi superestimado. Isto sugeriu que o último retorno obtido não foi proveniente do solo submerso nem da água, mas de raízes aéreas ou copas mais baixas. Isto acarretou a subestimativa dos valores de altura do mangue vermelho no CHM (CHADWICK, 2011). No presente estudo, as classificações dos pontos pertencentes ao terreno foram refinadas por inspeção visual e técnica de reclassificação de forma a garantir que pontos acima do nível do solo não fossem incluídos no modelo digital de terreno.

O número de trabalhos utilizando dados LiDAR de retorno discreto para a estimativa da AGB de manguezais ainda é bastante limitado se comparado a outros tipos florestais, o que de certa forma dificulta uma confrontação sistemática de métodos e resultados. Mesmo assim é possível afirmar que a abordagem metodológica aplicada no presente estudo com uso das métricas LiDAR mostrou ser eficaz para estimar a AGB de bosques com distintos graus de alteração para uma extensa área de manguezal. Este estudo é um dos primeiros trabalhos a utilizar este tipo de abordagem metodológica para estimar AGB de bosques de mangue de que se tem conhecimento. Parte dos trabalhos encontrados na literatura que utilizam os dados LiDAR para estimar a AGB de mangue utilizaram dados do tipo *waveform* (FATOYINBO; SIMARD, 2013; FATOYINBO et al., 2008; SIMARD et al., 2006; 2008). Os trabalhos que utilizaram dados LiDAR de retorno discreto empregaram o modelo de altura do dossel como base para a estimativa da altura florestal e da AGB (ABREU, 2014; ARASATO et al., 2015; GALVINCIO; POPESCU, 2016; LAGOMASINO et al., 2016; WANNASIRI et al., 2013).

No mapeamento da biomassa do manguezal de Ciénaga Grande de Santa Marta, Colômbia, efetuado por Simard et al. (2008), foram utilizados dados LiDAR *waveform* (ICESat/GLAS) para calibrar dados de elevação do SRTM. Naquele trabalho foi utilizado o centróide da contribuição do *canopy waveform* (CWC) como o melhor

estimador da altura, e estas informações foram relacionadas linearmente com dados de elevação do SRTM. O resultado da estimativa da altura apresentou um $RMS = 2,6$ m e $R^2 = 0,85$. A partir desta altura foi estimada e mapeada a AGB do manguezal. Uma das vantagens daquele método foi a possibilidade de mapear a biomassa de manguezais em extensas áreas (> 30.000 ha) com dados disponibilizados gratuitamente. Por outro lado, o método apresentou muitas incertezas, desde a calibração do dado SRTM com dados LiDAR e dados de campo até a modelagem final da biomassa. O uso de dados LiDAR de retorno discreto, como no presente estudo, apresentou resultados mais precisos e com melhor resolução espacial para a estimativa da biomassa.

Na abordagem de Zhang et al. (2006) foi estimada a distribuição da altura referente à nuvem de pontos LiDAR (sistema Optech ALTM 1233) da área de manguezal da Baía Biscayne, Florida. A partir de intervalos do histograma de frequência da altura, os pontos foram classificados utilizando métodos de agrupamento (K-médias) para vários tipos de floresta de mangue de acordo com a altura, tais como: bosque-anão (0-2m), transicional (2-4m), interior (4-8m) e costeira (>8 m). As informações foram espacializadas formando um mapa de tipos de mangue. De acordo com esses autores, o uso de histograma de frequência da altura preserva mais a estrutura tridimensional da floresta em comparação com modelos digitais do dossel. Porém, as informações LiDAR subestimaram a altura das árvores devido à baixa densidade de pontos (pontos espaçados a cada 1,5 m) e penetração dos pontos no dossel florestal. No presente estudo o modelo M2a (AutoPLS) de melhor desempenho apresentou valores de biomassa preditos (média de 125,9 t/ha e desvio padrão de 31,9 t/ha) muito próximos dos valores obtidos em campo (média 125,7 t/ha e desvio padrão de 33,7 t/ha). A Figura 5.3 referente aos valores preditos de AGB pelo M2a *versus* a AGB estimada em campo mostra um bom ajuste sem muitas tendências. Apenas na parcela C25 observa-se que o modelo superestima o valor de AGB. O bosque em C25 apresenta os menores valores de AGB e características estruturais de bosque de bacia se distinguindo dos demais bosques típicos da franja. As características do sistema LiDAR, como por exemplo a densidade de pontos por metro quadrado, influenciam diretamente a estimativa de AGB, seja pela abordagem das métricas LiDAR ou com uso de modelos de altura do dossel. No presente estudo, o sistema LiDAR utilizado, que é de ~ 5 pulsos/m², possibilitou a

estimativa da AGB com um bom ajuste do modelo. Chadwick (2011) utilizou dados LiDAR de retorno discreto com menor resolução para gerar o modelo digital do terreno e o modelo digital do dossel da área do manguezal de Greater Everglades, Flórida. As alturas obtidas com o modelo digital do dossel foram preditores precisos da altura do dossel medida em campo para os modelos de estimativa com $R^2 = 0,93$ e $R^2 = 0,88$ para mangue vermelho e preto, respectivamente. Porém, de acordo com os autores, os valores de altura do CHM foram sistematicamente subestimados em até 2 metros para os dosséis mais altos, indicando um problema que se deve prever na estimativa destes valores quando obtidos com dados LiDAR. Provavelmente esta subestimativa ocorreu devido à baixa densidade de pontos LiDAR (~ 1 ponto/m²), o que não possibilitou captar com exatidão as copas das árvores mais emergentes.

Os estudos em manguezais do Brasil utilizando dados LiDAR são recentes (ABREU, 2014; ARASATO et al., 2015; GALVINCIO; POPESCU, 2016). Galvncio e Popescu (2016) investigaram o uso de CHM obtido com dados LiDAR de retorno discreto para detectar e estimar a altura de indivíduos arbóreos e diâmetro da copa por meio do algoritmo TreeVaW (POPESCU; WYNNE, 2004) em uma pequena área de mangue em Recife, PE. Foram analisados 583 indivíduos arbóreos. Os autores indicaram que foi possível identificar árvores no CHM como árvores dominantes e co-dominantes. Segundo os autores, a estimativa da altura a partir do CHM com 0,5 m de resolução apresentou melhores resultados do que com 1 m de resolução (onde ocorreram sobrestimativas). O coeficiente de correlação entre a altura dos indivíduos estimada em campo e o CHM (0,5 m) foi de $R = 0,6$ e $RMSE = 2,8$ m.

O trabalho de Abreu (2014) estimou a altura e AGB em uma área de manguezal preservado da Ilha dos Guarás, PA. A altura das árvores do manguezal foi estimada a partir de informações de superfície obtidas de dados LiDAR, SRTM e ortofotos. Com os dados LiDAR de retorno discreto foi obtido o modelo digital da vegetação (MDV) com 1 m de resolução espacial. A relação da altura das árvores medida em campo com a obtida com o MDV resultou em $RMSE = 1,10$ m e $R^2 = 0,94$. Indiretamente foi estimada e mapeada a biomassa do mangue por meio dos dados calibrados referentes à altura-LiDAR ($R^2 = 0,91$, $RMSE = 0,98$ cm) e DAP-LiDAR ($R^2 = 0,74$) e de equações de estimativa de biomassa do manguezal da Guiana Francesa disponíveis na literatura

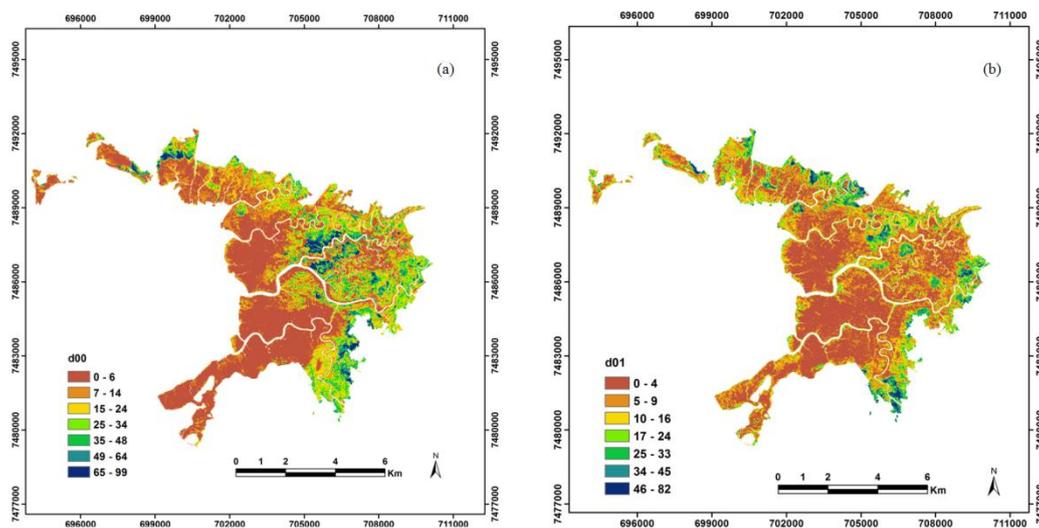
(FROMARD et al., 1998). A autora observa que para os dados LiDAR ocorreu a superestimativa da altura da vegetação em áreas onde o mangue é jovem, e para bosques com indivíduos maduros e dossel alto, ocorreu uma subestimativa da altura. O uso de equações de estimativa de biomassa que não sejam específicas do manguezal de estudo, como no caso daquele trabalho, pode ser mais uma fonte de incertezas na estimativa da AGB com uso de dados de sensoriamento remoto. No presente estudo a AGB das parcelas de campo foram estimadas com uso de equações específicas do manguezal do Rio de Janeiro e sudeste brasileiro (ESTRADA et al., 2014; SOARES et al., 2005). A utilização de equações alométricas específicas da estrutura e das espécies de mangue da área de estudo é fundamental em estimativas de AGB, pois permite que as estimativas obtidas por técnicas de sensoriamento remoto sejam mais confiáveis e condizentes com a AGB do manguezal estudado, reduzindo incertezas na modelagem.

Especificamente para o manguezal da APA de Guapimirim, Arasato et al. (2015) estimaram a AGB por meio do modelo digital de altura do dossel obtido com dados LiDAR de retorno discreto e utilizando medidas da AGB em 16 parcelas de campo. Foi obtido $R^2=0,80$ e não foi reportado o RMSE e outras incertezas do modelo. Naquele estudo e com uso de pares estereoscópicos da imagem WorldView-1, foi obtido um modelo digital de altura do dossel (MDA) com uma correlação alta ($R=0,95$) com o MDA médio obtido com LiDAR. Apesar de pouco relato sobre a acurácia dos modelos de estimativa de AGB apresentados em Arasato et al. (2015), estes resultados apresentam o potencial dos pares estereoscópicos para serem calibrados com os dados LiDAR possibilitando estimativas de AGB em extensas áreas, visto o menor custo dos dados ópticos e a maior eficácia dos dados LiDAR para estimar a altura e AGB florestal.

O presente estudo utilizou uma abordagem metodológica já utilizada para outros tipos florestais, mas que é distinta das abordagens anteriormente aplicadas para estimar a AGB de bosques de mangue. Foram utilizadas métricas estatísticas calculadas a partir da nuvem de pontos LiDAR como variáveis preditoras para a estimativa da AGB de bosques de mangue com distintos graus de alteração. As métricas descritivas obtidas com a altura normalizada dos dados LiDAR e que indicam a densidade de pontos referentes à altura dos estratos dos bosques de mangue de 0,5 - 2,0 m (d00) e de 2,0 -

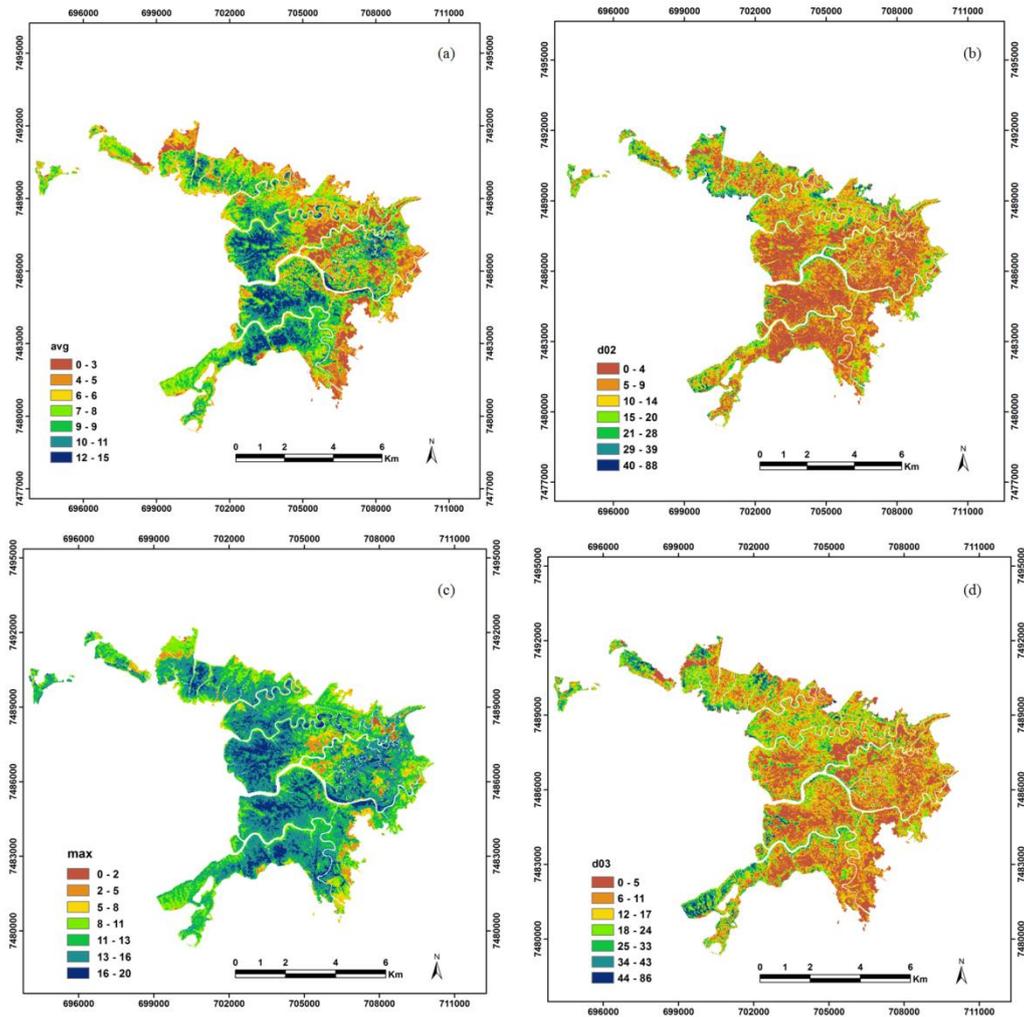
4,0 m (d01), são apresentadas na Figura 5.8. Pode-se observar que as áreas dominadas pela vegetação não-mangue (como a espécie *Acrostichum*) se destacam pela maior densidade de pontos com até 2 m de altura, pois estas áreas possuem poucas ou nenhuma árvore de mangue e esta vegetação invasora é mais baixa em comparação com o mangue maduro. Estas áreas com maior densidade de pontos, principalmente para a variável d00 na Figura 5.8, representam as áreas provavelmente mais alteradas do manguezal. As métricas LiDAR utilizadas como variáveis preditoras na modelagem da AGB com o modelo M2a (Auto-PLS) – avg, min, max, d02 (4,0 - 6,0 m), d03 (6,0 - 8,0 m), d04 (8,0 - 10,0 m), d05 (10,0 - 12,0 m) e d08 (16,0 - 18 m), podem ser observadas nas Figura 5.9 e Figura 5.10. Em d05 (Figura 5.10b) destacam-se os estratos arbóreos dos bosques de mangue mais desenvolvidos. O mapa do CHM (Figura 5.11) pode servir como base de informações para auxiliar trabalhos de campo, análises quantitativas e qualitativas da floresta de mangue, comparações futuras do estado do manguezal, dentre outras finalidades que este produto oferece.

Figura 5.8 - Classes de densidade de pontos LiDAR - d00 e d01.



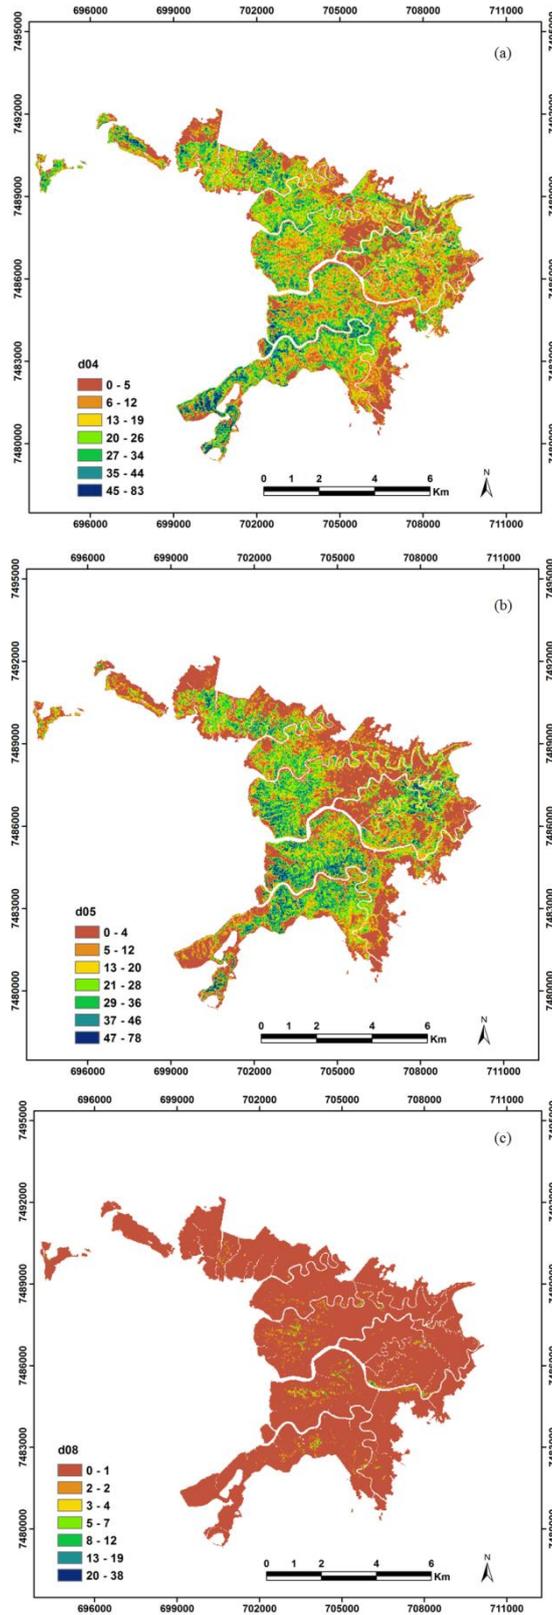
Imagens obtidas com as métricas descritivas LiDAR de densidade de pontos referentes à altura dos estratos dos bosques de mangue da APA de Guapimirim, sendo: (a) d00 (0,5 - 2,0 m), e (b) d01 (2,0 - 4,0 m).

Figura 5.9 - Classes das métricas LiDAR - avg, d02, max e d03.



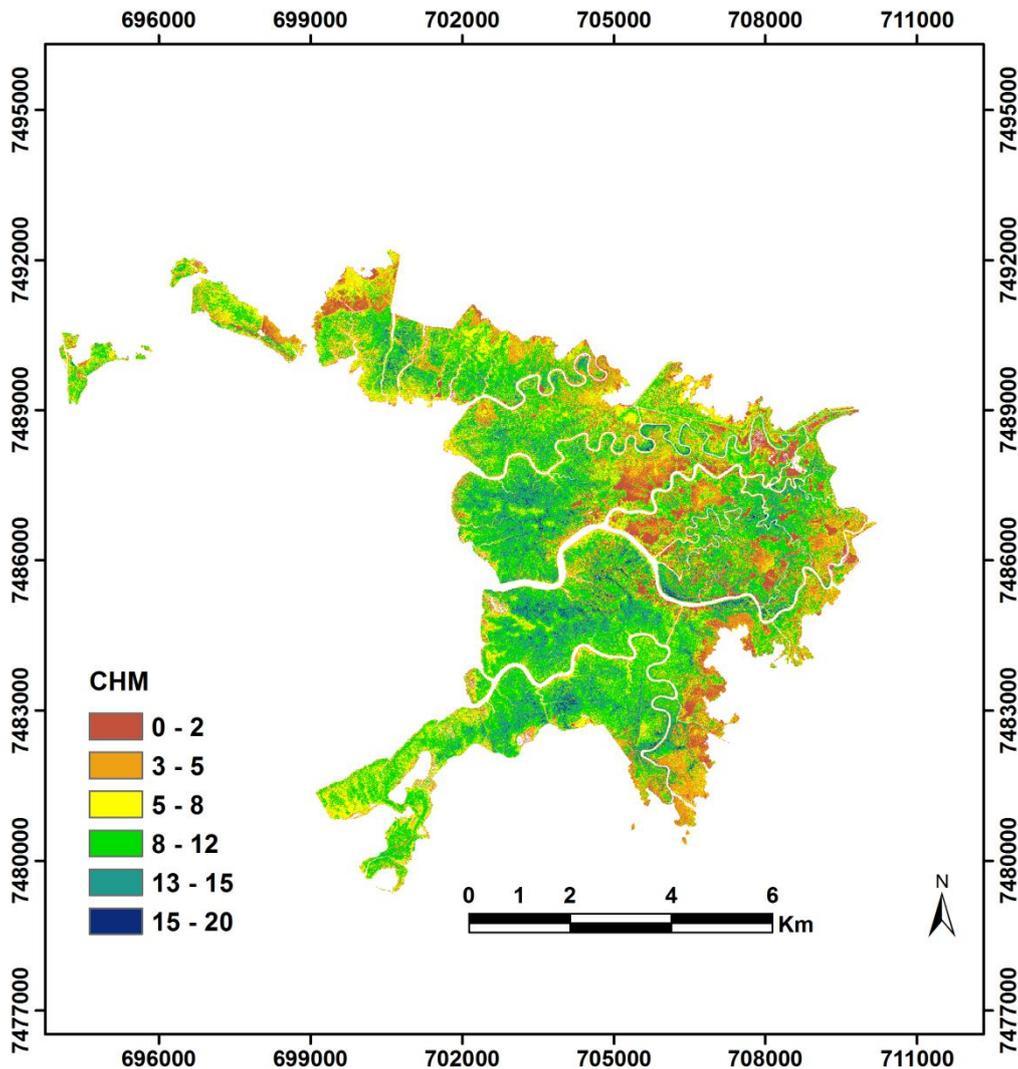
Imagens obtidas com as métricas descritivas LiDAR de densidade de pontos referentes à altura dos estratos dos bosques de mangue da APA de Guapimirim, sendo: avg, max, d02 (4,0 - 6,0 m) e d03 (6,0 - 8,0 m).

Figura 5.10 - Classes obtidas com as métricas LiDAR - d04 d05 e d09.



Imagens obtidas com as métricas descritivas LiDAR de densidade de pontos referentes à altura dos estratos dos bosques de mangue da APA de Guapimirim, sendo: d04 (8 - 10 m), d05 (10 - 12 m) e d08 (16 - 18 m).

Figura 5.11 - Modelo da altura do dossel.



Modelo da altura do dossel (CHM - *canopy height model*) obtido com dados LiDAR de retorno discreto para o manguezal da APA de Guapimirim

Os resultados obtidos no presente estudo demonstram o potencial dos dados LiDAR para caracterizar dosséis e a estrutura de bosques de mangue e possibilitar estimativas mais precisas de AGB. Estas informações são úteis para políticas públicas de mitigação do aquecimento global como o REDD+. Além de auxiliar na quantificação e qualificação de AGB e carbono florestal essas informações auxiliam o monitoramento e a gestão de manguezais visando sua recuperação, proteção, conservação e preservação, visto que este é um ecossistema de preservação permanente. Segundo o Plano de Manejo da APA de Guapimirim (PELLENS et al., 2001), as atividades das ações

gerenciais gerais que asseguram o bom funcionamento da APA dizem respeito à pesquisa e monitoramento, bem como, à utilização sustentável dos recursos, saneamento, recuperação e controle ambiental e gerencial. Desta forma, é de grande valia o conhecimento sobre a cobertura vegetal do manguezal da APA de Guapimirim, bem como, a identificação de áreas de mangue alteradas, degradadas e em processo de recuperação. Estas informações podem ser efetivamente aproveitadas na gestão ambiental da APA orientando a definição de áreas prioritárias de manguezais a serem recuperados.

5.2 Avaliação dos modelos de estimativa de biomassa aérea com uso dos índices texturais

Os resultados referentes à pergunta científica 2 - *Qual o potencial da análise textural aplicada a imagens ópticas de alta resolução espacial para estimar a biomassa de floresta de mangue com distintos graus de alteração?* serão apresentados nesta seção. Os modelos de estimativa aqui avaliados foram obtidos com os índices texturais FOTO e GLCM obtidos na escala da parcela. Também são avaliados os modelos gerados com os índices texturais obtidos na escala da paisagem, e calibrados e validados com os valores de AGB obtidos pelo mapa gerado com os dados LiDAR.

5.2.1 Avaliação dos modelos de estimativa de biomassa aérea com uso de índices texturais do método FOTO

Os modelos preditivos de AGB dos bosques de mangue aqui avaliados foram gerados utilizando os índices texturais FOTO obtidos na escala da parcela como variáveis preditoras e para sua calibração e validação foram utilizados os valores de AGB das 34 parcelas de campo. Estes modelos se diferenciam em função do número de variáveis preditoras de entrada e em função do método de regressão utilizado (RF e AutoPLS). Desse modo foram gerados 4 modelos (M4a, M4b, M4.all.a, M4.all.b), cujas características e resultados são apresentados na Tabela 5.3 a seguir.

Os resultados dos modelos de regressão utilizando índices texturais FOTO (Tabela 5.3) em comparação com os resultados dos modelos obtidos com as variáveis LiDAR foram

inferiores em relação aos valores de R^2 e apresentaram maiores valores de RMSE. De modo geral, os índices texturais obtidos com a metodologia FOTO não possibilitaram resultados consistentes para a estimativa da AGB de bosques de mangue com distintos graus de alteração. Para os modelos utilizando as três primeiras componentes principais (PCA1, PCA2 e PCA3) o melhor resultado foi com M4a (AutoPLS), com RMSE(LOO) de 35,90 t/ha e $R^2(\text{LOO}) = -0,17$. O modelo M4.all.a utilizando as 17 componentes principais como entrada apresentou RMSE(LOO) de 40,80 t/ha e $R^2(\text{LOO}) = -0,51$.

Tabela 5.3 - Resultados dos modelos de regressão para estimativa de biomassa das 34 parcelas de campo por meio dos índices de textura.

Modelo (variáveis de entrada)	AutoPLS (a)	Random Forest (b)
M4 PCA1, PCA2, PCA3	RMSE(CAL) = 32,10 RMSE(LOO) = 35,90 R2(CAL) = 0,07 R2(LOO) = -0,17	RMSE = 39,03 R ² = -0,38
M4.all. PCA1, PCA2, PCA3, PCA4, PCA5, PCA6, PCA7, PCA8, PCA9, PCA10, PCA11, PCA12, PCA13, PCA14, PCA15, PCA16, PCA17	RMSE(CAL) = 24,70 RMSE(LOO) = 40,80 R2(CAL) = 0,45 R2(LOO) = -0,51	RMSE = 37,45 R ² = -0,27

Proisy et al. (2007) aplicaram o método FOTO em imagem IKONOS pancromática com 1 m de resolução para a estimativa de biomassa de manguezais na Guiana Francesa com distintos graus de desenvolvimento estrutural, como bosque pioneiro, jovem, adulto, maduro e em declínio. Os resultados foram significativamente melhores do que os obtidos no presente estudo. Com o modelo de regressão linear e janela de 50 pixels, Proisy et al. (2007) obtiveram um $R^2 = 0,92$ e $\text{RMSE} = 33$ t/ha para a estimativa de AGB. Naquele trabalho os estágios de desenvolvimento estrutural do manguezal foram caracterizados por frequências espaciais particulares para cada estágio (Figura 4 de Proisy et al., 2007) utilizando os valores de *r-spectra*. Os autores sugerem que uma ampla variedade da estrutura florestal pode ser discriminada utilizando a ordenação dos valores de *r-spectra*, com alta frequência espacial para florestas jovens (imagem com textura fina) e baixa frequência espacial para floresta madura e em declínio (imagem com textura rugosa). Segundo os autores, este método para a estimativa de biomassa

tem como vantagem sobre o uso de dados SAR a não saturação do sinal para valores altos de biomassa florestal.

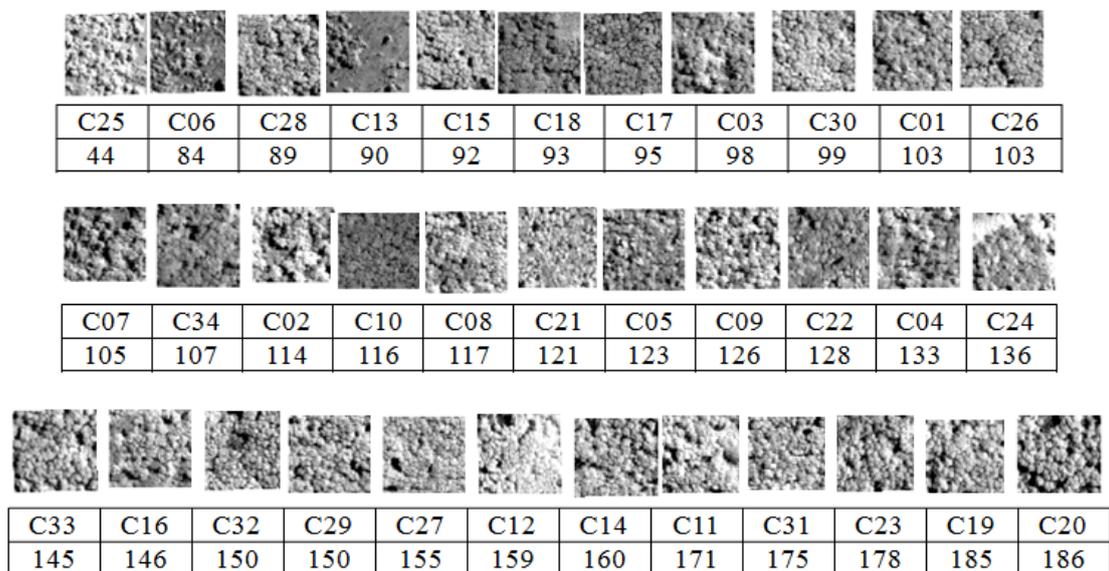
Nfotabong-Atheull (2011) aplicou o método FOTO para estimar e mapear a AGB de um manguezal preservado em Camarões, África. Os resultados mostraram boa relação entre os índices texturais do dossel e a AGB do mangue ($R^2 = 0,92$ e $RMSE = 19,7$ t/ha) utilizando a PCA1 como variável preditora. Os padrões texturais dos dosséis referentes à granulometria do dossel do manguezal possibilitaram distinguir o grau de desenvolvimento estrutural dos bosques.

A aplicação do método FOTO também obteve bons resultados para outros tipos de floresta quando esta se caracterizava por apresentar distintos estágios de desenvolvimento estrutural (COUTERON et al., 2005; COUTERON, 2002). Couteron et al. (2005) estimaram parâmetros estruturais de floresta tropical na Guiana Francesa obtendo significativa correlação entre os índices texturais gerados pelo método FOTO e os parâmetros estruturais referentes à densidade de indivíduos ($R^2 = 0,80$), distribuição de classes de DAP ($R^2 = 0,64$), diâmetro da árvore de área basal média ($R^2 = 0,71$) e altura média do dossel ($R^2 = 0,57$). Naqueles trabalhos, a aplicação do método FOTO permitiu relacionar distintos padrões texturais das imagens ópticas de alta resolução com os gradientes de desenvolvimento estrutural.

Contudo a aplicação do método FOTO para estimativa da biomassa em bosque de mangue com distintos graus de alteração realizada no presente estudo não obteve resultados satisfatórios. Uma possível explicação está associada às diferentes condições de conservação e aos diferentes padrões estruturais florestais do manguezal da APA de Guapimirim e das florestas estudadas nos trabalhos anteriormente citados. Recortes da imagem pancromática WorldView-2 (vinhetas de 50 m) retratando cada uma das 34 parcelas de campo (Figura 5.12) mostram sua textura visual e os valores correspondentes de AGB ordenados de forma crescente. Pode-se observar que o gradiente textural visual (textura fina a grossa) das 34 vinhetas não apresenta variação expressiva relacionada com os valores da AGB dos bosques de mangue. Bosques de mangue mais alterados apresentam clareiras em seu interior (por exemplo a parcela C13). Enquanto bosques maduros mais preservados apresentam dosséis com copas

maiores e sem grandes clareiras (por exemplo as parcelas C29 e C20). Observa-se que o padrão textural de acordo com o grau de alteração do bosque é diferente do padrão textural que retrata distintos estágios de desenvolvimento estrutural de uma floresta preservada, como observado em Proisy et al. (2007). Este aspecto pode ter causado a baixa correlação entre os índices de textura obtidos com o método FOTO e os valores de biomassa obtidos em campo para um manguezal com distintos graus de alteração, como no caso do presente estudo. Assim, as informações texturais obtidas com o método FOTO e os resultados dos modelos não apresentaram boa acurácia para modelar a AGB de bosques de mangue com distintos graus de alteração. No entanto, os resultados obtidos no presente estudo indicam que o método FOTO deve ser aprimorado de modo a permitir capturar diferenças texturais causadas ou associadas à presença de espécies invasoras ou associadas, troncos mortos, clareiras, diferenças estruturais e dosséis mais complexos, como as observadas na área de estudo.

Figura 5.12 - Imagem pancromática representativa das parcelas de estudo.



Vinhetas de 50x50 m da imagem pancromática representativas de cada parcela de campo ordenadas pelo valor de AGB (t/ha) de cada parcela.

A diversidade estrutural florestal da África Central foi investigada por meio dos índices texturais obtidos com o método FOTO por Bastin et al. (2014). Segundo esses autores, os índices texturais que caracterizavam os dosséis de diferentes tipos florestais apresentaram baixa correlação com a AGB quando o modelo gerado utilizava todos os tipos florestais ($RSE\% = 35,1$ e $R^2 = 0,32$). Naquele trabalho, o padrão textural não apresentou relação com valores de AGB, sendo que o padrão textural do dossel com granulometria grossa não só correspondeu a baixos valores de AGB de floresta de dosséis abertos, como também, correspondeu para altos valores de AGB de áreas com grandes copas e dosséis mais fechados. Ainda, o padrão textural do dossel com granulometria fina correspondeu a baixos valores de AGB para bosques jovens e também para altos valores de AGB para floresta monoespecífica. Entretanto, os modelos preditores de AGB que utilizaram grupos texturais mais homogêneos relativos a classes específicas de florestas apresentaram melhores resultados ($RSE\% = 19,37$ e $R^2 = 0,85$). Os resultados de Bastin et al. (2014) e do presente estudo indicam que os índices texturais obtidos pelo método FOTO apresentam bons resultados de correlação com a AGB de florestas com uma variação estrutural menos complexa. Ou seja, tipos de cobertura florestal que diferem apenas (ou sobretudo) no tamanho das copas, como por exemplo, quando formam padrão florestal heterogêneo, porém com dosséis homogêneos de bosques jovens e dosséis homogêneos de bosques maduros, apresentando uma textura fina a grossa nas imagens, respectivamente. Mas quando os dosséis apresentam características muito distintas, como quando na presença de clareiras e espécies invasoras, o padrão textural capturado pelos índices não corresponde ao intervalo de AGB da floresta.

5.2.2 Avaliação da cobertura amostral para os índices FOTO

Com objetivo de avaliar a cobertura amostral das 34 parcelas capturada pelos produtos FOTO procedeu-se com a mesma metodologia anteriormente aplicada para as métricas LiDAR (FEKETY et al., 2015; WHITE et al., 2013), na qual a cobertura amostral dos índices texturais representativos das parcelas foi avaliada graficamente. Por meio dos índices texturais FOTO (PCA1 e PCA2) obtidos na escala da parcela e na escala da paisagem, mostra-se o intervalo de variabilidade estrutural capturada na área de floresta

de mangue indicado em preto (10.000 pixels aleatoriamente selecionados como amostras de floresta de mangue) e em vermelho observa-se a variabilidade capturada pelos índices texturais (PCA1 e PCA2) representativos das 34 parcelas de campo (Figura 5.13). A proporção de variância acumulada para o conjunto das componentes da PCA para a área de floresta de mangue (escala da paisagem) foi de 44% para PCA1 + PCA2. Pode-se observar (FIGURA 5.13) que as 34 parcelas (coordenadas PCA1 e PCA2 referentes às parcelas - em vermelho) não cobrem a variabilidade estrutural capturada pelas coordenadas PCA1 e PCA2 referentes à floresta de mangue da área de estudo. Para 95% de confiança a elipse sólida cobre apenas 52% dos pixels da área de floresta de mangue. Observa-se também que as coordenadas PCA1 e PCA2 das 34 parcelas não apresentam-se ordenadas de acordo com o grau de alteração do bosque ou valor de biomassa, diferentemente do que se observa no trabalho de Proisy et al. (2007), onde o plano formado pelas coordenadas PCA1 e PCA2 na Figura 3 apresentou uma ordenação bem definida de acordo com os estágios de desenvolvimento estrutural dos bosques e os valores de biomassa correspondentes. Naquele trabalho o manguezal se caracterizava por extensas áreas com predomínio de bosques jovens, maior densidade de indivíduos com copas menores (textura fina) e bosques maduros com copas maiores cobrindo extensas áreas (textura grossa). De acordo com Barbier et al. (2010) pontos localizados longe da origem da PCA correspondem a dosséis mais homogêneos dominados por uma escala espacial única. Observa-se na Figura 5.13 que a maioria dos pontos representativos das parcelas estão localizados próximos à origem da PCA, indicando uma heterogeneidade das copas e do dossel em geral, causada por fatores naturais e antropogênicos, como por exemplo as clareiras. Isto indica que o método FOTO apresenta melhor correlação dos índices texturais com a estrutura do dossel quando este apresenta padrões mais homogêneos (PROISY et al., 2007). Em florestas com padrões heterogêneos e mais complexos de dossel as relações entre os índices FOTO e os parâmetros estruturais são mais fracas (PLOTON et al., 2012). Os bosques da APA de Guapimirim aqui estudados apresentam dosséis heterogêneos e complexos. Estes padrões podem explicar a baixa correlação entre os índices FOTO e as estimativas de biomassa.

Figura 5.13 - Diagrama de dispersão das componentes PCA 1 e PCA2 dos índices texturais FOTO.

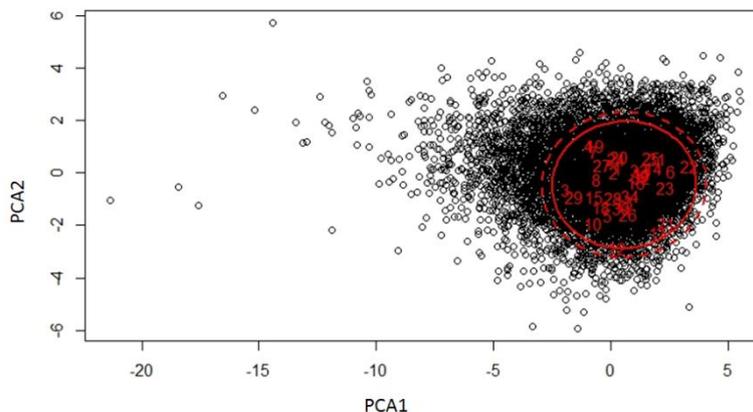


Diagrama de dispersão das componentes PCA1 e PCA2 dos valores das janelas de análise obtidos pelo método FOTO aplicado à cobertura de floresta de mangue em preto, e os valores plotados das componentes PCA1 e PCA2 referentes às 34 parcelas em vermelho.

5.2.3 Avaliação dos modelos de estimativa de biomassa com uso dos produtos do método GLCM

O método GLCM foi aplicado nas vinhetas da imagem pancromática WorldView-2 representativas das 34 parcelas de campo. Os melhores resultados para estimativa da AGB utilizando índices texturais GLCM como variáveis preditoras foram obtidos pelo modelo M5 (35-32), com janelas de 35 x 35 pixels e quantização em 32 bits, gerado pelo método AutoPLS, com $(RMSE(CAL) = 29,3 \text{ t/ha}, RMSE(LOO) = 31,7 \text{ t/ha}, R^2(CAL) = 0,22 \text{ e } R^2(LOO) = 0,09)$. Para este modelo as variáveis preditoras que mais contribuíram foram: homogeneidade, contraste, dissimilaridade e correlação. E para o modelo M5 (35-32) gerado pelo método RF a acurácia também foi considerada baixa, com $RMSE = 29,7 \text{ t/ha}$ e $R^2 = 0,20$ (Tabela 5.4). Para este modelo as 5 variáveis preditoras que mais contribuíram foram: contraste, segundo momento, variância, dissimilaridade e correlação.

O uso de índices texturais GLCM para estimativa de biomassa demonstrou resultados distintos de acordo com o tipo de floresta em estudo. Lu e Batistella (2005) analisaram índices GLCM extraídos de uma imagem Landsat-TM da floresta tropical Amazônica

com distintos estágios sucessionais decorrentes de desmatamento e degradação com AGB média de 8,35 kg/m², e de floresta madura com AGB média de 24,76 kg/m². Foi obtida fraca correlação entre os índices texturais e a AGB de floresta madura. Alguns índices como variância, contraste e dissimilaridade foram significativos para as bandas TM5 e TM7. Para a floresta com distintos estágios sucessionais os índices GLCM foram fracamente correlacionados com a AGB, sendo significativos somente os índices média e variância. Ainda de acordo com Lu e Batistella (2005), a textura suaviza as diferenças das características espectrais dos distintos estágios de sucessão vegetal resultando em fraca correlação da AGB com os índices texturais.

Eckert (2012) analisou o uso de índices GLCM e parâmetros espectrais derivados de uma imagem WorldView-2 para estimar a AGB em uma área de floresta tropical úmida no Madagascar. Os resultados desse autor indicaram correlação mais forte da AGB com os índices texturais do que com os parâmetros espectrais como índices de vegetação. A melhor estimativa da AGB, com R² ajustado = 0,84; RMSE = 31,6 t/ha e RMSE relativo = 6,8% (n=100), foi obtida pelo autor em áreas degradadas com uso dos índices texturais correlação, segundo momento angular e contraste derivados da banda no vermelho. Ainda segundo Eckert (2012), os índices texturais possibilitaram capturar melhor a variação da estrutura do dossel florestal se comparados a razões de banda e medidas de reflectância espectral. Os índices texturais apresentaram maior sensibilidade aos aspectos espaciais do sombreamento dos dosséis, principalmente no caso de dosséis heterogêneos como em áreas degradadas. Wang. et al. (2014) também obteve melhores resultados para a estimativa de AGB florestal com o uso de índices GLCM derivados de imagem óptica do que com uso de razões de banda ou índices de vegetação.

Tabela 5.4 - Resultados dos modelos preditivos da AGB de bosques de mangue na APA de Guapimirim, RJ utilizando índices texturais GLCM e FOTO.

Modelo (janela n.pixels-n.bits)	Modelo - variáveis de entrada	AutoPLS (a)	Random Forest (b)
M5 (15-32)	GLCM Janela = 15; nível de cinza = 32	RMSE(CAL)= 29,50 RMSE(LOO)= 33,00 R2(CAL)= 0,21 R2(LOO)= 0,01	RMSE= 30,05 R ² =0,18
M5 (15-64)	GLCM Janela = 15; nível de cinza = 64	RMSE(CAL)= 29,60 RMSE(LOO)= 33,30 R2(CAL)= 0,21 R2(LOO)= -0,01	RMSE=30,45 R ² = 0,16
M5 (35-32)	GLCM Janela = 35; nível de cinza = 32	RMSE(CAL)= 29,30 RMSE(LOO)= 31,70 R2(CAL)= 0,22 R2(LOO)= 0,09	RMSE= 29,70 R ² = 0,20
M5 (15-64)	GLCM Janela = 35; nível de cinza = 64	RMSE(CAL)= 29,90 RMSE(LOO)= 31,90 R2(CAL)= 0,19 R2(LOO)= 0,08	RMSE=30,54 R ² =0,16
M6	FOTO 17 variáveis + GLCM (35-32) 8 variáveis	RMSE(CAL)= 29,30 RMSE(LOO)= 31,70 R2(CAL)= 0,22 R2(LOO)= 0,09	RMSE= 33,96 R ² = -0,04

Os modelos M6 de estimativa da AGB utilizando todos os índices texturais (17 componentes PCA do método FOTO e 8 índices GLCM) também não apresentaram resultados estatísticos satisfatórios (Tabela 5.4). Para o modelo M6a (RMSE(CAL) = 29,3 t/ha, RMSE(LOO) = 31,7 t/ha, R²(CAL) = 0,22 e R²(LOO) = 0,09) as variáveis preditoras que mais contribuíram foram: homogeneidade, contraste, dissimilaridade e correlação. Para o modelo M6b a acurácia também foi considerada baixa, com RMSE = 33,96 t/ha e R² = -4,48. As variáveis preditoras que mais contribuíram para o modelo M6b foram: dimissilaridade, contraste, homogeneidade, variância, segundo momento, correlação e entropia. O modelo M6a apresentou resultado semelhante ao modelo M5a (35-32) que utilizou somente as variáveis dos produtos GLCM. Para ambos os modelos M5a (35-32) e M6a as variáveis homogeneidade, contraste, dissimilaridade e correlação foram as variáveis preditoras selecionadas pelo modelo. No entanto, todos estes modelos (M4, M4.all, M5 e M6) que utilizaram índices texturais relativos às 34 parcelas de campo não apresentaram resultados com boa precisão.

5.2.4 Estimativa de AGB com uso dos índices texturais FOTO e GLCM e valores de AGB estimados com LiDAR

Para melhorar a capacidade preditiva destes modelos, foi investigada a utilização de um número maior de amostras representativas da AGB do manguezal. A ideia é aumentar a representatividade da variabilidade estrutural das parcelas com a inclusão de mais amostras de treinamento. E assim, averiguar o potencial dos índices texturais para a predição da AGB com uma variação maior de valores de AGB do manguezal com distintos graus de alteração. O mapa de AGB do manguezal da APA de Guapimirim obtido com o melhor modelo preditivo M2a serviu como base de dados de referência para calibração e validação.

Vários grupos de variáveis de entrada nos modelos foram testados para cada conjunto de pontos (50, 100 e 2000) e para os modelos de regressão RF e AutoPLS. Os grupos de variáveis de entrada obtidos na escala da paisagem são: (i) grupo com os índices texturais FOTO (3 componentes principais) obtidos com janelas de 50 e 100 pixels; (ii) grupo com os 8 índices texturais GLCM; e (iii) grupo utilizando todos os índices texturais FOTO e GLCM. A partir destas variáveis foram gerados 18 modelos, cujas características e resultados estão apresentados na Tabela 5.5. Os modelos construídos apenas com índices texturais FOTO (M8) não apresentaram bons resultados para janelas de 50 e 100 pixels. Observa-se que os modelos M8 e M9 apresentaram resultados semelhantes quando utilizado o método AutoPLS. De modo geral, os índices texturais GLCM foram as variáveis preditoras que mais contribuíram para o desempenho dos modelos. Os melhores resultados foram obtidos pelos modelos M9,2000. O modelo M9,2000a obteve $RMSE(CAL) = 29,40$, $RMSE(LOO) = 29,50$ t/ha, $R^2(CAL) = 0,32$ e $R^2(LOO) = 0,31$, com as variáveis preditoras : FOTO 50 PCA1, FOTO 50 PCA2, FOTO 50 PCA3, FOTO 100 PCA2, média, homogeneidade, contraste, dissimilaridade, segundo momento e correlação. O modelo M9,2000b obteve $RMSE = 25,64$ t/ha e $R^2 = 0,41$, com as variáveis preditoras: média, contraste, FOTO 100 PCA1, homogeneidade, entropia e variância.

Tabela 5.5 - Resultados RMSE e R² dos modelos de estimativa de biomassa de bosques de mangue com uso das variáveis texturais e AGB do mapa LiDAR.

Modelos	Variáveis de entrada	AutoPLS (a)	Random forest (b)
FOTO			
M7 (n. pontos)			
M7,50	FOTO 50 PCA1	RMSE(CAL)= 29,90	RMSE=34,76 R ² = -0,25
	FOTO 50 PCA2	RMSE(LOO)= 33,80	
	FOTO 50 PCA3	R2(CAL)= 0,08	
M7,100	FOTO 100 PCA1	R2(LOO)= -0,18	RMSE=31,83 R ² = -0,33
	FOTO 100 PCA2	RMSE(CAL)= 30,70	
	FOTO 100 PCA3	RMSE(LOO)= 32,90	
M7,2000	<i>idem</i>	R2(CAL)= 0,04	RMSE=32,85 R ² =0,25
	<i>idem</i>	R2(LOO)= -0,10	
	<i>idem</i>	RMSE(CAL)= 33,00	
GLCM			
M8 (n. pontos)			
M8,50	média, variância, homogeneidade, contraste, dissimilaridade, entropia, segundo momento, correlação	RMSE(CAL)= 27,40	RMSE=30,60 R ² = 0,32
		RMSE(LOO)= 29,00	
		R2(CAL)= 0,23	
M8,100	<i>idem</i>	R2(LOO)= 0,13	RMSE=29,38 R ² = 0,12
		RMSE(CAL)= 27,20	
		RMSE(LOO)= 28,40	
M8,2000	<i>idem</i>	R2(CAL)= 0,24	RMSE=26,08 R ² = 0,38
		R2(LOO)= 0,18	
		RMSE(CAL)= 27,20	
GLCM+FOTO			
M9 (n. pontos)			
M9,50	FOTO 50 PCA1 FOTO 50 PCA2 FOTO 50 PCA3 FOTO 100 PCA1 FOTO 100 PCA2 FOTO 100 PCA3 média, variância, homogeneidade, contraste, dissimilaridade, entropia, segundo momento, correlação	RMSE(CAL)= 27,40	RMSE=31,28 R ² = -0,50
		RMSE(LOO)= 29,00	
		R2(CAL)= 0,23	
		R2(LOO)= 0,13	
		RMSE(CAL)= 27,00	
		RMSE(LOO)= 28,10	
M9,100	<i>idem</i>	R2(CAL)= 0,26	RMSE=28,32 R ² = 0,18
		R2(LOO)= 0,19	
		RMSE(CAL)= 29,40	
M9,2000	<i>idem</i>	RMSE(LOO)= 29,50	RMSE= 25,64 R ² = 0,41
		R2(CAL)= 0,32	
		R2(LOO)= 0,31	

O diagrama de dispersão entre os valores preditos de AGB e observados da AGB do mapa LiDAR para os modelos M9,2000 – AutoPLS e RF com 2000 pontos – pode ser visto na Figura 5.14. Observa-se que os valores preditos de AGB concentram-se mais entre ~70,0 t/ha a ~130 t/ha para os dois modelos AutoPLS (com AGB média = 108,46 t/ha e desvio padrão = 19,99) e RF (com AGB média = 108,77 t/ha e desvio padrão = 22,31), enquanto os valores observados de AGB (referentes ao mapa LiDAR) apresentam maior intervalo de valores (com AGB média = 108,44 t/ha e desvio padrão = 35,52).

Figura 5.14 - Diagrama de dispersão entre os valores de AGB preditos e observados para os modelos M9,2000.

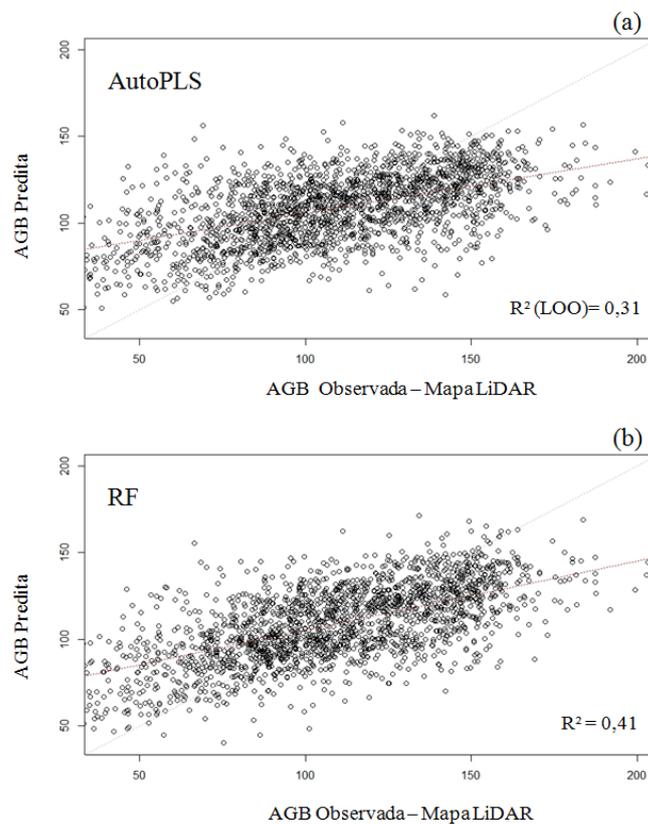


Diagrama de dispersão entre os valores de AGB preditos e observados (mapa LiDAR), para os modelos de regressão M9,2000a(AuroPLS) e M9,2000b (Random Forest), utilizando 2000 pontos aleatórios.

Os resultados obtidos no presente estudo indicaram baixa correlação entre os índices texturais testados e a AGB dos manguezais da área de estudo com distintos graus de alteração. Os índices texturais não apresentaram um gradiente de padrões texturais coerente com a variabilidade de valores da AGB em função da heterogeneidade dos dosséis alterados ou preservados. Informações texturais variam com as características da vegetação de estudo e com as características das imagens utilizadas. Desta forma, o comportamento e a seleção adequada de índices texturais para estimar a AGB é ainda um campo de pesquisa a ser mais explorado. Entretanto, a disponibilidade de dados ópticos é, de modo geral, relativamente mais viável que a de dados LiDAR e por isso justifica-se o esforço de pesquisa para a utilização efetiva dos índices texturais derivados de imagens ópticas.

5.3 Classificação dos tipos de mangue

Além de avaliar o potencial da análise textural para estimar a AGB, também foi investigado o potencial dos índices texturais para distinguir tipos de cobertura do manguezal da APA de Guapimirim, permitindo sua classificação em três grandes classes de alteração: *mangue denso* (bosque preservado), *mangue alterado* (bosque alterado), e *não-mangue* (bosque sem vegetação de mangue, equivalente a uma área completamente alterada). Desta forma buscou-se responder à pergunta científica 3 - *É possível distinguir tipos de bosques de mangue em diferentes estágios de alteração por meio de análise textural?*

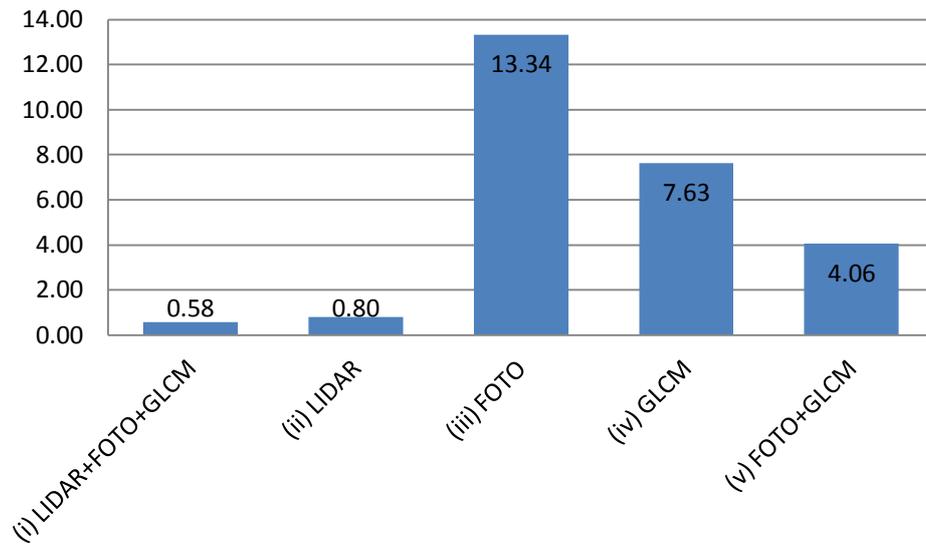
Com este intuito, foi aplicado o método de classificação RF nos índices texturais e métricas LiDAR na escala de paisagem. Foram testados diferentes grupos de variáveis compostos por: (i) grupo com todos os índices texturais FOTO, GLCM e as métricas LiDAR; (ii) grupo com as métricas LiDAR; (iii) grupo com as 3 primeiras componentes principais do método FOTO aplicado com janelas de 50 e 100 pixels; (iv) grupo com os índices texturais GLCM; (v) grupo com os índices texturais FOTO e GLCM. Os resultados (Tabela 5.6, Tabela 5.7, Tabela 5.8, Tabela 5.9 e Tabela 5.10) indicam que a menor taxa de erro (0,58%) da estimativa OOB (Figura 5.15) foi obtida para o grupo (i) seguido pelo grupo (ii, 0,8%), pelo grupo (v, 4,06%), grupo (iv, 7,63%), e por último pelo grupo composto pelos índices FOTO (iii, 13,34%). Os dois grupos (i) e (ii) que

usaram as métricas LiDAR apresentaram a melhor acurácia para discriminação entre as classes *mangue denso*, *mangue alterado* e *não-mangue*. O uso conjunto dos índices FOTO e GLCM pelo grupo (v) obteve melhor resultado em comparação com o uso separado desses índices texturais, diminuindo também a confusão entre as classes de cobertura do manguezal.

O resultado da classificação utilizando todas as variáveis LiDAR+FOTO+GLCM (Tabela 5.6) mostra que as métricas LiDAR tiveram maior contribuição relativa de acordo com o índice Gini. As 10 variáveis mais influentes na classificação foram: p25, avg, p10, qav, p05, d00, std, p99, p95 e max. Estas variáveis permitem diferenciar as alturas dos bosques. A variável p25, por exemplo, que apresentou forte influência na classificação, indica a distribuição da altura da vegetação para 25% dos pontos, permitindo diferenciar bosques com vegetação mais baixa de bosques mais fechados com indivíduos maiores. A avg que está relacionada com a altura média dos bosques contribui para distinguir vegetação não-mangue e rasteira dos bosques com dosséis mais preservados e com indivíduos desenvolvidos. As variáveis p99, p95 e max apresentam valores mais altos para bosques desenvolvidos e valores baixos para bosques pouco desenvolvidos ou vegetação não-mangue. Na classificação utilizando os índices FOTO a maior contribuição foi dada pela PCA1-FOTO100 (primeira componente da PCA FOTO com janela de 100 pixels). Na classificação utilizando os índices FOTO+GLCM as variáveis com maior contribuição são PCA1-FOTO100, homogeneidade, dissimilaridade, contraste, variância, correlação e entropia, mostrando maior influência dos índices GLCM na discriminação dos tipos de mangue, ainda que com forte influência do índice PCA1-FOTO100.

Foi também realizada uma classificação dos tipos de cobertura do manguezal utilizando somente as variáveis avg, PCA1-FOTO100 e homogeneidade, que foram as variáveis mais influentes dos grupos (ii) LiDAR, (iii) FOTO, e (iv) GLCM, respectivamente. A taxa de erro desta classificação foi de 0,85% (Tabela 5.11) o que pode ser considerado um bom resultado, também indicando forte influência dos índices texturais.

Figura 5.15 - Taxas dos erros (OOB) estimado para as classificações RF.



Taxas dos erros *out of bag* (OOB) estimado em porcentagem (%) das classificações comparativamente para os grupos: (i) grupo com todos os índices texturais FOTO, GLCM e métricas LiDAR; (ii) grupo com métricas LiDAR; (iii) grupo com índices texturais FOTO; (iv) grupo com os índices texturais GLCM; (v) grupo com índices FOTO e GLCM.

Tabela 5.6 - Resultado da classificação Random Forest para o grupo (i) com todas as variáveis LiDAR e índices texturais FOTO e GLCM. Matriz de confusão, importância das variáveis para a classificação RF e Índice Gini.

(i) Todas Variáveis LiDAR FOTO GLCM	avg	d00	d01	d02	d03	d04
	d05	d06	d07	d08	dns_gap	kur
	p01	p05	p10	p25	p50	p75
	p90	p95	p99	qav	Ske	std
	min	max	Media		Variância	
	Homogeneidade		Contraste		Dissimilaridade	
	Entropia		Segundo momento		Correlação	
	FOTO 50 PCA1		FOTO 50 PCA2		FOTO 50 PCA3	
FOTO 100 PCA1		FOTO 100 PCA2		FOTO 100 PCA3		
Taxa de erro estimado OOB: 0,58%						
Matriz de confusão	Mangue- alterado	Mangue- denso	Não-mangue	Erro de classificação		
Mangue-alterado	701	3	4	0,00989		
Mangue-denso	2	1024	0	0,00195		
Não-mangue	4	0	503	0,00789		
Variáveis/ importância na classificação RF	Mangue- alterado	Mangue- denso	Não-mangue	Índice Gini		
avg	10,7	8,91	8,6	120,13		
d00	8,56	9,7	7,31	89,6		
d01	3,78	7,42	4,46	5,32		
d02	3,68	4,33	3,92	7,63		
d03	6,33	4,15	9,13	46,61		
d04	5,34	3,74	8,23	61,64		
d05	4,21	2,66	5,54	23,03		
d06	2,33	2,53	1,44	0,58		
d07	4,01	3,81	1,46	3,02		
d08	1,52	0,01	1	0,07		
dns_gap	8,34	4,94	6,36	1,92		
kur	3,92	5,45	5,51	7,01		
max	7,59	3,71	9,77	61,92		
min	4,11	3,12	1,07	0,87		
p01	8,97	11,28	6,03	54,87		
p05	10,97	10,49	7,63	92,54		
p10	10,6	9,54	7,86	104,53		
p25	12,71	13,81	9,58	138,92		
p50	5,92	5,74	7,05	53,87		
p75	5,55	3,59	7,55	56,14		
p90	8,19	3,77	9,76	60,76		
p95	9,16	4,41	10,57	69,57		
p99	10,04	4,67	12,13	84,71		
qav	7,32	8,12	9,25	100,53		
ske	4,9	2,43	5,81	33,43		
std	11,91	3,85	13,11	84,84		
FOTO 50 PCA1	1,39	1,67	-1,87	0,32		
FOTO 50 PCA2	2,08	1,3	3,88	0,8		
FOTO 50 PCA3	1,3	0,37	0,75	0,36		
FOTO 100 PCA1	9,79	5,15	7,05	12,08		
FOTO 100 PCA2	6,52	2,97	4,4	3,59		
FOTO 100 PCA3	1,18	0,97	2,6	0,75		
Média	5,18	6,02	1,99	1,14		
Variância	1,85	2,21	4,72	9,85		
Homogeneidade	3,53	7,41	3,64	3,72		
Contraste	3,78	7,75	3,92	2,85		
Dissimilaridade	3,87	7,2	3,31	3,17		
Entropia	2,81	3,89	5,95	11,39		
Segundo momento	3,92	3,32	5,79	2,58		
Correlação	4,29	2,28	6,99	16,08		

Tabela 5.7 - Resultado da classificação Random Forest para o grupo (ii) com todas as variáveis LiDAR. Matriz de confusão, importância das variáveis para a classificação RF e Índice Gini.

(ii) Variáveis LIDAR	avg	d00	d01	d02	d03	d04
	d05	d06	d07	d08	dns_gap	kur
	p01	p05	p10	p25	p50	p75
	p90	p95	p99	qav	Ske	std
	min	max				
Taxa de erro estimado OOB: 0,8%						
Matriz de confusão	Mangue- alterado	Mangue-denso	Não-mangue	Erro de classificação		
Mangue-alterado	697	4	7	0,015536723		
Mangue-denso	3	1023	0	0,002923977		
Não-mangue	4	0	503	0,007889546		
Variáveis/ importância na classificação RF	Mangue- alterado	Mangue-denso	Não-mangue	Índice Gini		
avg	12,03	9,75	10,28	121,69		
d00	8,63	10,62	8,4	109,54		
d01	2,74	7,7	4,88	5,03		
d02	4,12	5,41	5,56	8,4		
d03	6,52	5,44	11,74	54,63		
d04	6,83	2,2	7,61	47,52		
d05	3,38	3,1	5,14	21,47		
d06	5,5	2,69	1,43	0,74		
d07	5,58	3,46	1,45	0,71		
d08	1,37	1,42	0	0,05		
dns_gap	10,34	7,5	7,83	2,63		
kur	5,39	5,95	7,3	4,39		
max	8,4	4,29	12,67	65,75		
min	4,67	4,35	-0,84	1,27		
p01	8,72	11,11	5,98	51,5		
p05	9,33	13,03	8,34	104,93		
p10	10,04	11,5	10,44	153,77		
p25	10,57	13,87	10,88	157,4		
p50	5,42	6,45	7,45	47,44		
p75	8,36	3,86	7,23	37,57		
p90	8,39	3,9	10,18	43,36		
p95	11,22	4,15	12,18	97,84		
p99	10,84	4,39	13,83	101,61		
qav	9,49	7,14	8,83	72,29		
ske	4,7	3,12	5,16	26,46		
std	13,7	3,82	15,77	94,51		

Tabela 5.8 - Resultado da classificação Random Forest para o grupo (iii) com as variáveis FOTO. Matriz de confusão, importância das variáveis para a classificação RF e Índice Gini.

(iii)	FOTO 50 PCA1	FOTO 50 PCA2	FOTO 50 PCA3	
Variáveis FOTO	FOTO 100 PCA1	FOTO 100 PCA2	FOTO 100 PCA3	
OOB estimate of error rate: 13,34%				
Matriz de confusão	Mangue- alterado	Mangue-denso	Não-mangue	Erro de classificação
Mangue-alterado	614	86	8	0,1327684
Mangue-denso	81	915	30	0,1081871
Não-mangue	13	81	413	0,1854043
Variáveis/ importância na classificação RF	Mangue- alterado	Mangue-denso	Não-mangue	Índice Gini
FOTO 50 PCA1	8,47	35,67	12,15	144,74
FOTO 50 PCA2	17,74	4,95	12,33	117,03
FOTO 50 PCA3	-2,31	1,78	1,06	70,39
FOTO 100 PCA1	180,94	146,68	31,27	550,24
FOTO 100 PCA2	52,57	107,92	61,57	375,69
FOTO 100 PCA3	-1,25	64,93	19,15	173,81

Tabela 5.9 - Resultado da classificação Random Forest para o grupo (iv) com as variáveis GLCM. Matriz de confusão, importância das variáveis para a classificação RF e Índice Gini.

(iv)	Media	Variância	Homogeneidade	
Variáveis GLCM	Contraste	Dissimilaridade	Entropia	
	Segundo momento	Correlação		
Taxa de erro estimado OOB: 7,63%				
Matriz de confusão	Mangue- alterado	Mangue-denso	Não-mangue	Erro de classificação
Mangue-alterado	619	64	25	0,12570621
Mangue-denso	43	979	4	0,04580897
Não-mangue	30	5	472	0,06903353
Variáveis/ importância na classificação RF	Mangue- alterado	Mangue-denso	Não-mangue	Índice Gini
Média	41,97	55,32	23,61	108,7
Variância	27,53	21,49	17,27	206,71
Homogeneidade	27,26	30,26	15,49	230,43
Contraste	23,74	29,39	15,62	178,06
Dissimilaridade	26,98	28,62	14,38	207,5
Entropia	32,71	19,22	22,19	191,31
Segundo momento	19,78	16,85	11,96	104,41
Correlação	47,31	27,8	34,62	205,25

Tabela 5.10 - Resultado da classificação Random Forest para o grupo (v) com as variáveis FOTO e GLCM. Matriz de confusão, importância das variáveis para a classificação RF e Índice Gini.

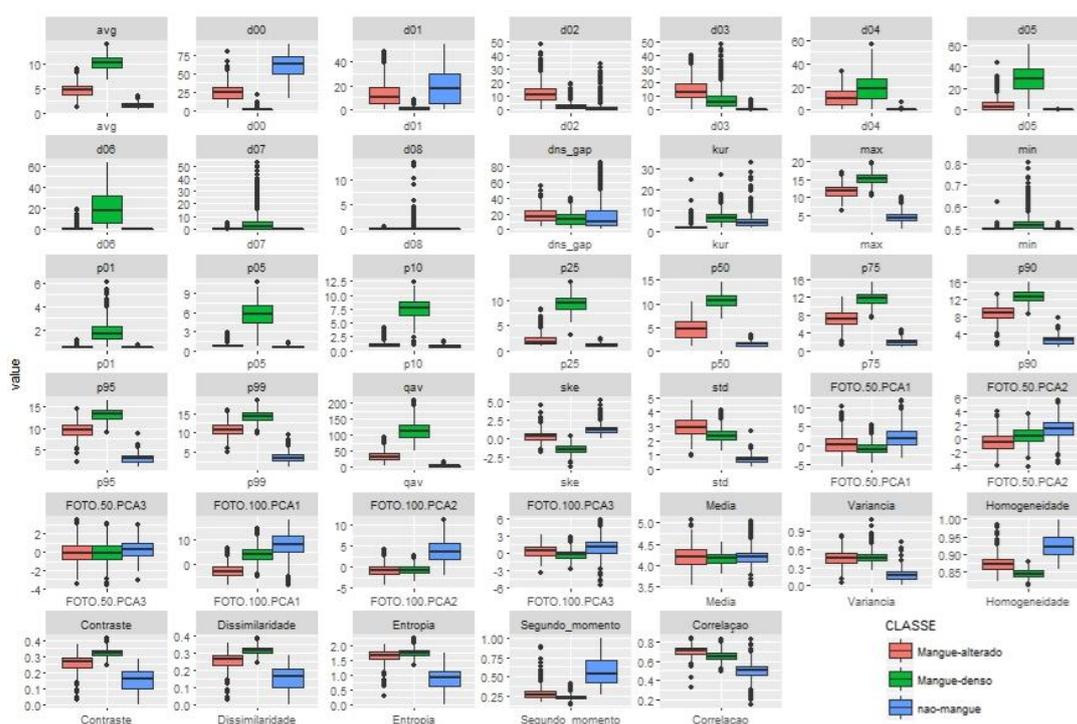
(v)	FOTO 50 PCA1	FOTO 50 PCA2	FOTO 50 PCA3	
Variáveis	FOTO 100 PCA1	FOTO 100 PCA2	FOTO 100 PCA3	
FOTO e GLCM	Media	Variância	Homogeneidade	
	Contraste	Dissimilaridade	Entropia	
	Segundo momento	Correlação		
Taxa de erro estimado OOB: 4,06%				
Matriz de confusão	Mangue- alterado	Mangue- denso	Não-mangue	Erro de classificação
Mangue-alterado	659	39	10	0,06920904
Mangue-denso	21	1003	2	0,02241715
Não-mangue	15	4	488	0,03747535
Variáveis/ importância na classificação RF	Mangue- alterado	Mangue- denso	Não-mangue	Índice Gini
FOTO 50 PCA1	3,16	6,01	7,78	16,4
FOTO 50 PCA2	11,45	6,21	7,48	23,98
FOTO 50 PCA3	-2,65	0,33	1,6	10,31
FOTO 100 PCA1	64,68	52,68	19,44	254,69
FOTO 100 PCA2	27,18	10,97	20,6	63,83
FOTO 100 PCA3	4,54	12,07	12,57	25,12
Média	44,61	46,5	16,17	71,05
Variância	17,47	16,74	13,85	147,46
Homogeneidade	18,82	23,41	14,13	172,52
Contraste	16,59	23,2	15,36	161,86
Dissimilaridade	17,9	21,25	13,44	162,57
Entropia	19,08	14,13	17,13	119,27
Segundo momento	11,22	13,22	8,88	65,53
Correlação	28,31	17,84	18,4	137,28

Tabela 5.11 - Resultado da classificação Random Forest para as variáveis avg, FOTO 100 PCA1 e homogeneidade. Matriz de confusão, importância das variáveis para a classificação RF e Índice Gini.

Variáveis	avg	FOTO 100 PCA1	Homogeneidade	
Taxa de erro estimado 0,85%				
Matriz de confusão	Mangue- alterado	Mangue-denso	Não-mangue	Erro de classificação
Mangue-alterado	697	4	7	0,015536723
Mangue-denso	4	1022	0	0,003898635
Não-mangue	4	0	503	0,007889546
Variáveis/ importância na classificação RF	Mangue- alterado	Mangue-denso	Não-mangue	Índice Gini
avg	61,14	166,26	64,32	696,22
FOTO 100 PCA1	64,34	30,79	46,74	359,54
Homogeneidade	16,03	27,12	31,63	376,3

Os gráficos de caixa (*boxplots*) das variáveis preditoras utilizadas nas classificações e as respectivas classes de cobertura do manguezal (Figura 5.16) mostram que algumas variáveis possibilitam a distinção entre as classes *mangue-denso*, *mangue-alterado* e *não-mangue*, por meio da observação da mediana dos valores de cada variável e dos 1º e 3º quartis dos valores de cada variável. Observa-se que a maioria das métricas LiDAR possibilitam a distinção entre 2 ou 3 classes. Os índices texturais FOTO PCA1 e PCA2, principalmente com a janela de 100 pixels, possibilitam distinguir a classe *não-mangue* das demais. Com os índices GLCM foi possível distinguir a classe *mangue* da *não-mangue* para a maioria dos índices, e discriminar as 3 classes para os índices homogeneidade, contraste, dissimilaridade e correlação.

Figura 5.16 - *Boxplot* das variáveis LiDAR e dos índices texturais FOTO e GLCM para discriminação entre as classes *mangue denso*, *mangue alterado* e *não-mangue*.



Boxplot das variáveis LiDAR e dos índices texturais FOTO e GLCM para discriminação entre as classes *mangue denso*, *mangue alterado* e *não-mangue*. Cada *boxplot* indica o valor da mediana dos valores dos pixels de cada classe, bem como os quartis 1º e 3º, e os limites dos valores inferior e superior.

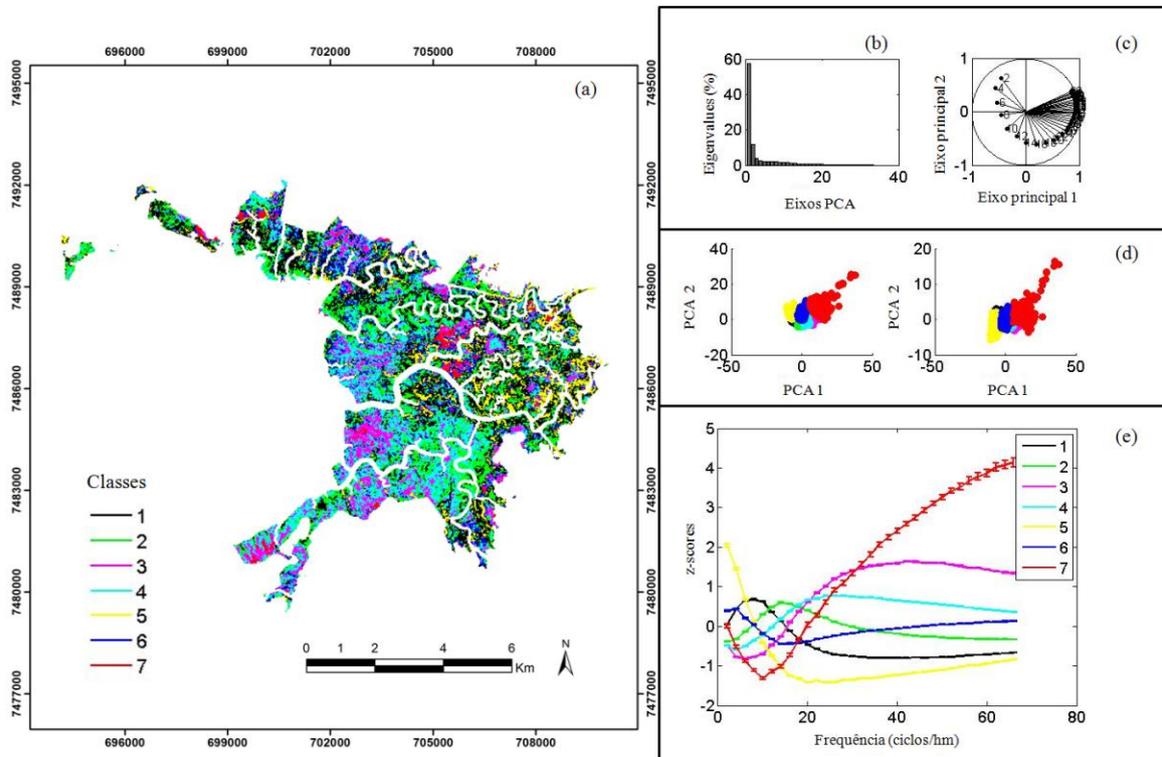
Como mencionado anteriormente, não foi possível estimar satisfatoriamente a AGB com uso dos índices FOTO. Entretanto, a classificação RF com uso desses índices

apresentou bons resultados para distinguir diferentes classes de cobertura do manguezal com destaque para o índice PCA1-FOTO100, sugerindo caminhos e estratégias para pesquisas futuras.

Análise complementar das características dos índices texturais FOTO (janela de análise 100 pixels)

Para uma segunda abordagem de classificação, por meio da análise de agrupamento *k-médias* sobre os valores de *r-spectra* médios das janelas de análise de 100 pixels (obtidos com o método FOTO aplicado na imagem pancromática na escala da paisagem), foi possível observar algumas características dos índices texturais FOTO. Foi analisada toda a cobertura do manguezal na área de estudo incluindo áreas de mangue denso mais preservado, mangue alterado com presença de clareiras e áreas com domínio de espécies invasoras e solo exposto. A Figura 5.17 mostra em (a) as classes do agrupamento *k-médias* espacializado no manguezal da área de estudo, (b) porcentagem da variância total das componentes da PCA, (c) círculo de correlação da PCA com as janelas de análise representativas, (d) PCA com os agrupamentos *k-médias* indicando a granulometria do dossel identificada pela análise de agrupamento *k-médias* sobre os valores *r-spectra*, (e) comportamento característico dos *r-spectra* médio das 7 classes de agrupamento *k-médias*. A combinação colorida das componentes R-PCA1, G-PCA2 e B-PCA3 referentes à janela de 100 pixels é mostrada na Figura 5.18. Observa-se na Figura 5.18 em tons mais verdes e brancos as áreas não cobertas de floresta de mangue, mas com dominância de espécies associadas e espécies invasoras ou solo exposto. Estas mesmas áreas também se observam nos mapeamentos encontrados em Arasato et al. (2015) e PETROBRAS (2012).

Figura 5.17. Resultado do agrupamento *k*-médias sobre os valores de *r*-spectra para o FOTO janela de análise de 100 pixels.



Resultado do agrupamento *k*-médias sobre os valores de *r*-spectra para o FOTO janela de análise de 100 pixels. (a) 7 classes do agrupamento espacializadas no manguezal da área de estudo. (b) Porcentagem da variância total dos eixos da análise de componentes principais (PCA) da tabela de *r*-spectra. (c) Correlação entre os eixos da PCA e as frequências espaciais (ciclos/hm). Cada direção radial no plano da PCA corresponde à importância relativa do *r*-spectrum de um intervalo particular de frequência espacial. (d) Granulometria do dossel identificada pela análise de agrupamento *k*-médias sobre os valores *r*-spectra das janelas de análise do método FOTO. (e) Comportamento característico dos *r*-spectra médio das 7 classes de agrupamento *k*-médias.

A componente PCA1 FOTO 100 explicou quase 60% da variabilidade total (Figura 5.17 b). As frequências espaciais são consideradas os números de repetições de um padrão periódico. A ordenação textural da cobertura do manguezal apresentou resultados mais significativos nos dois primeiros eixos das PCAs (Figura 5.17c). A Figura 5.17c referente ao círculo de correlação, ilustra que tipo de frequência espacial caracteriza a PCA1 e a PCA2. Frequências mais altas estão em oposição às frequências mais baixas e se distribuem ao longo do eixo da PCA1. Porém, observa-se um aglomerado de frequências médias e altas no eixo principal 1, mostrando a pouca distinção entre elas

(Figura 5.17c). As baixas frequências espaciais se relacionam com texturas de maior rugosidade associadas à granulometria dos dosséis. As altas frequências espaciais são relacionadas com texturas finas de copas menores. O ordenamento das 7 classes referentes ao agrupamento *k-médias* (Figura 5.17 d) e o respectivo comportamento do *r-spectra* médio de cada classe do agrupamento (Figura 5.17 e) mostram a alta frequência espacial para a classe 7 em vermelho e classe 3 em rosa e mostra a baixa frequência para as classes 1 em preto, 5 em amarelo e 6 em azul. O agrupamento *k-médias* possibilitou separar 7 classes texturais representadas nos exemplos das janelas de análise com a Figura 5.19. Estas representações podem auxiliar no entendimento do erro de classificação RF das classes *mangue-denso* e *não-mangue* (Tabela 5.8). No agrupamento *k-médias* da Figura 5.17a observa-se em vermelho a classe 7 referente a áreas de não cobertura de mangue e presença de solo exposto (Figura 5.19). Observa-se também em rosa a classe 3 referente a áreas de *mangue-denso*, porém com confusão com a classe *não-mangue*. Para a classe 3 observa-se que o dossel é denso e homogêneo e a textura é menos rugosa do que em áreas de clareiras entre os dosséis densos, como na classe 1 (Figura 5.19).

Como discutido em PLOTON et al., (2012), o método FOTO apresenta limitações para a detecção de padrões texturais do dossel florestal quando os dosséis são de diferentes tipos florestais, heterogêneos e complexos. Alguns padrões texturais podem não estar relacionados com a homogeneidade característica de dosséis com grandes copas, mas sim com a presença de clareiras ou variações de iluminação, causando uma heterogeneidade espacial e padrões de textura grossa semelhantes aos de dosséis com grandes copas. A classe 1 da análise *k-médias* (Figura 5.19) é um exemplo onde diferentes padrões de dosséis são agrupados em uma mesma classe de textura. No presente trabalho observa-se uma confusão de padrões texturais na classe 3 com a presença de dosséis de *mangue-denso* e áreas caracterizadas por espécies invasoras/associadas (Figura 5.19).

Figura 5.18 - Composição colorida (RGB) utilizando as 3 primeiras componentes da PCA obtidas com o método FOTO janela de análise de 100 pixels RPCA1/GPCA2/BPCA3.

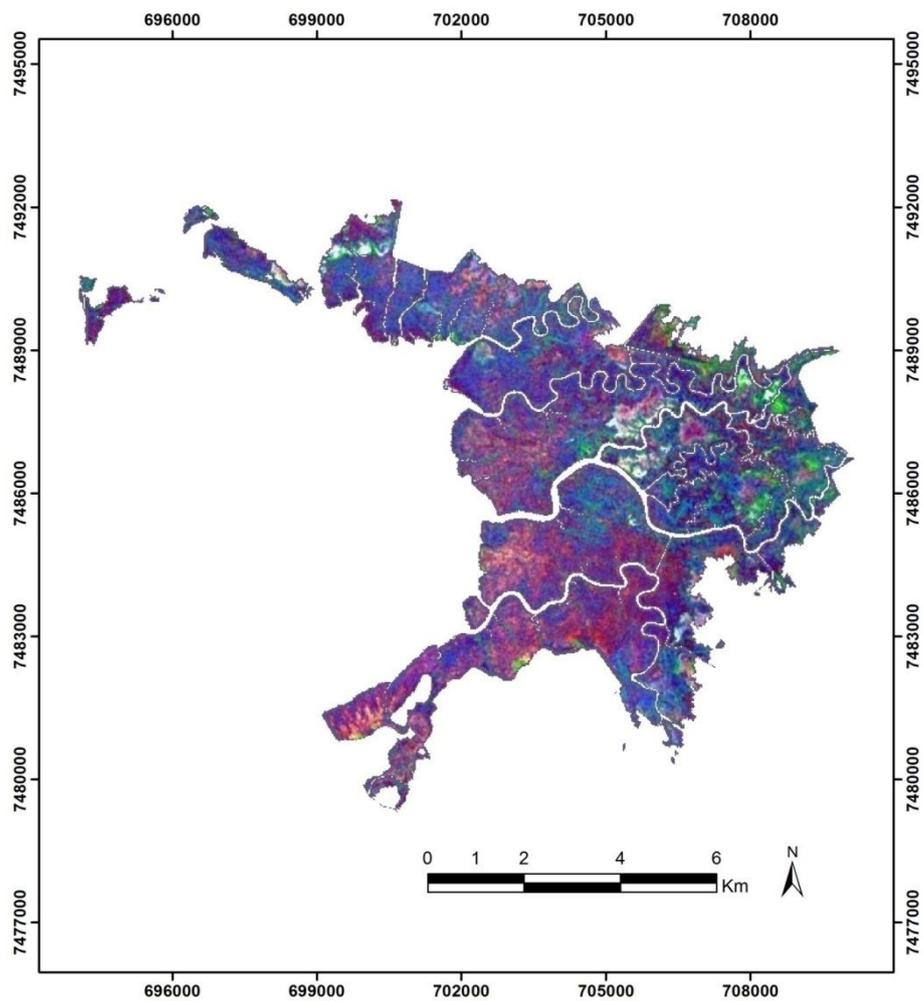
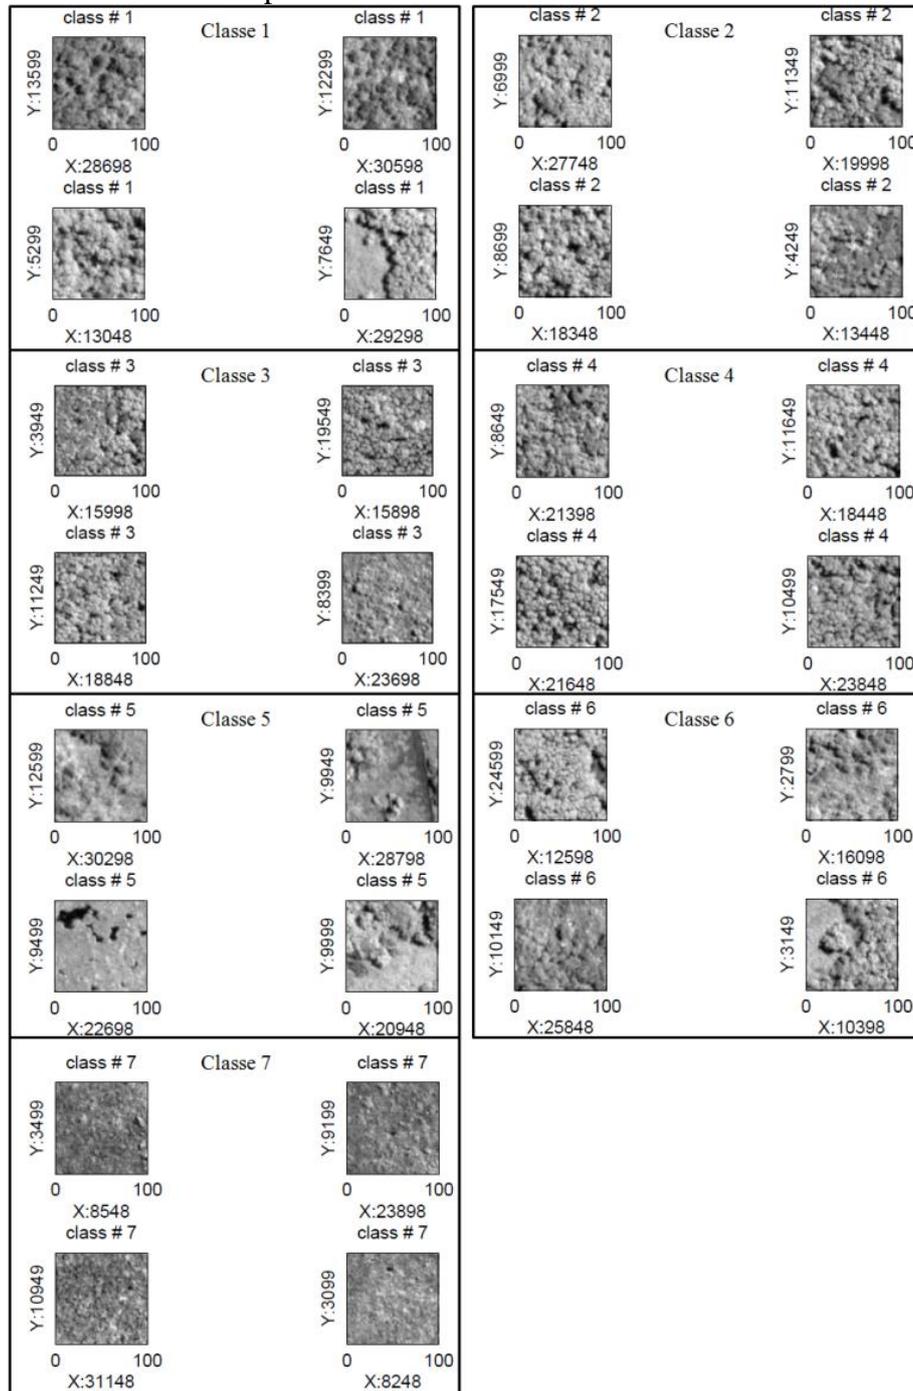


Figura 5.19 - Recortes da imagem pancromática representativos de cada janela de análise de 100 pixels.



Recortes da imagem pancromática representativos de cada janela de análise de 100 pixels, obtidos com o método FOTO, exemplificando o padrão textural dos dosséis de cada classe obtida pelo o agrupamento *k-médias*.

De forma geral, pode-se observar uma variabilidade textural nos recortes referentes às janelas de cada classe nas imagens mostradas na Figura 5.19. Os padrões texturais

relacionados com as frequências espaciais relativas às 7 classes (Figura 5.17e) indicam altas frequências em áreas com características de rugosidade fina. De modo inverso, baixas frequências são associadas a áreas com características de rugosidade grossa. Como anteriormente mencionado, as áreas de dosséis com grandes clareiras e espécies não-mangue (ou áreas de mangue tipicamente alterado) são caracterizadas por uma maior rugosidade do que as áreas de dosséis densos e homogêneos com grandes copas em bosques desenvolvidos (ou áreas mais preservadas). Estas características se refletem nos valores dos índices texturais explicando a fraca correlação com os valores de AGB anteriormente apresentados. Porém, a discriminação das classes de tipos de cobertura do manguezal foi melhor realizada.

O presente trabalho contribui com a identificação de algumas limitações do método FOTO. A variabilidade textural observada nas imagens pancromáticas está relacionada com características do dossel florestal e cobertura do solo (com florestas preservadas, alteradas e presença de clareiras). Estas características locais acarretam diferenças nos índices texturais associadas à heterogeneidade e complexidade da cobertura florestal. Resultados mais promissores são obtidos quando os dosséis florestais são menos complexos, e cujos padrões heterogêneos representam principalmente diferenças nos tamanhos das copas devido a diferentes estágios de desenvolvimento estrutural da floresta de estudo. Os resultados da classificação RF demonstram o uso potencial de alguns índices texturais FOTO e GLCM e métricas LiDAR para discriminar tipos de cobertura do manguezal. Esta abordagem pode ser útil como ferramenta de identificação de áreas alteradas, degradadas, desmatadas e até áreas de floresta de mangue mais saudável. As alterações que têm ocorrido nas áreas cobertas por manguezais devido a processos de urbanização, desmatamento e conversão em caricultura têm levado a perdas consideráveis de vegetação e de todos os benefícios que este ecossistema presta para o meio ambiente e comunidades costeiras. A detecção de alterações, assim como a quantificação e qualificação do estado do ecossistema são necessárias e urgentes. O uso de técnicas de sensoriamento remoto pode contribuir com as estratégias de monitoramento e gestão da APA de Guapimirim que contempla o ecossistema manguezal e a zona costeira associada.

6 CONCLUSÕES

O presente estudo foi norteado por três questões científicas, como apresentadas na introdução: *1-O quão precisa é a estimativa de biomassa de bosques de mangue com distintos graus de alteração com uso de dados LiDAR? 2- Qual o potencial da análise textural aplicada a imagens ópticas de alta resolução espacial para estimar a biomassa de floresta de mangue com distintos graus de alteração? 3-É possível distinguir tipos de bosques de mangue em diferentes estágios de alteração por meio de análise textural?* De acordo com os processamentos adotados e os resultados obtidos no presente estudo pode-se comprovar que o uso de dados LiDAR de retorno discreto para estimativa de biomassa foi efetivo e superior aos resultados obtidos com uso dos índices texturais FOTO e GLCM extraídos da imagem óptica de alta resolução. Os dados LiDAR penetram no interior do dossel florestal, mensuram a altura do dossel e dos estratos, caracterizam a estrutura do mangue, e permitem estimar a AGB com maior precisão do que os dados ópticos. O modelo preditivo mais acurado da AGB (M2a) apresentou $R^2(\text{CAL}) = 0,89$, $R^2(\text{LOO}) = 0,81$, $\text{RMSE}(\text{LOO}) = 14,80$ t/ha, $\text{RMSE}(\text{CAL}) = 11,20$ t/ha e $\text{RSE}\% = 8,90$. Foi gerado com as métricas estatísticas obtidas da nuvem de pontos LiDAR como variáveis preditoras e com uso do método de regressão AutoPLS. O mapeamento do manguezal na área de estudo contabilizou 561.374,0 toneladas de AGB de floresta de mangue para uma área de 5.432,0 hectares, Isto equivale a uma AGB média de 103,4 t/ha. As variáveis preditoras do modelo M2a que mais contribuíram para a estimativa de AGB foram avg, min, max, d02, d03, d04, d05, d08 demonstrando que informações sobre a densidade de pontos relativa aos estratos estruturais da floresta são importantes variáveis para as estimativas de biomassa em florestas com distintos graus de alteração. Os resultados estatísticos de desempenho do modelo obtidos neste trabalho mostraram-se consistentes com resultados obtidos para a estimativa de AGB em outros tipos florestais. As variáveis de densidade de pontos LiDAR proporcionais à altura caracterizam os estratos dos dosséis e o interior dos bosques de mangue. Desta forma, possibilitam a identificação de bosques de mangue com dosséis preservados estruturalmente, bem como bosques de mangue alterados, com clareiras, troncos mortos, estruturalmente alterados/degradados.

Este pode ser o primeiro esforço realizado para estimar a AGB de uma área relativamente extensa (~58,2 km²) de manguezal com distintos graus de alteração no Brasil com o uso de métricas estatísticas derivadas de dados LiDAR de retorno discreto. O mapa de AGB gerado pode ser utilizado como uma fonte de informações quantitativas e qualitativas da biomassa atual da floresta de mangue na APA de Guapimirim. Pode servir também como base para futuras análises sobre o manguezal e estimativas de carbono florestal, contribuindo com informações objetivas para a tomada de decisão e formulação de políticas públicas no âmbito do gerenciamento costeiro (GERCO) e REDD+, entre outras finalidades.

A estimativa da AGB de bosques de mangue com distintos graus de alteração com uso dos índices texturais FOTO e GLCM não apresentou resultados consistentes. O padrão de variabilidade textural que reflete as características dos dosséis florestais mensurados com os índices texturais não apresentou forte relação com os valores de AGB dos bosques de mangue. Para o método FOTO, as áreas de mangue alterado, com clareiras ou com copas maiores e sombras, apresentaram padrão textural de rugosidade mais grossa, com baixa frequência espacial. Algumas áreas com características de mangue desenvolvido e com dosséis mais homogêneos e sem grandes clareiras apresentaram índices texturais com padrão semelhante ao de outras áreas homogêneas com frequência espacial mais alta. Esta relativa confusão entre algumas características dos bosques de mangue e os padrões texturais observados não permitiu obter uma boa correlação ou variação textural coerente entre os índices texturais e os valores de AGB. Este comportamento foi observado tanto na análise das 34 parcelas de campo como de todo o manguezal da área da APA com a simulação de pontos aleatórios cobrindo uma maior diversidade estrutural da vegetação.

Por outro lado, o uso de índices texturais FOTO e GLCM na classificação Random Forest apresentou resultados satisfatórios permitindo discriminar diferentes classes de cobertura do manguezal como áreas de *não-mangue*, *mangue-alterado* e *mangue-denso*. Desta forma, a análise textural de imagens ópticas de alta resolução pode ser uma ferramenta útil no planejamento ambiental do ecossistema manguezal e da própria APA, ajudando a definir as áreas prioritárias para recuperação e monitoramento.

A estimativa de biomassa de bosques de mangue com uso de dados LiDAR de retorno discreto mostrou-se superior às estimativas realizadas com o uso de informações texturais obtidas da imagem óptica de alta resolução para este tipo de condição florestal, com distintos graus de alteração. Sugere-se em trabalho futuro aplicar o método FOTO em outros tipos florestais, como por exemplo, em floresta tropical densa com distintos graus de degradação/alteração, para averiguar a eficácia e para aprimorar a análise e estimativa de AGB em áreas degradadas utilizando este método.

Como mencionado anteriormente, a área de estudo apresenta outras espécies como *Acrostichum* e *Hibiscus*. No entanto, a estimativa de AGB em campo é calculada apenas para as espécies de mangue. Assim, sugere-se em trabalho futuro estimar a AGB total da área de estudo incluindo as outras espécies encontradas nas parcelas de campo e em outras áreas específicas com dominância destas espécies. Com isto, as incertezas nos modelos de estimativa de AGB do manguezal com uso de dados LiDAR podem ser reduzidas possibilitando estimar com maior exatidão a AGB de toda a vegetação encontrada no manguezal alterado. Recomenda-se, também, incluir mais parcelas de campo de modo a melhor representarem a diversidade estrutural dos bosques de mangue encontrados na área de estudo, como os bosques estruturalmente menos desenvolvidos, e assim melhorar o ajuste do modelo de estimativa de AGB.

Recomenda-se, também, dar continuidade à exploração de outras fontes e técnicas de sensoriamento remoto para estimar a AGB do manguezal com distintos graus de alteração de forma comparativa com os resultados obtidos com LiDAR. Comparações temporais entre as situações atual e futuras são também desejáveis.

Devido à importância dos manguezais para a regulação dos fluxos de carbono e controle das mudanças climáticas, com suas funções ecológicas essenciais para a manutenção da vida de muitas espécies costeiras e marinhas e seus valiosos serviços prestados à zona costeira tropical, torna-se essencial obter estimativas acuradas de sua biomassa e carbono, efetuando-se a sua devida caracterização e monitoramento para fins de conservação e preservação deste ecossistema. O presente estudo demonstra a eficácia do uso de técnicas de sensoriamento remoto, em especial de dados LiDAR de retorno discreto, para estimar a AGB de bosques de mangue e discriminar tipos de cobertura no

manguezal. Os resultados aqui apresentados podem contribuir com a análise e caracterização estrutural do manguezal, quantificação e qualificação da AGB e carbono, bem como contribuir com o monitoramento, formulação de políticas públicas de conservação e proteção do ecossistema, auxiliando a sua gestão. Salienta-se ainda o potencial dos dados LiDAR de retorno discreto para estimar e mapear a AGB com boa acurácia contribuindo com as estimativas globais de AGB e carbono florestal relevantes no âmbito de políticas de redução do desmatamento e controle do aquecimento global como o REDD+.

REFERÊNCIAS BIBLIOGRÁFICAS

ABREU, M. R. B. S. **Mapeamento dos parâmetros florísticos e estruturais de floresta de mangue com dados LiDAR e SRTM**. 2014. 56f. Dissertação (Mestrado do Programa de Pós-Graduação em Geologia e Geoquímica.)- Universidade Federal do Pará, Instituto de Geociências, Belém, 2014.

ALONGI, D. M. Carbon cycling and storage in mangrove forests. **Annu. Rev. Mar. Sci.**, v. 6, n. January 2014, p. 195–219, 2014.

ALONGI, D. M. Present state and future of the world's mangrove forests. **Environmental Conservation**, v. 29, n. 03, p. 331–349, 13 nov. 2002. Disponível em: <http://www.journals.cambridge.org/abstract_S0376892902000231>. Acesso em: 23 jan. 2014.

ALONGI, D. M. **The energetics of mangrove forests**. Dordrecht: Springer Netherlands, 2009. Disponível em: <<http://link.springer.com/10.1007/978-1-4020-4271-3>>.

ALONGI, D. M. The impact of climate change on mangrove forests. **Curr Clim Change Rep**, v. 1, n. April, p. 30–39, 2015. Disponível em: <<http://www.springerlink.com/index/10.1007/978-90-481-2945-4>>.

ALONGI, D. M.; MUKHOPADHYAY, S. K. Contribution of mangroves to coastal carbon cycling in low latitude seas. **Agricultural and Forest Meteorology**, v. 213, n. November 2014, p. 266–272, 2015.

ANDERSEN, H.-E.; MCGAUGHEY, R. J.; REUTEBUCH, S. E. Estimating forest canopy fuel parameters using LIDAR data. **Remote Sensing of Environment**, v. 94, n. 4, p. 441–449, fev. 2005. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S034425704003438>>. Acesso em: 20 jan. 2014.

ARASATO, L. S.; BENTZ, C. M.; FONSECA, M. G.; GUERRA, J. B.; PAES, J. E. S.; FREITAS, L. R.; COSTA, U. E.; LUIZ, S. Avaliação do uso de modelos LiDAR e Worldview-1 para a caracterização e monitoramento de manguezais. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 17. (SBSR), 2015, João Pessoa. **Anais...** São José dos Campos: INPE, 2015. p. 5050-5057. Internet. ISBN 978-85-17-0076-8. Disponível em: <<http://urlib.net/8JMKD3MGP6W34M/3JM4DHR>>. Acesso em: 05 março. 2016.

ARASATO, L. S.; BENTZ, C. M.; SILVA, R. S. B.; GUERRA, J. B.; PAES, J. E. S.; FREITAS, L. R.; LUIZ, S. Uso do sensoriamento remoto ótico de alta resolução para a caracterização e monitoramento qualitativo de manguezais. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 17. (SBSR), 2015, João Pessoa. **Anais...** São José dos Campos: INPE, 2015. p. 5141-5148. Internet. ISBN 978-85-17-0076-8. Disponível em: <<http://urlib.net/8JMKD3MGP6W34M/3JM4DLH>>.

ARAUJO, D. S. D.; MACIEL, N. C. **Os Manguezais do Recôncavo da Guanabara**. Rio de Janeiro: FEEMA, 1979.

ASNER, G. P.; FLINT HUGHES, R.; VARGA, T. A.; KNAPP, D. E.; KENNEDY-BOWDOIN, T. Environmental and biotic controls over aboveground biomass throughout a tropical rain forest. **Ecosystems**, v. 12, n. 2, p. 261–278, 2009.

ASNER, G. P.; MASCARO, J. Mapping tropical forest carbon: Calibrating plot estimates to a simple LiDAR metric. **Remote Sensing of Environment**, v. 140, p. 614–624, 2014. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2013.09.023>>.

ASNER, G. P.; MASCARO, J.; MULLER-LANDAU, H. C.; VIEILLEDENT, G.; VAUDRY, R.; RASAMOELINA, M.; HALL, J. S.; VAN BREUGEL, M. A universal airborne LiDAR approach for tropical forest carbon mapping. **Oecologia**, v. 168, n. 4, p. 1147–1160, 2012.

ASNER, G. P.; POWELL, G. V. N.; MASCARO, J.; KNAPP, D. E.; CLARK, J. K.; JACOBSON, J.; KENNEDY-BOWDOIN, T.; BALAJI, A.; PAEZ-ACOSTA, G.; VICTORIA, E.; SECADA, L.; VALQUI, M.; HUGHES, R. F. High-resolution forest carbon stocks and emissions in the Amazon. **Proceedings of the National Academy of Sciences of the United States of America**, v. 107, n. 38, p. 16738–42, 2010. Disponível em: <<http://www.pnas.org/cgi/content/long/107/38/16738>>.

AXELSSON, P. Processing of laser scanner data—algorithms and applications. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 54, n. 2-3, p. 138–147, jul. 1999. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0924271699000088>>.

BALTSAVIAS, E. . Airborne laser scanning: basic relations and formulas. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 54, n. 2-3, p. 199–214, jul. 1999. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0924271699000155>>.

BALZTER, H.; ROWLAND, C. S.; SAICH, P. Forest canopy height and carbon estimation at Monks Wood National Nature Reserve, UK, using dual-wavelength SAR interferometry. **Remote Sensing of Environment**, v. 108, n. 3, p. 224–239, 2007.

BANSKOTA, A.; WYNNE, R. H.; JOHNSON, P.; EMESSIENE, B. Synergistic use of very high-frequency radar and discrete-return lidar for estimating biomass in temperate hardwood and mixed forests. **Annals of Forest Science**, v. 68, n. 2, p. 347–356, 2011.

BARBIER, N.; COUTERON, P.; LEJOLY, J.; DEBLAUWE, V.; LEJEUNE, O. Self-organized vegetation patterning as a fingerprint of climate and human impact on semi-arid ecosystems. **Journal of Ecology**, v. 94, n. 3, p. 537–547, 10 abr. 2006. Disponível em: <<http://doi.wiley.com/10.1111/j.1365-2745.2006.01126.x>>. Acesso em: 23 jan. 2014.

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. **Global Ecology and Biogeography**, v. 19, n. 1, p. 72–84, 2010.

BARBOSA, J. M.; BROADBENT, E. N.; BITENCOURT, M. D. Remote sensing of aboveground biomass in tropical secondary forests: a review. **International Journal of Forestry Research**, v. 2014, p. 1–14, 2014. Disponível em: <<http://www.hindawi.com/journals/ijfr/2014/715796/>>.

BARKMAN, J. J. A new method to determine some characters of vegetation structure. **Vegetatio**, v. 78, n. 1-2, p. 81–90, dez. 1988. Disponível em: <<http://link.springer.com/10.1007/BF00045642>>.

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. **Ecological Applications**, v. 24, n. 8, p. 1984–2001, 2014. Disponível em: <<http://www.esajournals.org/doi/10.1890/13-1574.1>>.

BEETS, P. N.; BRANDON, A. M.; GOULDING, C. J.; KIMBERLEY, M. O.; PAUL, T. S. H.; SEARLES, N. The national inventory of carbon stock in New Zealand's pre-1990 planted forest using a LiDAR incomplete-transect approach. **Forest Ecology and Management**, v. 280, p. 187–197, 2012. Disponível em: <<http://dx.doi.org/10.1016/j.foreco.2012.05.035>>.

BLASCO, F.; GAUQUELIN, T.; RASOLOFOHARINORO, M.; DENIS, J.; AIZPURU, M.; CALDAIROU, V. Recent advances in mangrove studies using remote sensing data. **Marine and Freshwater Research**, n. 49, n. 4, p. 287–296, 1998.

BOUDREAU, J.; NELSON, R.; MARGOLIS, H.; BEAUDOIN, A.; GUINDON, L.; KIMES, D. Regional aboveground forest biomass using airborne and spaceborne LiDAR in Québec. **Remote Sensing of Environment**, v. 112, n. 10, p. 3876–3890, 2008. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0034425708001995>>.

BRANDTBERG, T.; WARNER, T. A.; LANDENBERGER, R. E.; MCGRAW, J. B. Detection and analysis of individual leaf-off tree crowns in small footprint, high sampling density lidar data from the eastern deciduous forest in North America. **Remote Sensing of Environment**, v. 85, n. 3, p. 290–303, 30 maio 2003. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0034425703000087>>.

BREIMAN, L. Random forests. **Machine learning**, p. 5–32, 2001. Disponível em: <<http://link.springer.com/article/10.1023/A:1010933404324>>.

BROWN, I.; MWANSASU, S.; WESTERBERG, L.-O. L-band polarimetric target decomposition of mangroves of the Rufiji Delta, Tanzania. **Remote Sensing**, v. 8, n. 2, p. 140, 2016. Disponível em: <<http://www.mdpi.com/2072-4292/8/2/140/htm>>.

CAVALCANTI, V. F.; SOARES, M. L. G.; ESTRADA, G. C. D.; CHAVES, F. O. Evaluating mangrove conservation through the analysis of forest structure data. **J. Coast. Res.**, v. 2009, n. 56, p. 390–394, 2009.

CHADWICK, J. Integrated LiDAR and IKONOS multispectral imagery for mapping mangrove distribution and physical properties. **International Journal of Remote Sensing**, v. 32, n. 21, p. 6765–6781, 10 nov. 2011. Disponível em: <<http://www.tandfonline.com/doi/abs/10.1080/01431161.2010.512944>>. Acesso em: 23 jan. 2014.

CHAMBERS, R. L.; CLARK, R. G. **An introduction to model-based survey sampling with applications**. Oxford: Oxford University Press, 2012.

CHEN, Q.; GONG, P.; BALDOCCHI, D.; XIE, G. Filtering airborne laser scanning data with morphological methods. **Photogrammetric Engineering & Remote Sensing**, v. 73, n. 2, p. 175–185, 1 fev. 2007. Disponível em: <<http://essential.metapress.com/openurl.asp?genre=article&id=doi:10.14358/PERS.73.2.175>>.

CHEN, Q.; VAGLIO LAURIN, G.; VALENTINI, R. Uncertainty of remotely sensed aboveground biomass over an African tropical forest: Propagating errors from trees to plots to pixels. **Remote Sensing of Environment**, v. 160, p. 134–143, 2015. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2015.01.009>>.

CINTRÓN, G.; LUGO, A. E.; MARTINEZ, R. Structure and functional properties of mangrove forest. In: D'ARCY, W. G.; CORREA, M. D. (Org.). **The botany and natural history of Panama**. [S.l.]: St. Louis, Missouri: Missouri Botanical Garden, 1985. v. 10. p. 53–66. Disponível em: <http://www.scielo.br/scielo.php?script=sci_nlinks&ref=000083&pid=S0100-8404200600040001800006&lng=pt>.

CLARK, M. L.; ROBERTS, D. A.; EWEL, J. J.; CLARK, D. B. Estimation of tropical rain forest aboveground biomass with small-footprint lidar and hyperspectral sensors. **Remote Sensing of Environment**, v. 115, n. 11, p. 2931–2942, 2011. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0034425711001404>>.

COLWELL, J. E. Vegetation canopy reflectance. **Remote Sensing of Environment**, v. 3, n. 3, p. 175–183, jan. 1974. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/0034425774900030>>.

COUGO, M.; SOUZA-FILHO, P.; SILVA, A.; FERNANDES, M.; SANTOS, J.; ABREU, M.; NASCIMENTO, W.; SIMARD, M. Radarsat-2 Backscattering for the modeling of biophysical parameters of regenerating mangrove forests. **Remote Sensing**, v. 7, n. 12, p. 17097–17112, 2015. Disponível em: <<http://www.mdpi.com/2072-4292/7/12/15873>>.

COUTERON, P. Quantifying change in patterned semi-arid vegetation by Fourier analysis of digitized aerial photographs. **International Journal of Remote Sensing**, v. 23, n. 17, p. 3407–3425, jan. 2002. Disponível em: <<http://www.tandfonline.com/doi/abs/10.1080/01431160110107699?journalCode=tres20#preview>>.

COUTERON, P.; BARBIER, N.; GAUTIER, D. Textural ordination based on Fourier spectral decomposition: A Method to Analyze and Compare Landscape Patterns. **Landscape Ecology**, v. 21, n. 4, p. 555–567, maio 2006. Disponível em: <<http://link.springer.com/10.1007/s10980-005-2166-6>>. Acesso em: 20 jan. 2014.

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. **Journal of Applied Ecology**, v. 42, n. 6, p. 1121–1128, 31 dez. 2005. Disponível em: <<http://doi.wiley.com/10.1111/j.1365-2664.2005.01097.x>>. Acesso em: 23 jan. 2014.

CUNHA-LIGNON, M.; COELHO-JR, C.; ALMEIDA, R.; MENGHINI, R. P.; SCHAEFFER-NOVELI, Y.; CINTRÓN, G.; DAHDOUH-GUEBAS, F. Characterisation of mangrove forest types in view of conservation and management: a review of mangals at the Cananéia region, São Paulo State, Brazil. 2011, **Journal of Coastal Research**, p. 349-353, 2011.

D'OLIVEIRA, M. V. N.; REUTEBUCH, S. E.; MCGAUGHEY, R. J.; ANDERSEN, H. E. Estimating forest biomass and identifying low-intensity logging areas using airborne scanning lidar in Antimary State Forest, Acre State, Western Brazilian Amazon. **Remote Sensing of Environment**, v. 124, p. 479–491, 2012. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2012.05.014>>.

DAHDOUH-GUEBAS, F. the use of remote sensing and gis in the sustainable management of tropical coastal ecosystems each of these habitats is formed by species that are to a large extent adapted to trop- intertidal forests that are composed of halotolerant plant species. **Environment, Development and Sustainability**, v. 4, n. 9, p. 93–112, 2002.

DAHDOUH-GUEBAS, F.; KAIRO, J. G.; JAYATISSA, L. P.; CANNICCI, S.; KOEDAM, N. An ordination study to view vegetation structure dynamics in disturbed and undisturbed mangrove forests in Kenya and Sri Lanka. **Plant Ecology**, v. 161, n. 1, p. 123–135, 2002.

DAHDOUH-GUEBAS, F.; KOEDAM, N. Empirical estimate of the reliability of the use of the Point-Centred Quarter Method (PCQM): Solutions to ambiguous field situations and description of the PCQM+ protocol. **Forest Ecology and Management**, v. 228, n. 1-3, p. 1–18, jun. 2006. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0378112706000776>>. Acesso em: 20 jan. 2014.

DAVID, L. C. G.; BALLADO, A. H. Mapping mangrove forest from lidar data using object-based image analysis and support vector machine: The case of Calatagan , Batangas. International conference on humanoid, nanotechnology, information technology, communication and control, environment and management (HNICEM), 2015, Cebu City, Philippines. **Proceedings... IEEE**, 2015.

DE SOUZA PEREIRA, F. R.; KAMPEL, M.; CUNHA-LIGNON, M. Mangrove vegetation structure in Southeast Brazil from phased array L-band synthetic aperture radar data. **Journal of Applied Remote Sensing**, v. 10, n. 3, p. 036021, 2016. Disponível em: <<http://remotesensing.spiedigitallibrary.org/article.aspx?doi=10.1117/1.JRS.10.036021>>.

DONATO, D. C.; KAUFFMAN, J. B.; MURDIYARSO, D.; KURNIANTO, S.; STIDHAM, M.; KANNINEN, M. Mangroves among the most carbon-rich forests in the tropics. **Nature Geoscience**, v. 4, n. 5, p. 293–297, 3 abr. 2011. Disponível em: <<http://www.nature.com/doifinder/10.1038/ngeo1123>>. Acesso em: 21 jan. 2014.

DUKE, N. C.; BALL, M. C.; ELLISON, J. C. Factors influencing biodiversity and distributional gradients in mangroves. **Global Ecology and Biogeography Letters**, v. 7, n. 1, p. 27–47, 1998. Disponível em: </home/ja/Documentos/Juan/Biblio/GEBL7(1)27-47.pdf>.

DUKE, N. C.; MEYNECKE, J.-O.; DITTMANN, S.; ELLISON, A. M.; ANGER, K.; BERGER, U.; CANNICCI, S.; DIELE, K.; EWEL, K. C.; FIELD, C. D.; KOEDAM, N.; LEE, S. Y.; MARCHAND, C.; NORDHAUS, I.; DAHDOUH-GUEBAS, F. A World without mangroves? **Science**, v. 317, n. 5834, p. 41b–42b, 6 jul. 2007. Disponível em: <<http://www.sciencemag.org/cgi/doi/10.1126/science.317.5834.41b>>.

ECKERT, S. Improved forest biomass and carbon estimations using texture measures from WorldView-2 satellite data. **Remote Sensing**, v. 4, n. 4, p. 810–829, 2012.

EDSON, C.; WING, M. G. **Airborne Light Detection and Ranging (LiDAR) for Individual tree stem location, height, and biomass measurements**. 2011. v. 3. Disponível em: <<http://www.mdpi.com/2072-4292/3/11/2494/>>. Acesso em: 20 jan. 2014.

ELVIDGE, C. D.; CHEN, Z. Comparison of broad-band and narrow-band red and near-infrared vegetation indices. **Remote Sensing of Environment**, v. 54, n. 1, p. 38-48, Oct. 1995.

ESTRADA, G. C. D. **Análise da variabilidade estrutural de florestas de mangue de Guaratiba, Rio de Janeiro - RJ**. 2009. 94 f. Dissertação (Mestrado em Ciências Biológicas - Ecologia) - Universidade Federal do Rio de Janeiro, 2009.

ESTRADA, G. C. D. **Análise espaço-temporal do sequestro e estoque de carbono na biomassa aérea de manguezais**. 2013. 276 f. Tese (Doutorado em Ciências Biológicas - Ecologia) - Universidade Federal do Rio de Janeiro, 2013.

ESTRADA, G. C. D.; SOARES, M. L. G.; FERNADEZ, V.; DE ALMEIDA, P. M. M. The economic evaluation of carbon storage and sequestration as ecosystem services of mangroves: a case study from southeastern Brazil. **International Journal of Biodiversity Science, Ecosystem Services & Management**, v. 11, n. 1, p. 29–35, 2014. Disponível em: <<http://www.scopus.com/inward/record.url?eid=2-s2.0-84926666282&partnerID=tZOtx3y1>>.

ESTRADA, G. C. D.; SOARES, M. L. G.; SANTOS, D. M. C.; FERNANDEZ, V.; DE ALMEIDA, P. M. M.; ESTEVAM, M. R. DE M.; MACHADO, M. R. O. Allometric models for aboveground biomass estimation of the mangrove *Avicennia schaueriana*. **Hydrobiologia**, v. 734, n. 1, p. 171–185, 2014. Disponível em: <<http://link.springer.com/10.1007/s10750-014-1878-5>>.

EWEL, K. C.; TWILLEY, R. R.; ONG, J. E. Different kinds of mangrove forests provide different goods and services. **Global Ecology and Biogeography Letters**, v. 7, n. 1, p. 83, jan. 1998. Disponível em: <[http://sfrf.ufl.edu/facultysites/ewel/pubs/Mangrove/Ewel, Twilley, and Ong. 1998.pdf](http://sfrf.ufl.edu/facultysites/ewel/pubs/Mangrove/Ewel,Twilley,andOng.1998.pdf)><<http://dx.doi.org/10.1016/j.ecss.2014.03.007>><<http://www.wcs.org/EBMguide>><<http://dx.doi.org/10.1016/j.ecoser.2012.07.005>>.

FALKOWSKI, M. J.; SMITH, A. M. .; HUDAK, A. T.; GESSLER, P. E.; VIERLING, L. A; CROOKSTON, N. L. Automated estimation of individual conifer tree height and crown diameter via two-dimensional spatial wavelet analysis of lidar data. **Canadian Journal of Remote Sensing**, v. 32, n. 2, p. 153–161, abr. 2006. Disponível em: <<http://pubs.casi.ca/doi/abs/10.5589/m06-005>>.

FALKOWSKI, M. J.; SMITH, A. M. S.; GESSLER, P. E.; HUDAK, A. T.; VIERLING, L. A; EVANS, J. S. The influence of conifer forest canopy cover on the accuracy of two individual tree measurement algorithms using lidar data. **Canadian Journal of Remote Sensing**, v. 34, n. S2, p. S338–S350, 21 nov. 2008. Disponível em: <<http://pubs.casi.ca/doi/abs/10.5589/m08-055>>.

FAO. **The world's mangroves 1980–2005**. 2007, Rome: [s.n.], 2007. p. 153. Disponível em: <<ftp://ftp.fao.org/docrep/fao/010/a1427e/a1427e00.pdf>>.

FATOYINBO, T. E.; SIMARD, M. Height and biomass of mangroves in Africa from ICESat/GLAS and SRTM. **International Journal of Remote Sensing**, v. 34, n. 2, p. 668–681, 20 jan. 2013. Disponível em: <<http://www.tandfonline.com/doi/abs/10.1080/01431161.2012.712224>>. Acesso em: 23 jan. 2014.

FATOYINBO, T. E.; SIMARD, M.; WASHINGTON-ALLEN, R. A.; SHUGART, H. H. Landscape-scale extent, height, biomass, and carbon estimation of Mozambique's mangrove forests with Landsat ETM+ and Shuttle Radar Topography Mission elevation data. **Journal of Geophysical Research**, v. 113, n. G2, p. G02S06, 20 jun. 2008. Disponível em: <<http://doi.wiley.com/10.1029/2007JG000551>>. Acesso em: 23 jan. 2014.

FEKETY, P. A.; FALKOWSKI, M. J.; HUDAK, A. T. Temporal transferability of LiDAR-based imputation of forest inventory attributes. **Canadian Journal of Forest Research**, v. 435, n. September 2014, p. 422–435, 2015.

FELICIANO, E. A.; WADOWINSKI, S.; POTTS, M. D. Assessing mangrove above-ground biomass and structure using terrestrial laser scanning: a case study in the Everglades National Park. **Wetlands**, v. 34, n. 5, p. 955–968, 2014.

FRANKLIN, J. F.; SPIES, T. A.; PELT, R. VAN; CAREY, A. B.; THORNBURGH, D. A.; BERG, D. R.; LINDENMAYER, D. B.; HARMON, M. E.; KEETON, W. S.; SHAW, D. C.; BIBLE, K.; CHEN, J. Disturbances and structural development of natural forest ecosystems with silvicultural implications, using Douglas-fir forests as an example. **Forest Ecology and Management**, v. 155, n. 1-3, p. 399–423, jan. 2002. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0378112701005758>>.

FRAZER, G. W.; MAGNUSSEN, S.; WULDER, M. A.; NIEMANN, K. O. Simulated impact of sample plot size and co-registration error on the accuracy and uncertainty of LiDAR-derived estimates of forest stand biomass. **Remote Sensing of Environment**, v. 115, n. 2, p. 636–649, 2011. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2010.10.008>>.

FROMARD, F.; PUIG, H.; MOUGIN, E.; MARTY, G.; BETOULLE, J. L.; CADAMURO, L.; BETOULLE, M. J. L. Structure, above-ground biomass and dynamics of mangrove ecosystems: new data from French Guiana. **Oecologia**, v. 115, n. 1-2, p. 39–53, 8 jun. 1998. Disponível em: <<http://www.springerlink.com/openurl.asp?genre=article&id=doi:10.1007/s004420050489>>.

FU, W.; WU, Y. Estimation of aboveground biomass of different mangrove trees based on canopy diameter and tree height. **Procedia Environmental Sciences**, v. 10, p. 2189–2194, jan. 2011. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S187802961100538X>>. Acesso em: 23 jan. 2014.

GALVINCIO, J. D.; POPESCU, S. C. Measuring individual tree height and crown diameter for mangrove trees with airborne lidar data. **International Journal of Advanced Engineering, Management and Science**, v. 2, n. 5, p. 431–443, 2016.

GAO, J. A hybrid method toward accurate mapping of mangroves in a marginal habitat from SPOT multispectral data. **International Journal of Remote Sensing**, v. 19, n. 10, p. 1887-1899, 1998.

GILMAN, E. L.; ELLISON, J.; DUKE, N. C.; FIELD, C. Threats to mangroves from climate change and adaptation options: A review. **Aquatic Botany**, v. 89, n. 2, p. 237–250, ago. 2008. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S030437700800003X>>. Acesso em: 23 mar. 2012.

GIRI, C.; OCHIENG, E.; TIESZEN, L. L.; ZHU, Z.; SINGH, A.; LOVELAND, T.; MASEK, J.; DUKE, N. Status and distribution of mangrove forests of the world using earth observation satellite data. **Global Ecology and Biogeography**, v. 20, n. 1, p. 154–159, 17 jan. 2011. Disponível em: <<http://doi.wiley.com/10.1111/j.1466-8238.2010.00584.x>>. Acesso em: 29 fev. 2012.

GOETZ, S.; DUBAYAH, R. Advances in remote sensing technology and implications for measuring and monitoring forest carbon stocks and change. **Carbon Management**, v. 2, n. 3, p. 231–244, jun. 2011. Disponível em: <<http://www.future-science.com/doi/abs/10.4155/cmt.11.18>>.

GREEN, E. P.; CB, C.; CLARK, C. D.; MUMBY, P. J.; EDWARDS, A. J.; NE, T.; ELLIS, A. C.; CB, C.; CLARK, C. D.; MUMBY, P. J.; EDWARDS, A. J.; NE, T.; ELLIS, A. C. Remote sensing techniques for mangrove mapping. **International Journal of Remote Sensing**, v. 19, n. 5, p. 935–956, 1998.

GREEN, E. P.; MUMBY, P. J.; EDWARDS, A. J.; CLARK, C. D.; ELLIS, A. C. Estimating leaf area index of mangroves from satellite data. **Aquatic Botany**, v. 58, n. 1, p. 11–19, jul. 1997. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0304377097000132>>.

GREGOIRE, T. G.; NÆSSET, E.; MCROBERTS, R. E.; STÅHL, G.; ANDERSEN, H. E.; GOBAKKEN, T.; ENE, L.; NELSON, R. Statistical rigor in LiDAR-assisted estimation of aboveground forest biomass. **Remote Sensing of Environment**, v. 173, p. 98–108, 2016. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2015.11.012>>.

HABTEC. **Programa de Monitoramento dos Manguezais da APA Guapimirim e ESEC Guanabara** - Subplanos Vegetação - Relatório final. Rio de Janeiro, 2013.

HÄGER, A.; SCHWENDENMANN, L. Forest carbon sequestration and climate change. In: MOLINA-MURILLO, S. A.; ROJAS, C. (Org.). **The paradigm of forests and the survival of the fittest**. [S.l.]: CRC Press, 2016. p. 30–86.

HANSEN, E.; GOBAKKEN, T.; BOLLANDSÅS, O.; ZAHABU, E.; NÆSSET, E. Modeling aboveground biomass in dense tropical submontane rainforest using airborne laser scanner data. **Remote Sensing**, v. 7, n. 1, p. 788–807, 2015. Disponível em: <<http://www.mdpi.com/2072-4292/7/1/788/>>.

HARALICK, R. Statistical and structural approaches to texture. **Proceedings of the IEEE**, v. 67, n. 5, p. 786–804, 1979.

HARALICK, R.; SHANMUGAM, K. Computer classification of reservoir sandstones. **IEEE Transactions on Geoscience Electronics**, v. 11, n. 4, p. 171–177, out. 1973. Disponível em: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=4071646>>.

HARALICK, R.; SHANMUGAN, K.; DINSTEN, I. **Textural features for image classification. IEEE Transactions on Systems, Man and Cybernetics.** [S.l.: s.n.]. Disponível em: <[http://dceanalysis.bigr.nl/Haralick73-Textural features for image classification.pdf](http://dceanalysis.bigr.nl/Haralick73-Textural%20features%20for%20image%20classification.pdf)>. , 1973

HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. **The Elements of statistical learning - Data mining, inference, and prediction.** second ed. [S.l.]: Springer, 2009.

HAWBAKER, T. J.; KEULER, N. S.; LESAK, A. A.; GOBAKKEN, T.; CONTRUCCI, K.; RADELOFF, V. C. Improved estimates of forest vegetation structure and biomass with a LiDAR-optimized sampling design. **Journal of Geophysical Research: Biogeosciences**, v. 114, n. 3, p. 1–11, 2009.

HEUMANN, B. W. An object-based classification of mangroves using a hybrid decision tree-support vector machine approach. **Remote Sensing**, v. 3, n. 11, p. 2440–2460, 2011a.

HEUMANN, B. W. An Object-Based classification of mangroves using a hybrid decision tree—support vector machine approach. **Remote Sensing**, v. 3, n. 12, p. 2440–2460, 17 nov. 2011b. Disponível em: <<http://www.mdpi.com/2072-4292/3/11/2440/>>. Acesso em: 23 jan. 2014.

HIRATA, Y.; TABUCHI, R.; PATANAPONPAIBOON, P.; POUNGPARN, S.; YONEDA, R.; FUJIOKA, Y. Estimation of aboveground biomass in mangrove forests using high-resolution satellite data. **Journal of Forest Research**, v. 19, n. 1, p. 34–41, 28 mar. 2013. Disponível em: <<http://link.springer.com/10.1007/s10310-013-0402-5>>. Acesso em: 23 jan. 2014.

HOPKINSON, C.; CHASMER, L. E.; SASS, G.; CREED, I. F.; SITAR, M.; KALBFLEISCH, W.; TREITZ, P. Vegetation class dependent errors in lidar ground elevation and canopy height estimates in a boreal wetland environment. **Canadian Journal of Remote Sensing**, v. 31, n. 2, p. 191–206, abr. 2005. Disponível em: <<http://pubs.casi.ca/doi/abs/10.5589/m05-007>>.

HOUGHTON, R. A. Aboveground forest biomass and the global carbon balance. **Global Change Biology**, v. 11, n. 6, p. 945–958, jun. 2005. Disponível em: <<http://doi.wiley.com/10.1111/j.1365-2486.2005.00955.x>>. Acesso em: 23 jan. 2014.

HOUGHTON, R. A. Biomass. In: JORGENSEN, S. E.; FATH., B. D. (Org.). . **Encyclopedia of Ecology. Volumes 1-5.** [S.l.]: Elsevier, 2008.

HUANG, X.; ZHANG, L.; WANG, L. Evaluation of morphological texture features for mangrove forest mapping and species discrimination using multispectral IKONOS imagery. **IEEE Geoscience and Remote Sensing Letters**, v. 6, n. 3, p. 393–397, 2009.

HUDAK, A. T.; STRAND, E. K.; VIERLING, L. A.; BYRNE, J. C.; EITEL, J. U. H.; MARTINUZZI, S.; FALKOWSKI, M. J. Quantifying aboveground forest carbon pools and fluxes from repeat LiDAR surveys. **Remote Sensing of Environment**, v. 123, p. 25–40, 2012. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2012.02.023>>.

HUETE, A.; DIDAN, K.; MIURA, T.; RODRIGUEZ, E. .; GAO, X.; FERREIRA, L. . Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote Sensing of Environment**, v. 83, n. 1-2, p. 195–213, nov. 2002. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0034425702000962>>.

HYYPPÄ, J.; HYYPPÄ, H.; LECKIE, D.; GOUGEON, F.; YU, X.; MALTAMO, M. Review of methods of small-footprint airborne laser scanning for extracting forest inventory data in boreal forests. **International Journal of Remote Sensing**, revisão discussões, v. 29, n. 5, p. 1339–1366, mar. 2008. Disponível em: <<http://www.tandfonline.com/doi/abs/10.1080/01431160701736489>>. Acesso em: 20 jan. 2014.

HYYPPÄ, J.; INKINEN, M. Detecting and estimating attributes for single trees using laser scanner. **The Photogrammetric Journal of Finland**, v. 16, p. 27–42, 1999.

HYYPPÄ, J.; KELLE, O.; LEHIKONEN, M.; INKINEN, M. A segmentation-based method to retrieve stem volume estimates from 3-d tree height models produced by laser scanners. v. 39, n. 5, p. 969–975, 2001.

IBGE. **Instituto Brasileiro de Geografia e Estatística - Censo Demográfico 2000**. Disponível em: <www.ibge.gov.br>. Acesso em: 5 abr. 2014.

IBGE. **Instituto Brasileiro de Geografia e Estatística - Censo Demográfico 2010..** Disponível em: <www.ibge.gov.br>. Acesso em: 15 mar. 2016.

ICMBIO. **INSTITUTO CHICO MENDES DE CONSERVAÇÃO DA BIODIVERSIDADE (ICMBIO). *Área de proteção ambiental de Guapi-Mirim***. Disponível em: <<http://www.icmbio.gov.br/apaguapimirim/quem-somos.html>>. Acesso em: 3 abr. 2016.

INEA, I. E. D. A.-. **Elaboração do plano estadual de recursos hídricos do Estado do Rio de Janeiro: relatório diagnóstico**. Rio de Janeiro: [s.n.], 2014.

INMET, I. N. D. M.-. **Dados meteorológico**. Disponível em: <<http://www.inmet.gov.br/portal/index.php?r=bdmep/bdmep>>. Acesso em: 20 jun. 2016.

IPCC. 2006 IPCC Guidelines for National Greenhouse Gas Inventories. 2006, Japan: IGES, 2006. p. 673. Disponível em: <<https://www.ipcc.ch/meetings/session25/doc4a4b/vol4.pdf>>.

IPCC. 2013 Supplement to the 2006 IPCC guidelines for national greenhouse gas inventories: wetlands. 2014, Switzerland: IPCC, 2014. p. 354.

JACHOWSKI, N. R. A.; QUAK, M. S. Y.; FRIESS, D. A.; DUANGNAMON, D.; WEBB, E. L.; ZIEGLER, A. D. Mangrove biomass estimation in Southwest Thailand using machine learning. **Applied Geography**, v. 45, p. 311–321, 2013. Disponível em: <<http://dx.doi.org/10.1016/j.apgeog.2013.09.024>>.

JAHARI, M.; RASHID, A.; SHARIFF, M. Change detection studies in Matang mangrove forest area, Perak. v. 19, n. July 2010, p. 307–327, 2011.

JANSEN, P. A.; VAN DER MEER, P. J.; BONGERS, F. Spatial contagiousness of canopy disturbance in tropical rain forest: an individual-tree-based test. **Ecology**, v. 89, n. 12, p. 3490–502, dez. 2008. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/19137954>>.

JENSEN, J. R. **Remote Sensing of the Environment: An Earth Resource Perspective**. 2 ed ed. [S.l: s.n.], 2007.

KAMAL, M.; PHINN, S. Hyperspectral data for mangrove species mapping: A comparison of pixel-based and object-based approach. **Remote Sensing**, v. 3, n. 10, p. 2222–2242, 2011.

KAMAL, M.; PHINN, S.; JOHANSEN, K. Object-based approach for multi-scale mangrove composition mapping using multi-resolution image datasets. **Remote Sensing**, v. 7, n. 4, p. 4753–4783, 2015. Disponível em: <<http://www.mdpi.com/2072-4292/7/4/4753/>>.

KENNAWAY, T. A.; HELMER, E. H.; LEFSKY, M. A.; BRANDEIS, T. A.; SHERRILL, K. R. Mapping land cover and estimating forest structure using satellite imagery and coarse resolution lidar in the Virgin Islands. **Journal of Applied Remote Sensing**, v. 2, n. 023551, p. 27, 2008. Disponível em: <<http://link.aip.org/link/JARSC4/v2/i1/p023551/s1&Agg=doi>>.

KENNEL, P.; TRAMON, M.; BARBIER, N.; VINCENT, G. Canopy height model characteristics derived from airborne laser scanning and its effectiveness in discriminating various tropical moist forest types. **International Journal of Remote Sensing**, v. 34, n. 24, p. 8917–8935, 2013. Disponível em: <<http://www.tandfonline.com/doi/abs/10.1080/01431161.2013.858846>>.

KILIAN, J.; HAALA, N.; ENGLICH, M. Capture and evaluation of airborne laser scanner data. **International Archives of Photogrammetry and Remote Sensing**, v. 31, p. 383–388, 1996.

KINI, A. U.; POPESCU, S. C. TREEVAW : a versatile tool for analyzing forest canopy lidar data – a preview with an eye towards future computation of DEM and CHM – preparing CHM input for Treevaw. In: ASPRS Images to Decision: Remote Sensing Foundation for GIS Applications 2004, Kansas City, Missouri: ASPRS-70, 2004.

KNAPP, R. **Sampling methods and tasyon analysis in vegetation science. Handbook of vegetation science**. v.4. ed. Netherlands: Hague, 1984.

KOEDSIN, W.; VAIPHASA, C. Discrimination of tropical mangroves at the species level with EO-1 hyperion data. **Remote Sensing**, v. 5, n. 7, p. 3562–3582, 2013.

KOMIYAMA, A.; ONG, J. E.; POUNGPARN, S. Allometry, biomass, and productivity of mangrove forests: A review. **Aquatic Botany**, v. 89, n. 2, p. 128–137, ago. 2008. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0304377007001829>>. Acesso em: 8 mar. 2012.

KOVACS, J. M.; FLORES-VERDUGO, F.; WANG, J.; ASPDEN, L. P. Estimating leaf area index of a degraded mangrove forest using high spatial resolution satellite data. **Aquatic Botany**, v. 80, n. 1, p. 13–22, set. 2004. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0304377004000841>>. Acesso em: 1 mar. 2012.

KOVACS, J. M.; WANG, J.; FLORES-VERDUGO, F. Mapping mangrove leaf area index at the species level using IKONOS and LAI-2000 sensors for the Agua Brava Lagoon, Mexican Pacific. **Estuarine, Coastal and Shelf Science**, v. 62, n. 1-2, p. 377–384, jan. 2005. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0272771404002604>>. Acesso em: 1 mar. 2012.

KRAUS, K.; PFEIFER, N. Determination of terrain models in wooded areas with airborne laser scanner data. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 53, n. 4, p. 193–203, ago. 1998. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0924271698000094>>.

LAGOMASINO, D.; FATOYINBO, T.; LEE, S.; FELICIANO, E.; TRETTIN, C.; SIMARD, M. A comparison of mangrove canopy height using multiple independent measurements from land, air, and space. **Remote Sensing**, v. 8, n. 4, p. 327, 2016. Disponível em: <<http://www.mdpi.com/2072-4292/8/4/327>>.

LAGOMASINO, D.; FATOYINBO, T.; LEE, S.-K.; SIMARD, M. High-resolution forest canopy height estimation in an African blue carbon ecosystem. **Remote Sensing in Ecology and Conservation**, v. 1, n. 1, p. 51–60, 2015.

LECKIE, D.; GOUGEON, F.; HILL, D.; QUINN, R.; ARMSTRONG, L.; SHREENAN, R. Combined high-density lidar and multispectral imagery for individual tree crown analysis. **Canadian Journal of Remote Sensing**, v. 29, n. 5, p. 633–649, out. 2003. Disponível em: <<http://pubs.casi.ca/doi/abs/10.5589/m03-024>>.

LEE, A. C.; LUCAS, R. M. A LiDAR-derived canopy density model for tree stem and crown mapping in Australian forests. **Remote Sensing of Environment**, v. 111, n. 4, p. 493–518, dez. 2007. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0034425707001976>>. Acesso em: 20 jan. 2014.

LEFSKY, M. A.; COHEN, W. B.; ACKER, S. A.; SPIES, T. A.; PARKER, G. G.; HARDING, D. Lidar remote sensing of forest canopy structure and related biophysical parameters at H.J. Andrews Experimental Forest, Oregon, USA. 1998, [S.l.]: IEEE, 1998. p. 1252–1254 vol.3. Disponível em: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=691367>>.

LEFSKY, M. A.; COHEN, W. B.; HARDING, D. J.; PARKER, G. G.; ACKER, S. A.; GOWER, S. T. Lidar remote sensing of above-ground biomass in three biomes. **Global Ecology and Biogeography**, v. 11, n. 5, p. 393–399, 2002. Disponível em: <<Go to ISI>://WOS:000178189800004\http://onlinelibrary.wiley.com/store/10.1046/j.1466-822x.2002.00303.x/asset/j.1466-822x.2002.00303.x.pdf?v=1&t=gvxvskb4&s=551ae0a9c79b0a90f190778c01203f4f71b116d9>.

LEFSKY, M. A.; HARDING, D.; COHEN, W. .; PARKER, G.; SHUGART, H. . Surface lidar remote sensing of basal area and biomass in deciduous forests of eastern Maryland, USA. **Remote Sensing of Environment**, v. 67, n. 1, p. 83–98, jan. 1999. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0034425798000716>>.

LI, Y.; ANDERSEN, H.-E.; MCGAUGHEY, R. A Comparison of statistical methods for estimating data. **Journal of Applied Forestry**, v. 23, n. 4, p. 223–231, 2008.

LIAW, A; WIENER, M. Classification and regression by randomForest. **R news**, v. 2, n.3, p. 18–22, 2002.

LIM, K. S.; TREITZ, P. M. Estimation of above ground forest biomass from airborne discrete return laser scanner data using canopy-based quantile estimators. **Scandinavian Journal of Forest Research**, v. 19, n. 6, p. 558–570, dez. 2004b. Disponível em: <<http://www.tandfonline.com/doi/abs/10.1080/02827580410019490>>. Acesso em: 23 jan. 2014.

LIM, K.; TREITZ, P.; WULDER, M.; ST-ONGE, B.; FLOOD, M. LiDAR remote sensing of forest structure. **Progress in Physical Geography**, v. 27, n. 1, p. 88–106, 1 mar. 2003. Disponível em: <<http://ppg.sagepub.com/cgi/doi/10.1191/0309133303pp360ra>>. Acesso em: 23 jan. 2014.

LIVENS, S.; SCHEUNDERS, P.; DYCK, D. V. Wavelets for texture analysis, an overview. 1997, [S.l.: s.n.], 1997. p. 581–585.

LORENZ, K.; LAL, R. **Carbon Sequestration in Forest Ecosystems**. Dordrecht: Springer Netherlands, 2010. Disponível em: <<http://www.amazon.co.uk/Carbon-Sequestration-Forest-Ecosystems-Lorenz/dp/9048132657>>.

LU, D.; BATISTELLA, M. Exploring TM image texture and its relationships with biomass estimation in Rondônia, Brazilian Amazon. **Acta Amazonica**, v. 35, n. 2, p. 249–257, 2005.

LUCAS, R. M.; BURTING, P.; CLEWLEY, D.; PROISY, C.; SOUZA-FILHO, P. W.; VIERGEVR, K.; WOODHOUSE, L. TICEHURST, C.; CARREIRAS, J.; ROSENQVIST, A.; ACCAD, A.; ARMSTON, J. **Characterisation and monitoring of mangroves using ALOS PALSAR DATA**. [s.n.], 2009.

LUCAS, R. M.; CRONIN, N.; LEE, A.; MOGHADDAM, M.; WITTE, C.; TICKLE, P. Empirical relationships between AIRSAR backscatter and LiDAR-derived forest biomass, Queensland, Australia. **Remote Sensing of Environment**, v. 100, n. 3, p. 407–425, fev. 2006. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S003442570500355X>>. Acesso em: 5 abr. 2012.

LUCAS, R. M.; ELLISON, J. C.; MITCHELL, A.; DONNELLY, B.; FINLAYSON, M.; MILNE, A. K. Use of stereo aerial photography for quantifying changes in the extent and height of mangroves in tropical Australia. **Wetlands Ecology and Management**, v. 10, n. 2, p. 159-173, 2002.

LUCAS, R. M.; LEE, A. C.; BUNTING, P. J. Retrieving forest biomass through integration of CASI and LiDAR data. **International Journal of Remote Sensing**, v. 29, n. 5, p. 1553–1577, mar. 2008. Disponível em: <<http://www.tandfonline.com/doi/abs/10.1080/01431160701736497>>. Acesso em: 23 jan. 2014.

LUGO, A. E.; MEDINA, E. Mangrove Forests. **Encyclopedia of Natural Resources: Land**. CRC Press, 2014. p. 343–352. Disponível em: <<http://www.crcnetbase.com/doi/10.1081/E-ENRL-120047500>>.

LUGO, A. E.; SNEDAKER, S. C.; ARIEL, E. The ecology of mangroves. **Annual Review of Ecology and Systematics**, v. 5, n. 1, p. 39–64, 1974.

MAGNUSSEN, S.; BOUDEWYN, P. Derivations of stand heights from airborne laser scanner data with canopy-based quantile estimators. **Canadian Journal of Forest Research**, v. 28, n. 7, p. 1016–1031, jul. 1998. Disponível em: <<http://www.nrcresearchpress.com/doi/abs/10.1139/x98-078>>.

MALHI, Y. The carbon balance of tropical forest regions, 1990-2005. **Current Opinion in Environmental Sustainability**, v. 2, n. 4, p. 237–244, 2010. Disponível em: <<http://dx.doi.org/10.1016/j.cosust.2010.08.002>>.

MARINHA DO BRASIL. **Marinha do Brasil** -. Disponível em: <<http://www.mar.mil.br/dhn/chm/box-previsao-mare/tabuas/>>. Acesso em: 10 mar. 2014.

MASCARO, J.; ASNER, G. P.; MULLER-LANDAU, H. C.; VAN BREUGEL, M.; HALL, J.; DAHLIN, K. Controls over aboveground forest carbon density on Barro Colorado Island, Panama. **Biogeosciences**, v. 8, n. 6, p. 1615–1629, 2011.

MASCARO, J.; DETTO, M.; ASNER, G. P.; MULLER-LANDAU, H. C. Evaluating uncertainty in mapping forest carbon with airborne LiDAR. **Remote Sensing of Environment**, v. 115, n. 12, p. 3770–3774, 2011. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2011.07.019>>.

MCELHINNY, C.; GIBBONS, P.; BRACK, C.; BAUHUS, J. Forest and woodland stand structural complexity: Its definition and measurement. **Forest Ecology and Management**, v. 218, n. 1-3, p. 1–24, out. 2005. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0378112705005001>>. Acesso em: 20 jan. 2014.

MEANS, J.; ACKER, S. Predicting forest stand characteristics with airborne scanning lidar. **Photogrammetric Engineering & Remote Sensing**, v. 66, n. 11, p. 1367–1371, 2000. Disponível em: <<http://andrewsforest.oregonstate.edu/pubs/pdf/pub2821.pdf>>.

MEANS, J. E.; ACKER, S. A.; HARDING, D. J.; BLAIR, J. B.; LEFSKY, M. A.; COHEN, W. B.; HARMON, M. E.; MCKEE, W. A. Use of large-footprint scanning airborne Lidar to estimate forest stand characteristics in the western cascades of Oregon. **Remote Sensing of Environment**, v. 67, n. 3, p. 298–308, 1999.

MEDEIROS, T. C. C.; SAMPAIO, E. V. S. B. Allometry of aboveground biomasses in mangrove species in Itamaracá, Pernambuco, Brazil. **Wetlands Ecology and Management**, v. 16, n. 4, p. 323–330, 24 ago. 2008. Disponível em: <<http://link.springer.com/10.1007/s11273-007-9069-z>>.

MENG, S.; PANG, Y.; ZHANG, Z.; JIA, W.; LI, Z. Mapping aboveground biomass using texture indices from aerial photos in a temperate forest of northeastern China. **Remote Sensing, FOTO**, v. 8, n. 3, p. 230, 2016. Disponível em: <<http://www.mdpi.com/2072-4292/8/3/230/htm>>.

MERIDIAN INSTITUTE. **Reducing Emissions from Deforestation and Forest Degradation (REDD): An Options Assessment Report. Ecological Modelling**. Washington: [s.n.], 2009. Disponível em: <<http://www.redd-oar.org>>.

MEVIK, B. H.; CEDERKVIST, H. R. Mean squared error of prediction (MSEP) estimates for principal component regression (PCR) and partial least squares regression (PLSR). **Journal of Chemometrics**, v. 18, n. 9, p. 422–429, 2004.

MEVIK, B.-H.; WEHRENS, R. The pls Package: Principle Component and Partial Least Squares Regression in R. **Journal of Statistical Software**, v. 18, n. January 2007, p. 1–24, 2007. Disponível em: <<http://www.jstatsoft.org/v18/i02/paper>>.

MEVIK, B.-H.; WEHRENS, R.; LILAND, K. H. **pls: Partial Least Squares and Principal Component Regression**. [S.l.: s.n.]. Disponível em: <<http://cran.r-project.org/package=pls>>. , 2015

MITCHELL, A. L.; LUCAS, R. M.; DONNELLY, B. E. A new map of mangroves for Kakadu National Park , Northern Australia , based on stereo aerial photography. v. 467, n. February, p. 446–467, 2007.

MONTESANO, P. M.; COOK, B. D.; SUN, G.; SIMARD, M.; NELSON, R. F.; RANSON, K. J.; ZHANG, Z.; LUTHCKE, S. Achieving accuracy requirements for forest biomass mapping: A spaceborne data fusion method for estimating forest biomass and LiDAR sampling error. **Remote Sensing of Environment**, v. 130, p. 153–170, 2013. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2012.11.016>>.

MOUGIN, E.; PROISY, C.; MARTY, G.; FROMARD, F.; PUIG, H.; BETOULLE, J. L. L.; RUDANT, J. P. P. Multifrequency and multipolarization radar backscattering from mangrove forests. **IEEE Transactions on Geoscience and Remote Sensing**, v. 37, n. 1, p. 94–102, 1999. Disponível em: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=739128>>.

MUGGLESTONE, M. A.; RENSHAW, E. Detection of geological lineations on aerial photographs using two-dimensional spectral analysis. **Computers & Geosciences**, v. 24, n. 8, p. 771–784, out. 1998. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S009830049800065X>>.

NÆSSET, E. Discrimination between ground vegetation and small pioneer trees in the boreal-alpine ecotone using intensity metrics derived from airborne laser scanner data. **Remote Sensing**, v. 8, n. 7, p. 548, 2016. Disponível em: <<http://www.mdpi.com/2072-4292/8/7/548>>.

NÆSSET, E. Estimating above-ground biomass in young forests with airborne laser scanning. **International Journal of Remote Sensing**, v. 32, n. 2, p. 473–501, 2011.

NÆSSET, E. Predicting forest stand characteristics with airborne scanning laser using a practical two-stage procedure and field data. **Remote Sensing of Environment**, v. 80, n. 1, p. 88–99, abr. 2002. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0034425701002905>>.

NÆSSET, E.; BJERKNES, K.-O. Estimating tree heights and number of stems in young forest stands using airborne laser scanner data. **Remote Sensing of Environment**, v. 78, n. 3, p. 328–340, dez. 2001. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0034425701002280>>.

NÆSSET, E.; GOBAKKEN, T. Estimation of above- and below-ground biomass across regions of the boreal forest zone using airborne laser. **Remote Sensing of Environment**, v. 112, n. 6, p. 3079–3090, 2008.

NATURAL RESOURCE CANADA. **GPS positioning guide**. Ottawa: [s.n.], 1995.

NELSON, R. F.; HYDE, P.; JOHNSON, P.; EMESSIENE, B.; IMHOFF, M. L.; CAMPBELL, R.; EDWARDS, W. Investigating RaDAR-LiDAR synergy in a North Carolina pine forest. **Remote Sensing of Environment**, v. 110, n. 1, p. 98–108, 2007.

NELSON, R.; GOBAKKEN, T.; NÆSSET, E.; GREGOIRE, T. G.; STAHL, G.; HOLM, S.; FLEWELLING, J. Lidar sampling - Using an airborne profiler to estimate forest biomass in Hedmark County, Norway. **Remote Sensing of Environment**, v. 123, n. 2012, p. 563–578, 2012. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2011.10.036>>.

NELSON, R.; KRABILL, W.; MACLEAN, G. Determining forest canopy characteristics using airborne laser data. **Remote Sensing of Environment**, v. 15, n. 3, p. 201–212, jun. 1984. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/0034425784900312>>.

NELSON, R.; KRABILL, W.; TONELLI, J. Estimating forest biomass and volume using airborne laser data. **Remote Sensing of Environment**, v. 24, n. 2, p. 247–267, mar. 1988. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/0034425788900284>>.

NETER, J.; KUTNER, M. H.; NACHTSHEIM, C. J.; WASSERMAN, W. **Applied linear statistical models**. 4. ed. Boston: [s.n.], 1996.

NEWTON, A. C. **Forest Ecology and Conservation- A handbook of techniques. Techniques in Ecology & Conservation Series**. Oxford University Press, 2007.

NFOTABONG-ATHEULL, A. **Impact of anthropogenic activities on the vegetation structure of mangrove forests in Kribi, the Nyong river mouth and Cameroon estuary**. 2011. Université Libre de Bruxelles-ULB (Belgium) e University of Douala (Cameroon), 2011.

NFOTABONG-ATHEULL, A.; DIN, N.; DAHDOUNH-GUEBAS, F. Qualitative and quantitative characterization of mangrove vegetation structure and dynamics in a peri-urban setting of Douala (Cameroon): an approach using air-borne imagery. **Estuaries and Coasts**, v. 36, n. 6, p. 1181–1192, 2013.

NICHOL, J. E.; SARKER, M. L. R. Improved biomass estimation using the texture parameters of two high-resolution optical sensors. **IEEE Transactions on Geoscience and Remote Sensing**, v. 49, n. 3, p. 930–948, mar. 2011. Disponível em: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=5604312>>.

NYSTROM, M.; HOLMGREN, J.; OLSSON, H. Prediction of tree biomass in the forest-tundra ecotone using airborne laser scanning. **Remote Sensing of Environment**, v. 123, p. 271–279, 2012. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2012.03.008>>.

OLAGOKE, A.; PROISY, C.; FÉRET, J.-B.; BLANCHARD, E.; FROMARD, F.; MEHLIG, U.; DE MENEZES, M. M.; DOS SANTOS, V. F.; BERGER, U. Extended biomass allometric equations for large mangrove trees from terrestrial LiDAR data. **Trees**, v. 30, n. 3, p. 935–947, 19 jun. 2016. Disponível em: <<http://link.springer.com/10.1007/s00468-015-1334-9>>.

OLWIG, M. F.; SØRENSEN, M. K.; RASMUSSEN, M. S.; DANIELSEN, F.; SELVAM, V.; HANSEN, L. B.; NYBORG, L.; VESTERGAARD, K. B.; PARISH, F.; KARUNAGARAN, V. M. Using remote sensing to assess the protective role of coastal woody vegetation against tsunami waves. **International Journal of Remote Sensing**, v. 28, n. 13-14, p. 3153–3169, jul. 2007. Disponível em: <<http://www.tandfonline.com/doi/abs/10.1080/01431160701420597>>. Acesso em: 23 jan. 2014.

PAN, Y.; BIRDSEY, R. A.; FANG, J.; HOUGHTON, R.; KAUPPI, P. E.; KURZ, W. A.; PHILLIPS, O. L.; SHVIDENKO, A.; LEWIS, S. L.; CANADELL, J. G.; CIAIS, P.; JACKSON, R. B.; PACALA, S. W.; MCGUIRE, A. D.; PIAO, S.; RAUTIAINEN, A.; SITCH, S.; HAYES, D. A large and persistent carbon sink in the world's forests. **Science (New York, N.Y.)**, v. 333, n. 6045, p. 988–93, 2011. Disponível em: <<http://www.scopus.com/inward/record.url?eid=2-s2.0-80051879083&partnerID=tZOtx3y1>>.

PAN, Y.; BIRDSEY, R. A.; PHILLIPS, O. L.; JACKSON, R. B. The structure, distribution, and biomass of the world's forests. **Annual Review of Ecology, Evolution, and Systematics**, v. 44, n. 1, p. 593–622, 2013. Disponível em: <<http://www.annualreviews.org/doi/abs/10.1146/annurev-ecolsys-110512-135914>>.

PELLENS, R. (ORG). **Plano de Manejo da Área de Proteção Ambiental de Guapi-Mirim (APA de Guapi-Mirim)**. Brasília: [s.n.], 2001.

PENDLETON, L.; DONATO, D. C.; MURRAY, B. C.; CROOKS, S.; JENKINS, W. A.; SIFLEET, S.; CRAFT, C.; FOURQUREAN, J. W.; KAUFFMAN, J. B.; MARB??, N.; MEGONIGAL, P.; PIDGEON, E.; HERR, D.; GORDON, D.; BALDERA, A. estimating global “blue carbon” emissions from conversion and degradation of vegetated coastal ecosystems. **PLoS ONE**, v. 7, n. 9, 2012.

PEREIRA, F. R. DE S.; KAMPEL, M.; CUNHA-LIGNON, M. Mapping of mangrove forests on the southern coast of São Paulo, Brazil, using synthetic aperture radar data from ALOS/PALSAR. **Remote Sensing Letters**, v. 3, n. 7, p. 567–576, 10 dez. 2012. Disponível em: <<http://www.tandfonline.com/doi/abs/10.1080/01431161.2011.641511>>.

PETROBRÁS. **Programa de monitoramento dos manguezais da APA de Guapimirim e ESEC Guanabara: relatório final**. . Rio de Janeiro: [s.n.], 2012.

PIRES, I. **Monitoramento dos Manguezais da APA de Guapi-Mirim-RJ, através da Correlação de Dados de Radiância Tm-Landsat**. 1992. Tese (Doutorado do programa de Pós Graduação em geografia), Universidade de São Paulo, 1992.

PIRES, I. D. O. Manguezais da região do recôncavo da Baía de Guanabara: revisita através dos mapas. **Revista da Gestão Costeira Integrada**, v. 8, n. 2, p. 1–9, 2010.

PIRES, I. O. **Mapeamentos dos manguezais do recôncavo da Baía de Guanabara através da utilização de técnicas de sensoriamento remoto**. 1985. 90 p. (INPE-3942-TDL/229). Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais (INPE), Sao Jose dos Campos, 1985. Disponível em: <<http://urlib.net/6qtX3pFwXQZ3r59YD6/GNnhb>>. Acesso em: 05 jan. 2017.

PLOTON, P.; PELISSIER, R.; PROISY, C.; FLAVENOT, T.; BARBIER, N.; RAI, S. N.; COUTERON, P. Assessing aboveground tropical forest biomass using Google Earth canopy images. **Ecological Applications**, v. 22, n. 3, p. 993–1003, 2012.

POLIDORO, B. A.; CARPENTER, K. E.; COLLINS, L.; DUKE, N. C.; ELLISON, A. M.; ELLISON, J. C.; FARNSWORTH, E. J.; FERNANDO, E. S.; KATHIRESAN, K.; KOEDAM, N. E.; LIVINGSTONE, S. R.; MIYAGI, T.; MOORE, G. E.; NAM, V. N.; ONG, J. E.; PRIMAVERA, J. H.; SALMO, S. G.; SANCIANGCO, J. C.; SUKARDJO, S. *et al.* The loss of species: mangrove extinction risk and geographic areas of global concern. **PloS one**, v. 5, n. 4, p. e10095, 2010. Disponível em: <<http://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=2851656&tool=pmcentrez&rendertype=abstract>>. Acesso em: 2 mar. 2012.

PONZONI, F. J. .; SHIMABUKURO, Y. E. **Sensoriamento remoto no estudo da vegetação**. 1. ed. São José dos Campos: Parêntese, 2007.

POPESCU, S. C. Estimating biomass of individual pine trees using airborne lidar. **Biomass and Bioenergy**, v. 31, n. 9, p. 646–655, set. 2007. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0961953407001316>>. Acesso em: 23 jan. 2014.

POPESCU, S. C.; WYNNE, R. H. Seeing the trees in the forest : using lidar and multispectral data fusion with local filtering and variable window size for estimating tree height. **Photogrammetric Engineering and Remote Sensing** 70(5):589-604, 2004.

POPESCU, S. C.; ZHAO, K.; NEUENSCHWANDER, A.; LIN, C. Satellite lidar vs. small footprint airborne lidar: Comparing the accuracy of aboveground biomass estimates and forest structure metrics at footprint level. **Remote Sensing of Environment**, v. 115, n. 11, p. 2786–2797, 2011. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2011.01.026>>.

PROISY, C.; BARBIER, N.; GUÉROULT, M.; PÉLISSIER, R.; GASTELLU-ETCHEGORRY, J. P.; GRAU, E.; COUTERON, P. Biomass prediction in tropical forests : the canopy grain approach. **Remote sensing of biomass: principles and applications**, p. 1–18, 2011.

PROISY, C.; COUTERON, P.; FROMARD, F. Predicting and mapping mangrove biomass from canopy grain analysis using Fourier-based textural ordination of IKONOS images. **Remote Sensing of Environment**, v. 109, n. 3, p. 379–392, ago. 2007. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0034425707000430>>. Acesso em: 1 mar. 2012.

PROISY, C.; COUTERON, P.; FROMARD, F.; PÉLISSIER, R. Mangroves dynamics from FOTO of IKONOS images and Lidar data. n. August 2015, 2007.

PROISY, C.; MOUGIN, E.; FROMARD, F.; KARAM, M. A. Interpretation of polarimetric radar signatures of mangrove forests. **Remote Sensing of Environment**, v. 71, n. 2, p. 56–66, 2000.

PROISY, C.; MOUGIN, E.; FROMARD, F.; TRICHON, V.; KARAM, M. A. On the influence of canopy structure on the radar backscattering of mangrove forests. **International Journal of Remote Sensing**, v. 23, n. 20, p. 4197–4210, jan. 2002. Disponível em: <<http://www.tandfonline.com/doi/abs/10.1080/01431160110107725>>. Acesso em: 12 abr. 2012.

R CORE TEAM. **R: A language and environment for statistical computing**. . Vienna, Austria.: R Foundation for Statistical Computing. Disponível em: <<https://www.r-project.org/>>. , 2015

RAMSEY, E. W., JENSEN, J. R.. Remote sensing of mangrove wetlands: relating canopy spectra to site-specific data. **Photogrammetric engineering and remote sensing**, 62(8), 939-948,1996.

RENSHAW, A. E.; FORD, E. D. The description of spatial pattern using two-dimensional spectral analysis. **Vegetation**, v. 56, n. 2, p. 75–85, 1984. Disponível em: <<http://www.jstor.org/stable/20146065>>.

REUTEBUCH, S. E.; ANDERSEN, H.; MCGAUGHEY, R. J.; FOREST, L. Light Detection and Ranging (LIDAR): an emerging tool for multiple resource inventory. **Journal of Forestry**, n. September, p. 286–292, 2005.

RIAÑO, D.; VALLADARES, F.; CONDÉS, S.; CHUVIECO, E. Estimation of leaf area index and covered ground from airborne laser scanner (Lidar) in two contrasting forests. **Agricultural and Forest Meteorology**, v. 124, n. 3-4, p. 269–275, ago. 2004. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0168192304000449>>. Acesso em: 23 jan. 2014.

ROCKSTRÖM, J.; STEFFEN, W.; NOONE, K.; PERSSON, Å.; CHAPIN, F. S.; LAMBIN, E.; LENTON, T. M.; SCHEFFER, M.; FOLKE, C.; SCHELLNHUBER, H. J.; NYKVIST, B.; DE WIT, C. A.; HUGHES, T.; VAN DER LEEUW, S.; RODHE, H.; SÖRLIN, S.; SNYDER, P. K.; COSTANZA, R.; SVEDIN, U. *et al.* Planetary boundaries: Exploring the safe operating space for humanity. **Ecology and Society**, v. 14, n. 2, 2009.

SAATCHI, S.; MARLIER, M.; CHAZDON, R. L.; CLARK, D. B.; RUSSELL, A. E. Impact of spatial variability of tropical forest structure on radar estimation of aboveground biomass. **Remote Sensing of Environment**, v. 115, n. 11, p. 2836–2849, nov. 2011. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0034425711001313>>. Acesso em: 23 jan. 2014.

SAATCHI, S. S.; HARRIS, N. L.; BROWN, S.; LEFSKY, M.; MITCHARD, E. T. A.; SALAS, W.; ZUTTA, B. R.; BUERMANN, W.; LEWIS, S. L.; HAGEN, S.; PETROVA, S.; WHITE, L.; SILMAN, M.; MOREL, A. Benchmark map of forest carbon stocks in tropical regions across three continents. **Proceedings of the National Academy of Sciences**, v. 108, n. 24, p. 9899–9904, 14 jun. 2011. Disponível em: <<http://www.pnas.org/cgi/doi/10.1073/pnas.1019576108>>.

SAENGER, P. **Mangrove ecology, silviculture and conservation**. [S.l.]: Springer, 2002.

SAENGER, P.; SNEDAKER, S. C. Pantropical trends in mangrove above-ground biomass and annual litterfall. **Oecologia**, v. 96, n. 3, p. 293–299, dez. 1993. Disponível em: <<http://link.springer.com/10.1007/BF00317496>>.

SARKER, L. R.; NICHOL, J. E. Improved forest biomass estimates using ALOS AVNIR-2 texture indices. **Remote Sensing of Environment**, v. 115, n. 4, p. 968–977, 15 abr. 2011. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2010.11.010>>. Acesso em: 8 abr. 2012.

SÄRNDAL, C.-E.; SWENSSON, B.; WRETMAN, J. **Model Assisted Survey Sampling**. 1. ed. Springer-Verlag New York, 1992.

SÄRNDAL, C.-E.; THOMSEN, I.; HOEM, J. M.; LINDLEY, D. V.; BARNDORFF-NIELSEN, O.; DALENIUS, T. Design-Based and Model-Based inference in survey sampling. **Scandinavian Journal of Statistics**, v. 5, n. 1, p. 27–52, 1978. Disponível em: <<http://www.jstor.org.proxy-um.researchport.umd.edu/stable/4615682>>.

SATYANARAYANA, B.; MOHAMAD, K. A.; IDRIS, I. F.; HUSAIN, M.-L.; DAHDOUH-GUEBAS, F. Assessment of mangrove vegetation based on remote sensing and ground-truth measurements at Tumpat, Kelantan Delta, East Coast of Peninsular Malaysia. **International Journal of Remote Sensing**, v. 32, n. 6, p. 1635–1650, 16 mar. 2011. Disponível em: <<http://www.tandfonline.com/doi/abs/10.1080/01431160903586781>>. Acesso em: 1 mar. 2012.

SCHAEFER, M. **Wörterbücher der Biologie. Ökologie**. Jena: [s.n.], 1992.

SCHAEFFER-NOVELLI, Y. **Manguezais brasileiros**. São Paulo: Instituto Oceanográfico da Universidade de São Paulo, 1991.

SCHAEFFER-NOVELLI, Y. .; CINTRÓN-MOLERO, G. **Guia para estudo de áreas de manguezal: estrutura, função e flora**. São Paulo: Caribbean Ecological Research., 1986.

SCHAEFFER-NOVELLI, Y.; CINTRÓN-MOLERO, G.; ADAIME, R. R.; DE CAMARGO, T. M. Variability of mangrove ecosystems along the Brazilian coast. **Estuaries**, v. 13, n. 2, p. 204–218, 1990.

SCHAEFFER-NOVELLI, Y.; CINTRÓN-MOLERO, G.; SOARES, M. L. G.; DE-ROSA, T. Brazilian mangroves. **Aquatic Ecosystem Health & Management**, v. 3, n. 4, p. 561–570, jan. 2000. Disponível em: <<http://www.tandfonline.com/doi/abs/10.1080/14634980008650693>>.

SCHAEFFER-NOVELLI, Y.; SORIANO-SIERRA, E. J.; VALE, C. C. DO; BERNINI, E.; ROVAI, A. S.; PINHEIRO, M. A. A.; SCHMIDT, A. J.; ALMEIDA, R. DE; COELHO JÚNIOR, C.; MENGHINI, R. P.; MARTINEZ, D. I.; ABUCHAHLA, G. M. DE O.; CUNHA-LIGNON, M.; CHARLIER-SARUBO, S.; SHIRAZAWA-FREITAS, J.; CINTRÓN-MOLERO, G. Climate changes in mangrove forests and salt marshes. **Brazilian Journal of Oceanography**, v. 64, n. spe2, p. 37–52, 2016. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1679-87592016000600037&lng=en&nrm=iso&tlng=en>.

SCHMIDTLEIN, S.; FEILHAUER, H.; BRUELHEIDE, H. Mapping plant strategy types using remote sensing. **Journal of Vegetation Science**, v. 23, p. 395–405, 2012.

SHENG, Y. Quantifying the size of a lidar footprint: a set of generalized equations. **IEEE Geoscience and Remote Sensing Letters**, v. 5, n. 3, p. 419–422, jul. 2008. Disponível em: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=4505315>>.

SIKAMAKI, J.; SANCHIRICO, J. N.; JARDINE, S. L. Global economic potential for reducing carbon dioxide emissions from mangrove loss. **Proceedings of the National Academy of Sciences**, v. 109, n. 36, p. 14369–14374, 2012. Disponível em: <<http://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=3437861&tool=pmcentrez&rendertype=abstract>\n<http://www.pnas.org/cgi/doi/10.1073/pnas.1200519109>>.

SIMARD, M.; RIVERA-MONROY, V. H.; MANCERA-PINEDA, J. E.; CASTAÑEDA-MOYA, E.; TWILLEY, R. R. A systematic method for 3D mapping of mangrove forests based on Shuttle Radar Topography Mission elevation data, ICESat/GLAS waveforms and field data: Application to Ciénaga Grande de Santa Marta, Colombia. **Remote Sensing of Environment**, v. 112, n. 5, p. 2131–2144, maio 2008. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0034425708000357>>.

SIMARD, M.; ZHANG, K.; RIVERA-MONROY, V. H.; ROSS, M. S.; RUIZ, P. L.; CASTAÑEDA-MOYA, E.; TWILLEY, R. R.; RODRIGUEZ, E. mapping height and biomass of mangrove forests in everglades national park with SRTM elevation data. **Photogrammetric Engineering & Remote Sensing**, v. 72, n. 3, p. 299–311, 1 mar. 2006. Disponível em: <<http://www.scopus.com/inward/record.url?eid=2-s2.0-33644677069&partnerID=40&md5=7b0d066e192f884cbe0c04a6129014e0>>.

SITHOLE, G.; VOSSSELMAN, G. Experimental comparison of filter algorithms for bare-Earth extraction from airborne laser scanning point clouds. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 59, n. 1-2, p. 85–101, ago. 2004. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0924271604000140>>. Acesso em: 23 jan. 2014.

SOARES, M. L. G. **Estudo da biomassa aérea de manguezais do sudeste do Brasil - Análise de modelos**. 1997. Tese (Doutorado no programa de Pós Graduação do Instituto Oceanográfico), Universidade de São Paulo, 1997.

SOARES, M. L. G.; ALMEIDA, P. M. M. DE; CAVALCANTI, V. F.; ESTRADA, G. C. D.; SANTOS, D. M. C. Megacidades, vulnerabilidades e mudanças climáticas: região metropolitana do Rio de Janeiro. **Projeto Megacidades, Vulnerabilidades E Mudanças Climáticas**, v. 1, p. p. 257–290, 2011.

SOARES, M. L. G.; CHAVES, F. D. O.; MOREIRA, F.; MILTON, C. Diversidade Estrutural de Bosques de Mangue e sua Relação com Distúrbios de Origem Antrópica : o caso da Baía de Guanabara (Rio de Janeiro). **Anuário do Instituto de Geociências UFRJ**, v. 26, p. 101–116, 2003.

SOARES, M. L. G.; ESTRADA, G. C. D.; FERNANDEZ, V.; TOGNELLA, M. M. P. Southern limit of the Western South Atlantic mangroves: Assessment of the potential effects of global warming from a biogeographical perspective. **Estuarine, Coastal and Shelf Science**, v. 101, p. 44–53, 2012. Disponível em: <<http://dx.doi.org/10.1016/j.ecss.2012.02.018>>.

SOARES, M. L. G.; SCHAEFFER-NOVELLI, Y.; GOMES, M.; SCHAEFFER-NOVELLI, Y. Above-ground biomass of mangrove species. I. Analysis of models. **Estuarine, Coastal and Shelf Science**, v. 65, n. 1-2, p. 1–18, out. 2005. Disponível em: <<http://www.sciencedirect.com.pbi.unam.mx:8080/science/article/pii/S0272771405001411>>. Acesso em: 1 mar. 2012.

SPALDING, M.; KAINUMA, M.; COLLINS, L. **World Atlas of Mangroves**. London (UK): Routledge, 2010. Disponível em: <<http://www.routledge.com/books/details/9781844076574>>.

STEFFEN, W.; CRUTZEN, P. J.; MCNEILL, J. R.; STEFFEN, W.; CRUTZEN, P. J.; MCNEILL, J. R. Royal Swedish Academy of Sciences The anthropocene : are humans now overwhelming the great forces of nature **AMBIO**, v. 36, n. 8, p. 614–621, 2007. Disponível em: <<http://www.jstor.org/stable/25547826>>.

STEPHENS, P. R.; KIMBERLEY, M. O.; BEETS, P. N.; PAUL, T. S. H.; SEARLES, N.; BELL, A.; BRACK, C.; BROADLEY, J. Airborne scanning LiDAR in a double sampling forest carbon inventory. **Remote Sensing of Environment**, v. 117, p. 348–357, 2012. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2011.10.009>>.

TUCERYAN, M.; JAIN, A. K. Texture Analysis. In: CHEN, C. H.; PAU, L. F.; WANG, P. S. P. (Org.). **The Handbook of Pattern Recognition and Computer Vision**. 2nd Editio ed.: World Scientific Publishing Co, 1998. p. 207–248.

VALENTIN, J. L. **Ecologia numérica: uma introdução à análise multivariada de dados ecológicos**. 2. ed. Rio de Janeiro: editora interciências, 2012.

VALIELA, I.; BOWEN, J. L.; YORK, J. K. Mangrove forests: one of the world's threatened major tropical environments. **BioScience**, v. 51, n. 10, p. 807, 2001.

VÉGA, C.; RENAUD, J. P.; DURRIEU, S.; BOUVIER, M. On the interest of penetration depth, canopy area and volume metrics to improve Lidar-based models of forest parameters. **Remote Sensing of Environment**, v. 175, p. 32–42, 2016. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2015.12.039>>.

VÉGA, C.; VEPAKOMMA, U.; MOREL, J.; BADER, J.-L.; RAJASHEKAR, G.; JHA, C.; FERÊT, J.; PROISY, C.; PÉLISSIER, R.; DADHWAL, V. Aboveground-biomass estimation of a complex tropical forest in India using lidar. **Remote Sensing**, v. 7, n. 8, p. 10607–10625, 2015. Disponível em: <<http://www.mdpi.com/2072-4292/7/8/10607/>>.

VINCENT, G.; SABATIER, D.; BLANC, L.; CHAVE, J.; WEISSENBACHER, E.; PÉLISSIER, R.; FONTY, E.; MOLINO, J.-F.; COUTERON, P. Accuracy of small footprint airborne LiDAR in its predictions of tropical moist forest stand structure. **Remote Sensing of Environment**, v. 125, p. 23–33, out. 2012. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0034425712002556>>. Acesso em: 20 jan. 2014.

VINCENT, G.; SABATIER, D.; RUTISHAUSER, E. Revisiting a universal airborne light detection and ranging approach for tropical forest carbon mapping: scaling-up from tree to stand to landscape. **Oecologia**, v. 175, n. 2, p. 439–443, 2014. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/24615493>>.

VO, Q. T.; OPPELT, N.; LEINENKUGEL, P.; KUENZER, C. Remote sensing in mapping mangrove ecosystems - an object-based approach. **Remote Sensing**, v. 5, n. 1, p. 183–201, 2013.

WANG, C.; GLENN, N. F. A linear regression method for tree canopy height estimation using airborne lidar data. v. 34, n. November, 2008.

WANG, L.; SILVÁN-CÁRDENAS, J. L.; SOUSA, W. P. Neural network classification of mangrove species from multi-seasonal Ikonos imagery. **Photogrammetric Engineering and Remote Sensing**, v. 74, n. 7, p. 921–927, 2008. Disponível em: <<http://www.scopus.com/inward/record.url?eid=2-s2.0-47549098844&partnerID=40&md5=231146a8a2f9bc6791443b4afe7c4bf5>>.

WANG, T.; ZHANG, H.; LIN, H.; FANG, C. Textural-spectral feature-based species classification of mangroves in Mai Po nature reserve from worldview-3 imagery. **Remote Sensing**, v. 8, n. 1, p. 1–15, 2016.

WANG, X.; PANG, Y.; ZHANG, Z.; YUAN, Y. Forest aboveground biomass estimation using SPOT-5 texture indices and spectral derivatives. **International Geoscience and Remote Sensing Symposium (IGARSS)**, p. 2830–2833, 2014.

WANNASIRI, W.; NAGAI, M.; HONDA, K.; SANTITAMNONT, P.; MIPHOKASAP, P. Extraction of mangrove biophysical parameters using airborne lidar. **Remote Sensing**, v. 5, n. 4, p. 1787–1808, 12 abr. 2013. Disponível em: <<http://www.mdpi.com/2072-4292/5/4/1787/>>. Acesso em: 23 jan. 2014.

WEBBER, M.; CALUMPONG, H.; FERREIRA, B.; GRANEK, E.; GREEN, S.; RUWA, R.; SOARES, M. **Mangroves. UN World Ocean Assessment**. [S.l.: s.n.], 2016. Disponível em: <http://www.un.org/Depts/los/global_reporting/WOA_RPROC/WOACompilation.pdf>

WEHR, A.; LOHR, U. Airborne laser scanning—an introduction and overview. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 54, n. 2-3, p. 68–82, jul. 1999. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0924271699000118>>.

WESTLAKE, D. F. Comparisons of plant productivity. **Biological Reviews**, v. 38, n. 3, p. 385–425, ago. 1963. Disponível em: <<http://doi.wiley.com/10.1111/j.1469-185X.1963.tb00788.x>>.

WHITE, J. C.; WULDER, M. A.; VARHOLA, A.; VASTARANTA, M.; COOPS, N. C.; COOK, B. D.; PITT, D.; WOODS, M. **A best practices guide for generating forest inventory attributes from airborne laser scanning data using an area-based approach. Natural Resources Canada Information Report FI-X-010.**, 2013.

WOLD, S.; SJÖSTRÖM, M.; ERIKSSON, L. PLS-regression: A basic tool of chemometrics. **Chemometrics and Intelligent Laboratory Systems**, v. 58, n. 2, p. 109–130, 2001.

WULDER, M. A.; HALL, R. J.; COOPS, N. C.; FRANKLIN, S. E. High spatial resolution remotely sensed data for ecosystem characterization. **BioScience**, v. 54, n. 6, p. 511, 2004. Disponível em: <<http://www.jstor.org/stable/3333945>>.

YANG, C.; EVERITT, J. H.; FLETCHER, R. S.; JENSEN, R. R.; MAUSEL, P. W. Evaluating AISA + Hyperspectral Imagery for Mapping Black Mangrove along the South Texas Gulf Coast. **Photogrammetric Engineering & Remote Sensing**, v. 75, n. 4, p. 425–435, 2009.

YU, X.; HYYPPÄ, J.; VASTARANTA, M.; HOLOPAINEN, M.; VIITALA, R. Predicting individual tree attributes from airborne laser point clouds based on the random forests technique. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 66, n. 1, p. 28–37, 2011. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0924271610000651>>.

ZANNE AE, LOPEZ-GONZALEZ G, COOMES DA, ILIC J, JANSEN S, LEWIS SL, MILLER RB, SWENSON NG, WIEMANN MC, CHAVE J (2009) Data from: Towards a worldwide wood economics spectrum. Dryad Digital Repository. <http://dx.doi.org/10.5061/dryad.234>

ZEHM, A.; NOBIS, M.; SCHWABE, A. Multiparameter analysis of vertical vegetation structure based on digital image processing. **Flora - Morphology, Distribution, Functional Ecology of Plants**, v. 198, n. 2, p. 142–160, jan. 2003. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0367253004700614>>.

ZHANG, C.; XIE, Z. Combining object-based texture measures with a neural network for vegetation mapping in the Everglades from hyperspectral imagery. **Remote Sensing of Environment**, v. 124, p. 310–320, set. 2012. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0034425712002180>>. Acesso em: 18 jun. 2012.

ZHANG, K. Identification of gaps in mangrove forests with airborne LIDAR. **Remote Sensing of Environment**, v. 112, n. 5, p. 2309–2325, maio 2008. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0034425707004506>>. Acesso em: 7 jun. 2012.

ZHANG, K.; HOULE, P. A.; ROSS, M. S.; RUIZ, P. L.; SIMARD, M. Airborne laser mapping of mangroves on the biscayne bay coast, Miami, Florida. **International Geoscience and Remote Sensing Symposium (IGARSS)**, p. 3750–3754, jul. 2006. Disponível em: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=4242109>>.

ZHANG, K.; SIMARD, M.; ROSS, M.; RIVERA-MONROY, V. H.; HOULE, P.; RUIZ, P.; TWILLEY, R. R.; WHELAN, K. R. T. Airborne laser scanning quantification of disturbances from hurricanes and lightning strikes to mangrove forests in Everglades National Park, USA. **Sensors**, v. 8, n. 4, p. 2262–2292, 1 abr. 2008. Disponível em: <<http://www.mdpi.com/1424-8220/8/4/2262/>>.

ZHANG, K.; SIMARD, M.; ROSS, M.; RIVERA-MONROY, V. H.; HURRICANE, I.; ENVIRONMENTAL, S.; SCIENCE, C.; ROUGE, B. Airborne laser mapping of gaps in mangrove forests in Everglades National Park, USA. n. Dcm, p. 1–2, 2006.

ZHU, Y.; LIU, K.; LIU, L.; WANG, S.; LIU, H. Retrieval of mangrove aboveground biomass at the individual species level with worldview-2 images. **Remote Sensing**, v. 7, n. 9, p. 12192–12214, 2015.

ZOLKOS, S. G.; GOETZ, S. J.; DUBAYAH, R. A meta-analysis of terrestrial aboveground biomass estimation using lidar remote sensing. **Remote Sensing of Environment**, v. 128, p. 289–298, 2013. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2012.10.017>>.

ZVOLEFF, A. glcm: Calculate Textures from Grey-Level Co-Occurrence Matrices (GLCMs). **R package version 1.6.1.** Disponível em: <<http://cran.r-project.org/package=glcm>>. , 2016

APÊNDICE A - Características das parcelas de campo

Tabela A.1- Características das 34 parcelas de campo, com fotografias obtidas dentro de cada parcela

(Fonte: arquivo pessoal, data: setembro de 2014).

Parcela	Características	Fotografia obtida no interior da parcela
C01	Sem fotos, alagado, bosque desenvolvido, conservado	Sem foto, difícil acesso, acesso apenas com a maré alta.
C02	Sem fotos, alagado, bosque desenvolvido, conservado	Sem foto, difícil acesso, acesso apenas com a maré alta.
C03	Mangue com truncos caídos, rebrotamento	
C04	Mangue com algumas árvores adultas mortas e rebrotamento, presença de <i>Acrostichum</i>	

C05

Bosque com troncos mais finos, presença de *Acrostichum* ao entorno



C06

Sem fotos, alagado, bosque desenvolvido com alguns indivíduos mortos, rebrotamento

Sem foto, difícil acesso, acesso apenas com a maré alta.

C07

Bosque maduro desenvolvido com rebrotamento, alguns indivíduos caídos



C08

Bosque maduro com troncos médios, presença de *Acrostichum* ao entorno



C09

Bosque com indivíduos médios, troncos finos tortos, presença de *Acrostichum* ao entorno



C10

Bosque com solo mais seco e firme, indivíduos maduros com troncos finos, presença de *Acrostichum*



C11

Bosque com indivíduos jovens e maduros, presença de *Acrostichum* ao entorno



C12

Bosque desenvolvido, alagado, com rebrotamento e presença de *Acrostichum* e *Hibiscus*



C13

Área de clareira com indivíduos maduros mortos, muitos troncos mortos e indivíduos jovens vivos



C14

Bosque desenvolvido, alagado, conservado, indivíduos grandes adultos e rebrotamento



C15

Bosque maduro
com
rebrotamento



C16

Bosque maduro
com
Acrostichum ao
entorno



C17

Bosque maduro,
galhos secos,
ramificado, com
Acrostichum e
Hibiscus ao
entorno



C18

Bosque com indivíduos médios, troncos ramificados e meio secos, presença de *Acrostichum* ao entorno e plantação de mangue ao entorno



C19

Bosque maduro desenvolvido, com rebrotamento



C20

Bosque maduro desenvolvido com rebrotamento, alagado, na trilha para chegar no bosque presença de indivíduos menores e *Acrostichum*



C21

Bosque desenvolvido, maduro, com *Acrostichum* ao entorno



C22

Bosque maduro troncos finos, solo mais seco com presença de *Acrostichum*



C23

Bosque maduro, com rebrotamento, presença de *Acrostichum* e *Hibiscus* ao entorno



C24

Bosque maduro, indivíduos com porte médio, presença de *Hibiscus* e *Acrostichum* ao entorno



C25

Bosque maduro de bacia, árvores pequenas e ramificadas, solo seco, presença de clareira e outras vegetações ao entorno



C26

Bosque maduro com indivíduos de porte médio, alagado, com indivíduos menores ao entorno



C27

Bosque maduro desenvolvido com rebrotamento



C28

Bosque maduro,
desenvolvido a
médio



C29

Bosque maduro,
desenvolvido



C30

Bosque
desenvolvido,
troncos finos
ramificados



C31

Bosque maduro, indivíduos médios, com rebrotamento e *Acrostichum*



C32

Bosque maduro, alguns indivíduos mortos, com rebrotamento e *Acrostichum* e *Hibiscus*, área poluída



C33

Bosque maduro, indivíduos médios, com rebrotamento e muito *Acrostichum* e *Hibiscus*, área poluída



C34

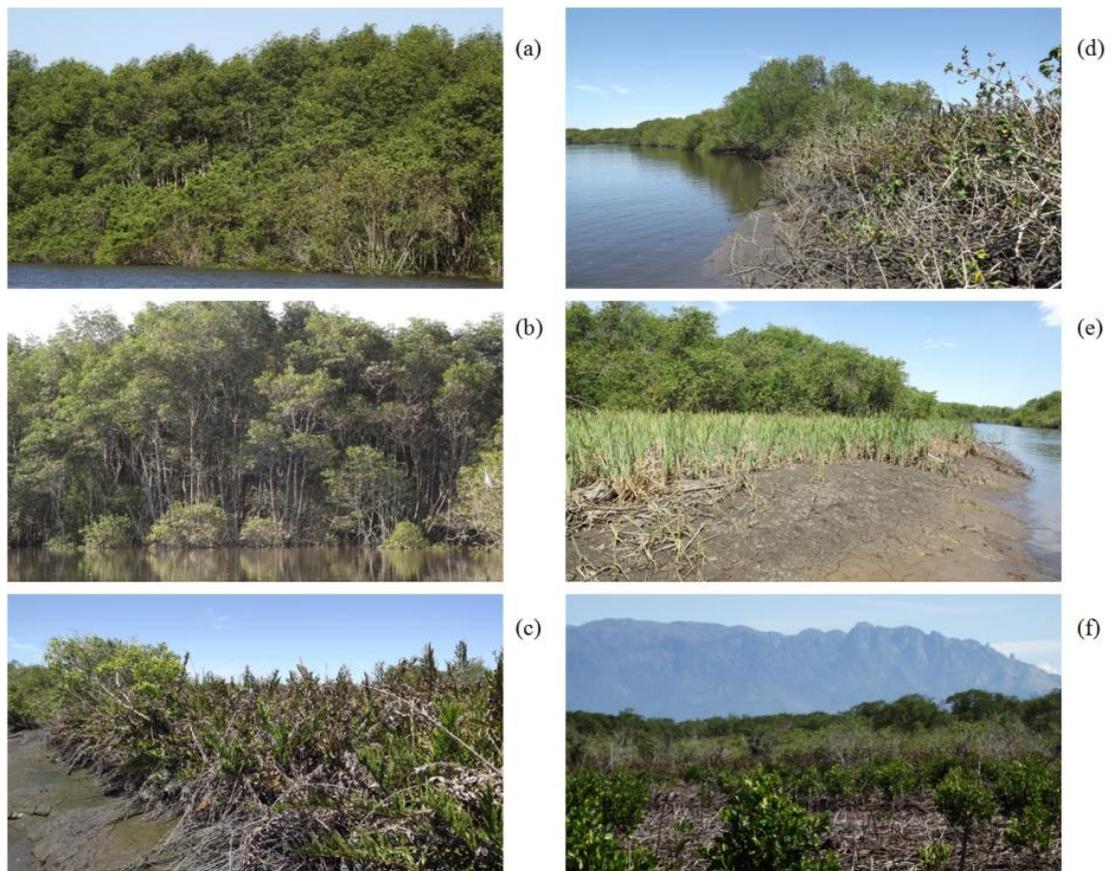
Bosque maduro
com indivíduos
médios a
pequenos,
troncos
ramificados e
galhos
quebrados,
Acrostichum ao
entorno



Figura A.1 - Aquisição de dados de campo. (a) obtenção das coordenadas geográficas dos vértices das parcelas de campo, levantamento com receptor GPS de precisão (b) identificação e medição de indivíduos arbóreos.



Figura A.2 - Tipos de cobertura vegetal encontrados no manguezal da APA de Guapimirim, (a) e (b) floresta de mangue estruturalmente desenvolvida, (c) *Acrostichum*, (d) *Hibiscus*, (e) *Spartina*, (f) reflorestamento de mangue.



APÊNDICE B - Resultados dos modelos de regressão M2a e M2b

Tabela B.1 - Resultados da estimativa de variância *jackknife* (*jack.test.autopls*) para o modelo M2a.

Parâmetro	Coeficiente	Std. Erro	t valor	Pr(> t)
avg	8,6730	6,2825	1,3805	0,17671
d02	-9,0128	3,6381	-2,4774	0,01853 *
d03	13,7730	5,4051	2,5481	0,01567 *
d04	-8,3888	3,5560	-2,3590	0,02439 *
d05	8,8587	4,6254	1,9152	0,06417 .
d08	9,0938	5,1396	1,7694	0,08607 .
max	14,2134	6,2871	2,2607	0,03050 *
min	-8,3112	3,4497	-2,4093	0,02172 *

Signif. codes: 0 '***' 0,001 '**' 0,01 '*' 0,05 '.' 0,1 ' ' 1

Figura B.1 - Importância das variáveis para o modelo M2b Random Forest, valores baseados na *mean decrease in accuracy* (%incMSE) e *mean decrease in node impurity* (IncNodePurity).

