Universidade de São Paulo
Escola Superior de Agricultura “Luiz de Queiroz”

Estratificação de povoamentos de *Eucalyptus* spp. em classes de idade por
escaneamento a laser aeroembarcado

Alexandre Pansini Camargo

Dissertação apresentada para a obtenção do título de
Mestre em Ciências, Programa: Recursos Florestais.
Opção em: Silvicultura e Manejo Florestal

Piracicaba
2017

Alexandre Pansini Camargo
Engenheiro Florestal

Estratificação de povoamentos de *Eucalyptus* spp. em classes de idade por escaneamento
a laser aeroembarcado

versão revisada de acordo com a resolução CoPGr 6018 de 2011

Orientador:
Prof. Dr. **LUIZ CARLOS ESTRAVIZ RODRIGUEZ**

Dissertação apresentada para a obtenção do título de
Mestre em Ciências, Programa: Recursos Florestais.
Opção em: Silvicultura e Manejo Florestal

Piracicaba
2017

Dados Internacionais de Catalogação na Publicação
DIVISÃO DE BIBLIOTECA – DIBD/ESALQ/USP

Camargo, Alexandre Pansini

Estratificação de povoamentos de *Eucalyptus* spp. em classes de idade por escaneamento a laser aerombarcado / Alexandre Pansini Camargo. - - versão revisada de acordo com a resolução CoPGr 6018 de 2011. - - Piracicaba, 2017.

86 p.

Dissertação (Mestrado) - - USP / Escola Superior de Agricultura "Luiz de Queiroz".

1. LiDAR 2. Sensoriamento remoto 3. Índices de vegetação 4. Inventário florestal 5. Classificação etária I. Título

À todos os membros da minha família Pansini e Camargo.

Aos meus pais, Antonio Renato e Marilene.

Aos meus irmãos, Vinícius e Bárbara.

Ao meu cunhado, Rafael.

DEDICO

AGRADECIMENTOS

À Deus, pela vida e saúde;

Aos meus pais, Antonio Renato e Marilene, por todo o carinho, amor e suporte à vida;

Aos meus queridos irmãos, Vinicius e Bárbara, e cunhado, Rafael, pela companhia em todos os momentos e pelo apoio nos momentos mais críticos enfrentados;

Ao professor Dr Luiz Carlos Estraviz Rodriguez pela orientação, esclarecimentos e paciência no ensino da arte de ser pesquisador;

Aos meus amigos do GET-LiDAR, Jefferson Polizel, Julianne Oliveira, André G. Silva, Danitiele Laranja, Cristiano Rodrigues, Daniel Papa, Luíza Amaral, Gustavo Almeida, Gabriel Prata, Thais Abib, Caio Hamamura, Thiago de Conto e Lucas Kelvin pelo companheirismo em todos os momentos de aprendizados e pela paciência;

Aos amigos e pesquisadores Eric Görgens e Danilo Almeida pelas dicas valiosas na edição deste trabalho;

Aos amigos do CMQ que sempre colaboraram com os momentos descontraídos de almoço e cafezinho, e com as ajudas nos momentos importantes da nossa jornada na pós-graduação;

Aos meus amigos da república Paiol que me acolheram em sua casa para me hospedar durante o período de disciplinas e trabalhos realizados na cidade de Piracicaba;

À Giovana Oliveira por todo o apoio administrativo realizado e por ouvir com paciência nossos pedidos urgentes;

À Fibria S.A. pelos dados de campo e dados LiDAR fornecidos sem os quais esse trabalho seria inviável;

Ao Ministério do Meio Ambiente, que através do site GeoCatálogo possibilitou o download das imagens RapidEye para o estudo nesse trabalho;

Ao Instituto Florestal do Estado de São Paulo, na pessoa do pesquisador MSc Marco Aurélio Nalon forneceu importante material para a conclusão da pesquisa;

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo financiamento com a bolsa de Mestrado Acadêmico (MA) concedida;

Ao Programa de Pós-Graduação em Recursos Florestais, pela oportunidade cursar o mestrado dentro da instituição e pelo suporte em materiais e equipamentos à essa pesquisa;

A todos que estiveram presente na minha vida durante esse período e que de alguma forma contribuíram para me tornar uma pessoa melhor.

“Eu sei o preço do sucesso: dedicação, trabalho duro, e uma incessante devoção às coisas que você quer ver acontecer”

Frank Lloyd Wright

SUMÁRIO

RESUMO	8
ABSTRACT	9
LISTA DE FIGURAS.....	10
LISTA DE TABELAS.....	13
LISTA DE ABREVIATURAS E SIGLAS	14
1. INTRODUÇÃO	17
2. REVISÃO BIBLIOGRÁFICA.....	19
2.1. BIOMETRIA E INVENTÁRIO FLORESTAL.....	19
2.2. IMAGENS DE SATÉLITES	19
2.3. TECNOLOGIA AIRBORNE LASER SCANNING (ALS)	21
3. MATERIAL E MÉTODOS.....	25
3.1. ÁREA DE ESTUDO.....	25
3.2. COLETA DE DADOS DE CAMPO	27
3.1. IMAGENS DE SATÉLITE	28
3.2. DADOS DE AEROLEVANTAMENTO A LASER	32
3.3. PROCESSAMENTO DOS DADOS.....	33
3.3.1. <i>Processamento do aerolevanteamento a laser</i>	33
3.3.2. <i>Produtos das nuvens de pontos</i>	37
3.3.3. <i>Modelo Digital de Terreno (MDT)</i>	37
3.3.4. <i>Modelo Digital de Superfície (MDS)</i>	37
3.3.5. <i>Modelos de Altura do Dossel (CHM)</i>	38
3.3.6. <i>Métricas das nuvens de pontos</i>	38
3.3.7. <i>Processamento dos dados de satélites</i>	38
3.4. MAPA FINAL DOS POVOAMENTOS	42
4. RESULTADOS.....	43
4.1. PROCESSAMENTO DAS NUVENS DE PONTOS.....	43
4.2. PRODUTOS DO PROCESSAMENTO DA NUVEM DE PONTOS	46
4.3. MÉTRICAS DAS NUVENS DE PONTOS	46
4.4. MODELOS COM VARIÁVEIS EXPLICATIVAS DE DADOS LIDAR.....	53
4.5. MODELOS COM VARIÁVEIS DE ÍNDICES DE VEGETAÇÃO	57
5. DISCUSSÃO.....	71
5.1. PROCESSAMENTO DAS NUVENS DE PONTOS ALS	71
5.2. PRODUTOS DO PROCESSAMENTO DA NUVEM DE PONTOS	72
5.3. MÉTRICAS DAS NUVENS DE PONTOS	72
5.4. MODELOS PREDITIVOS DE IDADE COM DADOS LIDAR	73
5.5. REPRESENTAÇÃO GRÁFICA DA DISTRIBUIÇÃO DE IDADE	74
5.6. MODELOS COM VARIÁVEIS DE ÍNDICES DE VEGETAÇÃO	75
5.7. MAPA FINAL DOS POVOAMENTOS	76
6. CONCLUSÃO.....	79
REFERÊNCIAS	81

RESUMO

Estratificação de povoamentos de *Eucalyptus* spp. em classes de idade por escaneamento a laser aeroembarcado

As condições climáticas do Brasil aliadas ao desenvolvimento tecnológico favorecem a obtenção de sucessivos incrementos em produção florestal e estimulam a expansão de área cultivada com povoamentos voltados para a produção madeireira. Com o objetivo de contribuir para o processo de quantificação das florestas plantadas em uma escala regional, este estudo propõe utilizar informações combinadas de imagens de satélites e dados obtidos do LiDAR (*Light Detecting and Ranging*) para a construção de modelos determinísticos capazes de distinguir em duas categorias de idade agrupamentos de florestas plantadas no Vale do Paraíba, estado de São Paulo. A primeira etapa constitui utilizar informações de parcelas de campo como resposta para modelos gerados com variáveis de escaneamento a laser aeroembarcado (ALS) e extrapolar os parâmetros para toda a região da plantação; em um segundo momento, utilizar as informações extrapoladas para gerar um modelo composto por variáveis de índice de vegetação (IV) calculados das imagens de satélite. As informações LiDAR (*Light Detecting and Ranging*) foram obtidas de sete fazendas da região do Vale do Paraíba, estado de São Paulo, em 2012, mesmo ano em que foram coletados os dados das parcelas de campo dos inventários florestais e que as imagens foram obtidas pela constelação de satélites RapidEye. Como variáveis de dados ALS foram utilizados o cálculo de todos os pontos por célula de 5 x 5 m avaliados, alturas máxima, mínima, média, desvio padrão e percentis de altura, calculados pelo programa de análise de dados *LASTools*®. Foram incluídas também métricas de diferença de alturas do percentil 90 e o percentil 10 (p_{9010}) e a medida dessa diferença relativa à altura do percentil 90 (p_{9010r}). Na modelagem dos dados LiDAR para imagens de satélite foram utilizadas como variáveis, de forma individual ou conjuntamente, os índices NDVI, $NDVI_{705}$, EVI, GNDVI, SAVI, Red-Green ratio e SRI. Os modelos foram avaliados quanto ao seu desempenho no coeficiente de determinação (R^2) e na raiz do erro quadrático médio (RMSE) e em uma análise final predizendo as fazendas em categorias de idade jovem e maduro. O modelo com melhores estimativas (R^2 e RMSE) para idade na primeira etapa foi o que possuía variáveis H_{p90} e H_{p9010r} , com $R^2=0,85$ e $RMSE=11,736$ meses, e para a segunda etapa foi o modelo contendo como variáveis os índices de vegetação $NDVI_{705}$, Red-Green index e SAVI, com $R^2=0,49$ e $RMSE=0,378$ meses. Apesar dos resultados melhores, o modelo contendo índices de vegetação GNDVI e Red-Green index foi o que melhor representou a distribuição das florestas quanto a sua maturidade.

Palavras-chave: LiDAR; Sensoriamento remoto; Índices de vegetação; Inventário florestal; Classificação etária

ABSTRACT

Stratification of stands of *Eucalyptus* spp. in age classes by airborne laser scanning

Brazil's climate conditions combined with the technological development promote the obtaining of successive increments in forest production and stimulate the expansion of cultivated area with stands for timber production. In order to contribute to the process of quantification of planted forests at regional scale, this study proposes to use combined information from satellite images and data obtained from the LiDAR (Light Detecting and Ranging) for the construction of deterministic models able to distinguish two categories of age groupings of planted forests in the Paraíba Valley, State of São Paulo in Brazil. The first step is to use field plots information in response to models generated with airborne laser scanning (ALS) variables and extrapolate the parameters for the whole region of the plantation; in a second moment, use the information extrapolated to generate a model composed of vegetation index variables (IV) calculated from satellite images. The information LiDAR (Light Detecting and Ranging) were obtained from seven farms in the region of the Paraíba Valley, State of São Paulo, in 2012, the same year in which the data were collected from plots of field forest inventories and that the images were obtained by the RapidEye satellite constellation. As data variables ALS were used the calculation of all points by cell size of 5 x 5 m evaluated, maximum height, minimum, mean, standard deviation and height percentiles, calculated by the data analysis program called LASTools®. Also included height difference metrics 90th percentile and percentile 10th (p9010) and the extent of this difference relative of the 90th percentile (p9010r). In the modeling of data LiDAR data for satellite images were used as variables, individually or jointly, the NDVI index, NDVI705, EVI, GNDVI, SAVI, Red-Green index and SRI. The models were evaluated regarding their performance on the coefficient of determination (R^2) and root mean square error (RMSE) and a final analysis predicting the farms into categories of age, young and mature. The model with best estimates (R^2 and RMSE) for age at first stage was what possessed variables Hp90 and Hp9010r, with $R^2 = 0.85$ and RMSE = 11.736 months, and the second stage was the model containing as variables the NDVI705 vegetation, Red-Green index and SAVI, with $R^2 = 0.49$ and RMSE = 0.378 months. Despite the better results, the model containing GNDVI and Red-Green vegetation indices was the best represented distribution of forests about your maturity.

Keywords: LiDAR; Remote sensing; Vegetation indices; Forest inventory; Age classification

LISTA DE FIGURAS

FIGURA 1. FLUXO DE TRABALHO COM AS DIVERSAS FONTES DE INFORMAÇÕES PARA O PROCEDIMENTO ABORDAGEM BASEADA POR ÁREA – ABA. ADAPTADO DE (WHITE ET AL., 2013).	23
FIGURA 2. LOCALIZAÇÃO DAS CIDADES NO VALE DO PARAÍBA DENTRO DO ESTADO DE SÃO PAULO.	25
FIGURA 3. PARCELAS DE CAMPO LOCALIZADAS DENTRO DAS IMAGENS DE SATÉLITE.	26
FIGURA 4. REPRESENTAÇÃO DA COBERTURA DE ÁREAS REFLORESTADAS DO ESTADO DE SÃO PAULO. FONTE: (INSTITUTO FLORESTAL - SECRETARIA DO MEIO AMBIENTE DO ESTADO DE SÃO PAULO, 2013).....	26
FIGURA 5. FAZENDAS JATAÍ E SÃO JOSÉ III, RESPECTIVAMENTE, COM DELIMITAÇÕES DOS SEUS PLANTIOS E LOCALIZAÇÃO DAS PARCELAS DE CAMPO.	30
FIGURA 6. FAZENDAS SANTA CECÍLIA E PATIZAL DO VALE FELIZ, RESPECTIVAMENTE, COM DELIMITAÇÕES DOS SEUS PLANTIOS E LOCALIZAÇÃO DAS PARCELAS DE CAMPO.....	30
FIGURA 7. FAZENDAS SANTA TEREZINHA V E SANTA TEREZINHA VI, RESPECTIVAMENTE, COM DELIMITAÇÕES DOS SEUS PLANTIOS E LOCALIZAÇÃO DAS PARCELAS DE CAMPO. .	31
FIGURA 8. FAZENDA URUTAY COM DELIMITAÇÕES DOS SEUS PLANTIOS E LOCALIZAÇÃO DAS PARCELAS DE CAMPO.....	31
FIGURA 9. À PRIMEIRA À ESQUERDA É A FOTO DO SENSOR LIDAR RIEGL, AO SEU LADO <i>HARD DISKS</i> (HDS) QUE ARMAZENAM OS DADOS DURANTE O VOO E SERVEM COMO BACKUP DAS INFORMAÇÕES; A ESCOTILHA ABERTA, POR ONDE É EMITIDO O PULSO LASER E, EM SEGUIDA, O MONITOR COM AS INFORMAÇÕES DE SAÍDA, UTILIZADOS PELO OPERADOR. FONTE: FOTO DO EQUIPAMENTO SELECIONADO DO SITE DA EMPRESA (RIEGL LASER MEASUREMENT SYSTEMS, 2017) E DEMAIS FOTOS PERTENCENTES AO PRÓPRIO AUTOR.	33
FIGURA 10. MÉTRICA CRIADA COM BASE NAS OBSERVAÇÕES DAS NUVENS DE PONTOS ALS.	36
FIGURA 11. PROCESSAMENTO DIGITAL DE IMAGENS EM SENSORIAMENTO REMOTO. FONTE: PRÓPRIO AUTOR.	39
FIGURA 12. MAPA DE DISTRIBUIÇÃO DOS PONTOS VISTO NA FERRAMENTA <i>LASVIEW</i> DO SOFTWARE <i>LASTOOLS</i> PARA AS NUVENS DE PONTOS NÃO-NORMALIZADAS CLASSIFICADAS POR ALTURA DOS PONTOS.....	45

FIGURA 13. MODELOS DIGITAIS DE TERRENO (MDT) EM FORMATO DE <i>HILLSHADE</i> DAS FAZENDAS DE ESTUDO. A: JATAÍ; B: PATIZAL DO VALE FELIZ; C: SÃO JOSÉ III; D: URUTAY; E: SANTA CECÍLIA; F: SANTA TEREZINHA V E VI.....	47
FIGURA 14. <i>CANOPY HIGHT MODEL</i> (CHM) GERADO PELA DIFERENÇA ENTRE OS MODELOS DIGITAIS DE SUPERFÍCIE (MDS) E MODELOS DIGITAIS DE TERRENO (MDT). É POSSÍVEL NOTAR AS FLORESTAS PLANTADAS SOBRESSAINDO EM ESCALA DE COR MAIS CLARA. A: JATAÍ; B: PATIZAL DO VALE FELIZ; C: SÃO JOSÉ III; D: URUTAY; E: SANTA CECÍLIA; F: SANTA TEREZINHA V E VI.....	48
FIGURA 15. GRÁFICOS DE DISPERSÃO EXPLORATÓRIOS DE RELAÇÃO ENTRE VARIÁVEIS DE DADOS LIDAR E A IDADE DAS PARCELAS DE CAMPO DAS FLORESTAS (CONTINUA).....	51
FIGURA 16. GRÁFICOS DE DISPERSÃO EXPLORATÓRIOS DE RELAÇÃO ENTRE VARIÁVEIS DE DADOS LIDAR E A IDADE DAS PARCELAS DE CAMPO DAS FLORESTAS.....	52
FIGURA 17. GRÁFICO QUANTIL-QUANTIL DOS RESÍDUOS ESTUDENTIZADOS POR QUANTIS TEÓRICOS DO MODELO 2 E UM GRÁFICO DE DISPERSÃO DOS RESÍDUOS POR VALORES AJUSTADOS DO MODELO 2.	53
FIGURA 18. GRÁFICO QUANTIL-QUANTIL DOS RESÍDUOS ESTUDENTIZADOS POR QUANTIS TEÓRICOS DO MODELO 5 E UM GRÁFICO DE DISPERSÃO DOS RESÍDUOS POR VALORES AJUSTADOS DO MODELO 5.	55
FIGURA 19. GRÁFICO QUANTIL-QUANTIL DOS RESÍDUOS ESTUDENTIZADOS POR QUANTIS TEÓRICOS DO MODELO 6 E UM GRÁFICO DE DISPERSÃO DOS RESÍDUOS POR VALORES AJUSTADOS DO MODELO 6.	55
FIGURA 20. MAPAS GERADOS COM A APLICAÇÃO DO MODELO 6 PARA IDADES (MESES) NAS FAZENDAS A: SANTA TEREZINHA V E VI; B: JATAÍ; C: PATIZAL; D: SÃO JOSÉ III; E: SANTA CECÍLIA; E F: URUTAY.	56
FIGURA 21. ANÁLISE DE AGRUPAMENTO EM DENDROGRAMA DAS VARIÁVEIS CANDIDATAS A COMPOR O MODELO.	58
FIGURA 22. DISTRIBUIÇÃO DAS IDADES POR FAZENDA COM APLICAÇÃO DO MODELO 4. A LINHA VERMELHA REPRESENTA A IDADE DE DIVISÃO DOS PLANTIOS EM CATEGORIA JOVEM E MADURA.....	60
FIGURA 23. REPRESENTAÇÃO GRÁFICA DA DISTRIBUIÇÃO DA IDADE DO PLANTIO CALCULADO POR NOVE DIFERENTES MODELOS COMPOSTOS POR ÍNDICES DE VEGETAÇÃO PARA A FAZENDA SANTA CECÍLIA.....	61

FIGURA 24. REPRESENTAÇÃO GRÁFICA DA DISTRIBUIÇÃO DA IDADE DO PLANTIO CALCULADO POR NOVE DIFERENTES MODELOS COMPOSTOS POR ÍNDICES DE VEGETAÇÃO PARA A FAZENDA JATAÍ.	62
FIGURA 25. REPRESENTAÇÃO GRÁFICA DA DISTRIBUIÇÃO DA IDADE DO PLANTIO CALCULADO POR NOVE DIFERENTES MODELOS COMPOSTOS POR ÍNDICES DE VEGETAÇÃO PARA A FAZENDA PATIZAL.....	63
FIGURA 26. REPRESENTAÇÃO GRÁFICA DA DISTRIBUIÇÃO DA IDADE DO PLANTIO CALCULADO POR NOVE DIFERENTES MODELOS COMPOSTOS POR ÍNDICES DE VEGETAÇÃO PARA A FAZENDA SÃO JOSÉ III.....	64
FIGURA 27. REPRESENTAÇÃO GRÁFICA DA DISTRIBUIÇÃO DA IDADE DO PLANTIO CALCULADO POR NOVE DIFERENTES MODELOS COMPOSTOS POR ÍNDICES DE VEGETAÇÃO PARA A FAZENDA SANTA TEREZINHA V.	65
FIGURA 28. REPRESENTAÇÃO GRÁFICA DA DISTRIBUIÇÃO DA IDADE DO PLANTIO CALCULADO POR NOVE DIFERENTES MODELOS COMPOSTOS POR ÍNDICES DE VEGETAÇÃO PARA A FAZENDA SANTA TEREZINHA VI.	66
FIGURA 29. REPRESENTAÇÃO GRÁFICA DA DISTRIBUIÇÃO DA IDADE DO PLANTIO CALCULADO POR NOVE DIFERENTES MODELOS COMPOSTOS POR ÍNDICES DE VEGETAÇÃO PARA A FAZENDA URUTAY.	67
FIGURA 30. MÉTRICAS DE DESVIO PADRÃO DA ALTURA, P9010R E P9010 COMPARADAS ENTRE OS ESTRATOS DAS FAZENDAS.....	68
FIGURA 31. MÉTRICAS DO DESVIO PADRÃO DA ALTURA, P90 E COBERTURA COMPARADAS ENTRE OS ESTRATOS DAS FAZENDAS.....	69
FIGURA 32. POVOAMENTOS FLORESTAIS CATEGORIZADOS POR IDADE.	70

LISTA DE TABELAS

TABELA 1. RESUMO DAS INFORMAÇÕES DAS FAZENDAS.....	28
TABELA 2. DATAS DE COLETA DOS DADOS.	28
TABELA 3. CARACTERÍSTICAS DO SATÉLITE <i>RAPIDEYE</i> , COM O SENSOR REIS. FONTE: (PLANET LABS INC., 2016).	29
TABELA 4. COORDENADAS DAS IMAGENS RAPIEYE.....	29
TABELA 5. DESCRIÇÃO DAS CARACTERÍSTICAS CONTRATADAS PARA O VOO DE AEROLEVANTAMENTO A LASER SOBRE A REGIÃO DO VALE DO PARAÍBA.	32
TABELA 6. MÉTRICAS LIDAR QUE SÃO GERADAS ATRAVÉS DO <i>LASCANOPY</i> (LASTOOLS®) E SERÃO UTILIZADAS NESSE PROJETO. FONTE: SILVA (2013) E SHINZATO (2015).....	35
TABELA 7. ÍNDICES DE VEGETAÇÃO ORIGINADOS QUE PODEM SER OBTIDOS COM BANDAS PRESENTE NAS IMAGENS DA SÉRIE DE IMAGENS RAPIDEYE.....	39
TABELA 8. RELATÓRIO DESCRITIVO DE DADOS ALS DE SOBREVOO REALIZADO NAS FAZENDAS NO VALE DO PARAÍBA.	43
TABELA 9. CORRELAÇÃO DE PEARSON ENTRE AS VARIÁVEIS DE DADOS LIDAR	49
TABELA 10. EQUAÇÕES DE IDADE COM VARIÁVEIS DO SOBREVOO ALS	53
TABELA 11. TESTE DE NORMALIDADE E HOMOCEDASTICIDADE DA VARIÂNCIA NOS MODELOS.	54
TABELA 12. TABELA COM AS MÉDIAS E DESVIOS DA IDADE DE CADA UMA DAS FAZENDAS DESTACADAS NO MAPA COM DADOS LIDAR.....	57
TABELA 13. MODELOS COMPOSTOS POR ÍNDICES DE VEGETAÇÃO.....	59

LISTA DE ABREVIATURAS E SIGLAS

3D	– <i>Three Dimentional</i> (três dimensões)
AIC	– <i>Akaike Information Criterion</i> (critério de informação de Akaike)
ALS	– <i>Airborne Laser Scanning</i> (escaneamento a laser aerotransportado)
APP	– Área de Preservação Permanente
BIL / .bil	– <i>Band Interleaved by Line</i> (Banda intervalada por linha)
CHM	– <i>Canopy Height Model</i> (modelo de altura de dossel)
CSV /.csv	– <i>Comma-separated values</i> (Valores separados por vírgula)
DAP	– <i>Diameter at Breast Height</i> (Diâmetro à Altura do Peito)
DEM	– <i>Digital Elevation Model</i> (modelo digital de terreno)
DTM	– <i>Digital Terrain Model</i> (modelo digital de terreno)
EO1	– <i>Earth Observing One</i> (Observação da Terra Um)
Esalq	– Escola Superior de Agricultura "Luiz de Queiroz"
ETM+	– <i>Enhanced Thematic Mapper Plus</i> (Mapeador Temático Melhorado Mais)
EVI	– <i>Enhanced Vegetation Index</i> (Índice de Vegetação Melhorada)
FLAASH	– <i>Fast Line-of-sight Atmospheric Analysis of Hypercubes</i> (Análise Rápida de Linha de Visão Atmosférica de Hiper cubos)
FOV	– <i>Field of View</i> (campo de visão)
GNDVI	– <i>Green Normalized Difference Vegetation Index</i> (Índice de Vegetação por Diferença Normalizada da banda do Verde)
GNSS	– <i>Global Navigation Satellite System</i> (Sistema de Navegação Global por Satélites)
GPS	– <i>Global Positioning System</i> (Sistema de Posicionamento Global)
HD	– <i>Hard Disk</i> (Disco Rígido)
IMU	– <i>Inertial Measurement Unit</i> (unidade de medição inercial)
LASER	– <i>Light Amplification by Stimulated Emission of Radiation</i> (amplificação da luz por emissão estimulada de radiação)
LCF	– Departamento de Ciências Florestais (antigo “Laboratório de Ciências Florestais”)
LiDAR	– <i>Light Detection and Ranging</i> (detecção e distanciamento da luz)
MMA	– Ministério do Meio Ambiente

MODTRAN4	– <i>MODerate resolution atmospheric TRANsmission 4</i> (Transmissão atmosférica de resolução moderada 4)
NDVI	– <i>Normalized Difference Vegetation Index</i> (Índice de Vegetação por Diferença Normalizada)
NDVI ₇₀₅	– <i>Red Edge Normalized Vegetation Index</i> (Índice de Vegetação por Diferença Normalizada da Borda do Infra-vermelho)
NIR	– <i>Near-infrared</i> (Infra-vermelho próximo)
REIS	– <i>RapidEye Imaging System</i> (Sistema de Imageamento RapidEye)
RMSE	– <i>Root Mean Square Error</i> (raiz do erro quadrático médio)
rRMSE	– <i>relative Root Mean Square Error</i> (raiz do erro quadrático médio relativo)
SAVI	– <i>soil-adjusted vegetation index</i> (Índice de Vegetação Ajustada do solo)
SIG	– <i>Geographyc Information System</i> (Sistema de Informação Geográfica)
SIRGAS2000	– Sistema de Referência Geocêntrico para as Américas de 2000
SLC	– <i>Scan Line Corrector</i> (corretor de linha de varredura)
SRI	– <i>Simple Ratio Index</i> (Índice de razão simples)
USGS	– <i>United States Geological Survey</i> (Levantamento Geológico dos Estados Unidos)
UTM	– <i>Universal Transversa de Mercator</i>
WGS84	– <i>World Geodetic System 84</i> (Sistema Geodésico Mundial de 84)

1. INTRODUÇÃO

As florestas plantadas possuem um papel importante na sociedade atual no fornecimento de matéria-prima para biomassa, energia e celulose, assumindo lugar reduzindo a pressão sobre as florestas nativas. São consideradas fontes seguras de fornecimento de matéria prima para produtos madeireiros e não-madeireiros importantes para o consumo humano, em que o uso da terra se dá de forma legítima e garante a produção sustentável, contribuindo para assegurar a manutenção dos princípios da segurança alimentar e redução à pobreza (FAO, 2010).

A América do Sul conta com ótimas condições climáticas para o cultivo de florestas plantadas, e países como Chile, Uruguai e Brasil são exemplos de países que plantam florestas em monocultivo homogêneo de alto rendimento principalmente para a produção de celulose (INDUSTRIA BRASILEIRA DE ÁRVORES, 2014). No território brasileiro as florestas estão presentes em todas as macrorregiões administrativas. Em 2014 a área de florestas plantadas atingiu o valor de 7,74 milhões de hectares, um aumento de 1,8 % comparado à área plantada de floresta no ano de 2013, sendo representado por 71,9 % de plantios de eucaliptos e 20,5% de plantios de *Pinus spp.*, concentrados principalmente nos estados de Minas Gerais, São Paulo, Paraná, Santa Catarina, Bahia e Mato Grosso do Sul (ABRAF, 2013; IBA, 2015). Todo esse maciço florestal utilizado por indústrias são manejados e recebem os cuidados silviculturais para tornarem-se florestas altamente produtivas, e o planejamento florestal é importante nesse processo. O manejo florestal precisa de informações sobre a distribuição do estoque de biomassa e o desenvolvimento da floresta por regiões, para o planejamento florestal seja adequado para maximizar o ganho de capital no investimento.

O planejamento da propriedade rural requer necessariamente o conhecimento da quantidade de estoque de madeira e a produtividade dos plantios florestais para abastecer as indústrias de base madeireira (MACHADO; FIGUEIREDO FILHO, 2006a). Enquanto que a biometria florestal se encarrega de quantificar o volume da madeira e permite calcular o crescimento de uma árvores através da medida de parâmetros dendrométricos (MACHADO; FIGUEIREDO FILHO, 2006a), o inventário florestal é a aplicação de um conjunto de ferramentas estatísticas que tem o potencial de especializar a quantificação feita sobre um conjunto de amostras do povoamento para toda a área do plantio (HIGUCHI;

SANTOS; LIMA, 2008; MEUNIER; SILVA; FERREIRA, 2001) significa a quantificação do volume de madeira é a se vale de ferramentas estatísticas que estimam parâmetros da floresta com base em amostras. Algumas medidas coletadas de florestas plantadas podem ser obtidas com um custo relativamente menor comparadas às outras, como o caso do diâmetro, que pode ser obtida facilmente, com menor erro nas medições, enquanto que altura das árvores são demoradas, muitas vezes imprecisas e mais difícil de aferir em campo (BINOTI et al., 2013). Como técnicas mais precisas tomam mais tempo e consomem mais recursos, estas são bastante aplicáveis para áreas pequenas ou localizadas em regiões próximas. Contudo, seriam muito onerosas atividades como essas para regiões mais abrangentes e, devido às diferenças entre os cultivos dos plantios, poderiam se tornar bastante imprecisas.

Com a finalidade de quantificar povoamentos florestais em uma escala regional por categorias de maturidade do plantio florestal propomos nesse trabalho utilizar uma amostragem em duas etapas: utilizar parcelas de campo validando dados de sensoriamento remoto ativo ALS, e, em seguida, dados ALS de toda a cobertura florestal da fazenda validando imagens de satélites. A especialização das florestas plantadas por classe de maturidade será a consequência dessas avaliações.

No decorrer deste trabalho, estudaremos com maiores detalhes:

- Classificação de povoamentos de *Eucalyptus* spp. em duas categorias de idade;
- Distribuição dos plantios por categoria;

A hipótese é que áreas de plantios homogêneos podem ser diferenciadas em categorias de idade jovem e madura através da modelagem em duas etapas.

2. REVISÃO BIBLIOGRÁFICA

2.1. Biometria e inventário florestal

A avaliação da produtividade de povoamentos florestais depende da avaliação de variáveis dendrométricas, cuja importância é fundamental (ARAÚJO; LEITE; PAES, 2004). A estatística de inferência moderna trabalha com dados biométricos coletados em amostras e possibilitam que estas informações sejam extrapoladas para toda uma população. Estes métodos se tornaram conhecidos através de publicações de Karl Pearson e Ronald Fisher no início do século passado (HIGUCHI; SANTOS; LIMA, 2008). Assim, com base nas informações extraídas do campo e com o auxílio da computação, os profissionais de engenharia florestal são capazes de gerenciar as atividades e realizar a otimização do processo produtivo florestal (MEUNIER; SILVA; FERREIRA, 2001), através de um conjunto de técnicas chamada inventário florestal.

A aplicação do inventário florestal na obtenção de dados do plantio é largamente utilizado e fornece informações precisas para tomadas de decisão por parte do gestor florestal. Apesar de largamente utilizadas, informações provenientes de campo podem conter erros em medições e não representar características da floresta. Pereira (2009) realizou um *check-list* em características quantitativas e qualitativas do inventário florestal e observou um considerável número de não-conformidades nos dados, principalmente em áreas com maior declividade. Em termos de volumes finais, uma tendência de subestimar valores foi observada.

Em pequenas áreas, com conglomerados de plantios próximos, o inventário pode fornecer informações seguras quantitativas e qualitativas. Por outro lado, para áreas mais distribuídas e com logística restritiva, pode ser uma alternativa onerosa e que demanda tempo. Nesse sentido, novas abordagens no estudo de parâmetros florestais para escala regional precisam ser investigadas para compreender o comportamento das florestas em um nível amplo e fornecer informações úteis para empresas e agentes públicos.

2.2. Imagens de satélites

A facilidade em acesso a informações disponíveis em rede e o avanço da tecnologia na área espacial e informática trouxeram para o profissional

contemporâneo possibilidades de uso de informações de sensores remotos. Novo (2010) define sensoriamento remoto como sendo a utilização conjunta de sensores, equipamentos para o processamento de dados, equipamentos transportados em aeronaves ou outras plataformas que são capazes de capturar os fenômenos e processos que ocorrem na superfície do planeta Terra (NOVO, 2010). É notável o uso de informações de sensoriamento e aparece em trabalhos de diversos profissionais, em estudos ligados à vegetação (BOLFE; BATISTELLA; FERREIRA, 2012; GAO, 1996; LANG, 2005; PARISE; VETTORAZZI, 2005) ou voltados para áreas afins ao planejamento de atividades.

As imagens de satélite são importantes por armazenar informações sobre um período passado, ou fazer relações com banco de dados em análises de séries temporais. A plataforma aeroespacial RapidEye tem um potencial de avaliação da cobertura terrestre muito bom e são disponibilizados pela empresa Planet® (PLANET LABS INC., 2016). Com uma constelação de 5 microssatélites, possui imagens com resolução espectral de 5 m e tempo de revisita de 24 horas, pode ser muito útil para avaliação de áreas onde a dificuldade de acesso é grande, ou auxiliar no planejamento de estradas e benfeitorias.

As principais avaliações realizadas com o uso de imagens de satélite para estudos em vegetação são baseadas na utilização de métricas calculadas com a reflectância específica dos alvos, chamadas de índices de vegetação (PONZONI; SHIMABUKURO, 2007). Muitos pesquisadores testaram índices de vegetação na relação com parâmetros biológicos ou biométricos da população estudada e foram bem sucedidos (BOLFE; BATISTELLA; FERREIRA, 2012; GAO, 1996; PARISE; VETTORAZZI, 2005; RAMOS et al., 2010; SHINZATO, 2015). Os índices mais relatados são o uso do *Normalized Difference Vegetation Index* - NDVI (PARISE; VETTORAZZI, 2005; RAMOS et al., 2010; SHINZATO, 2015) e o *Enhanced Vegetation Index* - EVI, mas também há índices com bons resultados como o uso *Normalized Difference Water Index* - NDWI (GAO, 1996).

Bolfe, Batistella e Ferreira (2012) trabalhando com estudo de estoque de carbono em sistemas agroflorestais na região do Pará encontraram diferenças significativas para índices de vegetação NDVI (máx $R^2 = 0,73$) e SAVI (máx $R^2 = 0,58$) relacionados ao incremento de carbono em biomassa aérea calculados com o uso de imagens de satélites Landsat. Em plantios de laranjeiras no estado de São Paulo, o uso de imagens aéreas serviram para mapear a produtividade de

laranjeiras em dois anos de avaliação distintos, através de índices NDVI e SAVI, com imagens de alta resolução (PARISE; VETTORAZZI, 2005). Há também trabalhos que relatam o sucesso do uso de imagens hiperespectrais na avaliação de estágios fenológicos e caracterização da vegetação florestal (SOUZA; VICENS; CRUZ, 2013).

Alguns tipos de sensores possuem maior capacidade de resolução espacial e temporal dentre os sensores disponíveis. A série de imagens fornecida pela constelação de microssatélites RapidEye (conjunto de 5 satélites que orbitam a Terra) possuem uma resolução espacial de 5 m e resolução temporal de 24 horas, ou seja, o tempo de revisita a um determinado local, por um de seus sensores é de no máximo 1 dia (BLACKBRIDGE, 2016). O produto é a composição de bandas multiespectrais na região do visível e infravermelho. Em estudo realizado com a comparação entre os dados gerados entre as 5 plataformas encontrou uma diferença relativa de apenas 3% entre as imagens (ANDERSON; THIELE; BRUNN, 2013). No presente estudo, os índices de vegetação serão relacionados com a variável idade das florestas com finalidade de categorizar os plantios homogêneos em duas categorias distintas.

2.3. Tecnologia Airborne Laser Scanning (ALS)

O laser aeroembarcado é um exemplo de tecnologia que tem auxiliado pesquisadores a estimar parâmetros florestais com bastante precisão em países europeus, principalmente da península Escandinava (NÆSSET *et al.*, 2004). A tecnologia laser teve início em trabalhos realizados com o objetivo de medir alturas das copas das árvores e se estenderam para medidas de métricas que associassem ao volume de madeira produzida pela floresta. Mais conhecida como tecnologia LiDAR (*Ligth Detection and Ranging*), o escaneamento a laser é frequentemente relacionado a estudos de caracterização de biometrias de florestas nativas em países do hemisfério norte, como Canadá, Noruega e Suécia (FERRAZ *et al.*, 2012; MAGNUSSEN; WULDER, 2012; NELSON *et al.*, 2012; WULDER *et al.*, 2012). Estudos avaliam o potencial uso dos dados do LiDAR embarcado em aeronaves como potencial ferramenta para tomar medidas de árvores em grandes extensões de florestas, como, por exemplo, quantificar biomassa (NELSON *et al.*, 2012) e mapear a estrutura da floresta em três dimensões através de mapeamento de

multicamadas (FERRAZ et al., 2012). Magnussen e Wulder (2012) avaliaram uma floresta canadense que não havia sido manejada e onde ocorreu historicamente 163 focos de incêndio, trouxe avanço para o conhecimento da dinâmica de florestas e taxas de recuperação em locais remotos, onde o acesso é difícil.

Zonete (2009) usou em seu trabalho métricas de dados ALS para estimar alturas de diâmetro médio, altura média, altura dominante e volume da parcela. Encontrou as melhores estimativas para o modelo que considerou variáveis como idade, percentil 30 da altura e a densidade de pontos no percentil 90 ($R^2 = 0,94$ a $0,95$ e $RMSE = 0,002$ a $0,003$). A predição de biomassa também é alvo de estudos com a utilização de variáveis de aerolevantamento, associados com a quantificação volumétrica no plantio.

Já Lindberg *et al.* (2012) afirma que erros podem ocorrer devido limitação dos modelos por conta das amostragens, em áreas onde a estrutura do dossel é desuniforme podem gerar superestimação da altura. Nem todas as informações poderão ser obtidas de uma floresta com bastante precisão utilizando um modelo de caracterização da estrutura vertical da floresta baseado apenas em amostras (WULDER et al., 2012). Para algumas aplicações serão necessárias a utilização de informações mais detalhadas. Nos locais onde a utilização de dados de estrutura vertical e características do subdossel da floresta se fazem necessárias e tratam-se de áreas extensas, a possibilidade de usar a tecnologia LiDAR pode ser onerosa demais. Então, alguns estudos sugerem a utilização de imagens de satélite com resolução espacial adequada para realizar a quantificação da biomassa e caracterização do plantio florestal com amostras LiDAR fornecendo a calibração e validação dos dados do modelo (GONZALEZ et al., 2010; HUDAK et al., 2002; WULDER et al., 2012).

Hudak *et al.* (2002) desenvolveram um trabalho com o uso de imagens de satélite e dados LiDAR para estabelecer uma ampla cobertura de atributos estruturais da floresta. Utilizando técnicas geoestatísticas para predição volumétrica com auxílio de banda pancromática de imagem de satélite obteve maior precisão que o uso apenas da krigagem ordinária. A estratégia de modelagem integrando imagens de sensores remotos calibradas com ALS são mais adequados para estimar volumes em locais onde não existem dados LiDAR mas possuem imagens de satélite. Lu *et al.* (2012) afirma que a adequação de imagens de satélites podem

estimar dados de biomassa adequados para florestas de sucessão secundária, mas terá problemas associados com saturação se utilizados em florestas maduras.

O ALS tem a capacidade de potencializar a estimativa de biomassa das imagens de satélite, no entanto, a maior parte das limitações é com a disponibilidade de dados LiDAR (LU et al., 2012).

Figura 1. Fluxo de trabalho com as diversas fontes de informações para o procedimento Abordagem Baseada por Área – ABA. Adaptado de (WHITE et al., 2013).

Em estudos com imagens do sensor RapidEye para mapeamento e monitoramento agrícola e ambiental se mostraram bastante promissoras para esta aplicação, gerando imagens compatíveis com a classe A na escala 1/20.000 e resolução espacial capaz de ser utilizada com adequada precisão em mapeamento de áreas agro-silvi-pastoris (ANTUNES; SIQUEIRA, 2013).

Um trabalho de escaneamento à laser aéreo foi realizado em florestas na região norte do Canadá gerando nuvens de dados LiDAR (cobertura de 0,27% da área total) conjunta com imagens de satélite (cobertura de 100% da área total) em abordagem de amostragem em duas fases e geraram mapas de predição de altura com erro médio de 3,5 m para a maior parte de áreas de florestas (81% de 2,16 milhões de ha) (CHEN et al., 2012). O LiDAR tem potencial de validar e calibrar

atributos florestais obtidos de imagens óticas (CHEN et al., 2012). Seria possível combinar as ferramentas e ampliar as estimativas para regiões maiores?

A integração das duas ferramentas através do método de modelagem em duas etapas pode proporcionar bons resultados preditivos. A hipótese é que áreas de plantios homogêneos podem ser diferenciadas em categorias de idade jovem e madura para uma escala regional. Com a finalidade de testar a hipótese, o presente estudo utiliza fazendas localizadas no Vale do Paraíba, Estado de São Paulo, identificadas pelo Instituto Florestal de SP como plantios homogêneos de eucaliptos.

3. MATERIAL E MÉTODOS

3.1. Área de estudo

Sete fazendas de propriedade de uma companhia florestal cultivadas em regime de manejo de alto fuste foram selecionadas na região do Vale do Paraíba, estado de São Paulo, especificamente nos municípios Jacareí, Jambuí, Natividade da Serra, São Luis do Paraitinga e Paraibuna, cujas coordenadas geográficas estão entre S 19° 46' 49.61" e S 25° 18' 30.05" de latitude e entre O 44° 9' 48.23" e O 55° 6' 17.54", no *datum* SIRGAS 2000 (Figura 2). Nesta região predomina a classificação climática de Köppen Cfa, subtropical sem estação seca e com verão quente, em altitudes entre 628 e 882 m acima do nível do mar, média pluviométrica anual de 1396 mm, com média do mês mais chuvoso em janeiro de 236 mm e mais seco em julho, com média de 27 mm na série histórica de dados (ALVARES et al., 2013). A média anual de temperatura é 19,3 °C, com média do mês mais quente atribuídas a janeiro e fevereiro, ambos com média de 22,3 °C, e média do mês mais frio de 15,5°C em julho (ALVARES et al., 2013).

Figura 2. Localização das cidades no Vale do Paraíba dentro do estado de São Paulo.

As localizações das parcelas sobrepostas às imagens de satélites da região mostram uma concentração de florestas plantadas na região do Vale do Paraíba, permite notar também um padrão de maciços maiores de plantios pulverizados por pequenas plantações em sua proximidade (Figura 3). Essa região é uma das áreas que concentram plantios homogêneos de espécies florestais no estado de São

Paulo, como mostra levantamento do Instituto Florestal, Secretaria do Meio Ambiente, motivo pelo qual foram selecionadas para este estudo (Figura 4).

Figura 3. Parcelas de campo localizadas dentro das imagens de satélite.

Figura 4. Representação da cobertura de áreas reflorestadas do Estado de São Paulo. Fonte: (INSTITUTO FLORESTAL - SECRETARIA DO MEIO AMBIENTE DO ESTADO DE SÃO PAULO, 2013).

3.2. Coleta de dados de campo

As informações das áreas, suas localizações, divisões por glebas e inventários foram obtidas das observações de campo, levantadas pela equipe de inventário florestal da empresa. As informações das idades dos talhões são obtidas do cadastro florestal, e informações da distribuição do plantio são produtos do geoprocessamento. Uma rápida verificação das informações foi realizada no software ArcGIS® (versão 10.3) para constatar eventuais inconsistências ou ausência de dados. As sete fazendas possuem dados de sobrevoo com escaneamento a laser aeroembarcado (ALS) em mesmo ano que foi realizada o levantamento dos dados de campo e capturada as imagens de satélites. O sobrevoo cobriu em toda a extensão a área reflorestada das sete fazendas em uma única campanha.

As parcelas amostrais de campo foram instaladas em plantios homogêneos do gênero *Eucalytus* spp., em espaçamento de 3,0 x 2,0 m e densidade média de 1667 plantas por hectare. Foram instaladas 123 parcelas de 400 m², georreferenciadas com um aparelho receptor GNSS, em uma área total de 581,82 hectares. A densidade amostral é de 1 parcela a cada 4,73 ha, em amostragem estratificada e parcelas aleatorizadas dentro de cada estrato, que garante menor erro dentre outros métodos amostrais (CAMPOS; LEITE, 2013).

Nas parcelas as informações levantadas foram:

- Localização central (coordenada X e Y) da parcela circular;
- Número de identificação da parcela;
- Número da árvore;
- Diâmetro à altura do peito (DAP) em centímetros (medida a 1,3 m do solo);
- Altura total (H) em metros de 15 árvores da parcela;
- Altura total (H_d) em metros de 5 árvores dominantes da parcela;
- Dados qualitativos.

As informações coletadas em campo foram tabuladas em planilhas eletrônicas e calculadas as estimativas de área basal, alturas e os volumes de árvores. Os volumes foram preditos através do uso de modelos alométricos ajustados para diferentes condições dos plantios, como materiais genéticos

cultivado, espaçamento do plantio, unidades de manejo de solo e região onde se encontram.

Tabela 1. Resumo das informações das fazendas.

Gleba	Fazenda	Área (ha)	Idade	Município	Mater. Genético
F184	Santa Cecília	58,33	87	São Luiz Paraitinga	VR3709H
F634	Patizal do Vale Feliz	84,80	113 a 145	Paraibuna	P4295H e TC31H
F849	São Jose III	138,96	72	São Luiz Paraitinga	VR3709H
F948	Jataí	79,33	98	Paraibuna	VR3709H
F950	Urutay	86,71	82	Paraibuna	C219H
F986	Santa Terezinha V	94,16	59	Jacareí	P4294H
F987	Santa Terezinha VI	39,53	32 a 43	Jacareí	C219H e P4295H

Fazenda = Nome da fazenda; Mater. Genético = Híbrido clonal plantado por projeto;

3.1. Imagens de satélite

As imagens da constelação de microssatélites RapidEye foram obtidas através do convênio da empresa fornecedora das imagens, a Planet[®], e o Ministério do Meio Ambiente (MMA), disponíveis na base de dados GeoCatálogo (IBAMA, 2015). O sensor de varredura eletrônica multiespectral REIS (*RapidEye Earth Imaging System*) capta informações com resolução espacial de 5 m e temporal de 24 horas (PLANET LABS INC., 2016) em cinco bandas espectrais diferentes (tabela 3). As imagens utilizadas foram imagens com ausência de nuvens, claras e que recobrem toda a área de plantio. As capturas das imagens foram contemporâneas aos dados de campo e aos sobrevoos com o avião coletor de dados ALS (tabela 2). Informações espacialmente distantes podem não ser representativas da realidade encontrada em campo e comprometerem o ajuste dos modelos ao final da pesquisa (MITCHELL et al., 2015).

Tabela 2. Datas de coleta dos dados.

2012												
Mês	jan.	fev.	mar.	abr.	maio	jun.	jul.	ago.	set.	out.	nov.	dez.
Parcelas												
RapidEye												
LiDAR (ALS)												

ALS = *Airborne Laser Scanning*.

A seguir, um resumo das características dos satélites RapidEye (tabela 3) disponível no site da empresa proprietária do satélite.

Tabela 3. Características do satélite *RapidEye*, com o sensor REIS. **Fonte:** (PLANET LABS INC., 2016).

Características Gerais	Informações		
Número de Satélites	5		
Tempo de vida	Acima de 7 anos		
Altitude de órbita	630 km de altura em órbita síncrona ao Sol		
Horário que cruza o equador	11:00 da hora local (aproximadamente)		
Tipo do sensor	Multiespectral de varredura eletrônica		
Tamanho do pixel ortorretificado	5 m		
Faixa de varredura	77 km		
Tempo de revisita	Diariamente (fora do nadir) / 5,5 dias (no nadir)		
Resolução radiométrica	12 bits		
Bandas Espectrais	Banda	Nome da banda	Resolução espectral (nm)
	1	Azul	440 – 510
	2	Verde	520 – 590
	3	Vermelho	630 – 680
	4	Borda do vermelho	690 – 730
	5	Infra-vermelho próximo	760 – 850

As coordenadas das imagens utilizadas, a data de quando foram obtidas e os quadrantes (*tileID*) referentes estão presentes na tabela 4.

Tabela 4. Coordenadas das imagens RapiEye.

Imagem	Data	TileID:	Coordenadas - UTM			
			Superior Esquerdo		Inferior Direito	
			Longitude	Latitude	Longitude	Latitude
1	05/12/2012	2328310	379499,986	7432499,985	404499,682	7407500,181
2	03/07/2012	2328311	403500,014	7432499,995	428499,989	7407500,040
3	20/08/2012	2328312	427499,969	7432500,030	452499,951	7407500,079
4	20/08/2012	2328313	451500,164	7432499,894	476499,856	7407500,041

Figura 5. Fazendas Jataí e São José III, respectivamente, com delimitações dos seus plantios e localização das parcelas de campo.

Figura 6. Fazendas Santa Cecília e Patizal do Vale Feliz, respectivamente, com delimitações dos seus plantios e localização das parcelas de campo.

Figura 7. Fazendas Santa Terezinha V e Santa Terezinha VI, respectivamente, com delimitações dos seus plantios e localização das parcelas de campo.

Figura 8. Fazenda Urutay com delimitações dos seus plantios e localização das parcelas de campo.

3.2. Dados de aerolevanteamento a laser

Os sobrevoos que fizeram o escaneamento sobre sete fazendas localizadas no Vale do Paraíba, foram realizados em dezembro do ano de 2012 com uma aeronave do modelo Piper Seneca II embarcada com o sistema ALS Riegl LMS – Q680I embarcado (Figura 9), seguindo configurações e características de voo como as descritas na tabela 5.

Tabela 5. Descrição das características contratadas para o voo de aerolevanteamento a laser sobre a região do Vale do Paraíba.

Características	Unidade	Descrição dos parâmetros
Densidade de pontos	retornos/m ²	10
Diâmetro do pulso no alvo	cm	15 a 30
Altura de voo	m	422,94
Velocidade de voo	km/h	200
Ângulo de escaneamento	graus	45
Largura da faixa de varredura	m	350 m
Frequência de emissão do pulso a laser	kHz	400
IMU / GPS	equipamento	Applanix 510
Precisão da IMU	cm	10 – 15
Datum horizontal	-	SIRGAS 2000
Datum vertical	-	Marégrafo de Imbituba-SC

Previamente foram estabelecidos os parâmetros do sobrevoo desejados para a empresa contratada. A equipe, composta por um piloto e um operador do equipamento de varredura, insere no *Software Tracker32* (V.3.0.3 c) todas as informações que orientarão as faixas sobrevoadas e segue os indicativos do software para orientar o prosseguimento com as instruções iniciais.

Os dados ALS passam por uma etapa de pré-processamento por parte da empresa contratada por fornecer os dados brutos, procurar por irregularidades ou ausência de pontos, chamados de “vazios” ou “buracos”, na nuvem ALS. Ainda nesta etapa, dados que são considerados “outliers” ou não representem informações do plantio são considerados como ruídos, e também são retiradas nessa etapa de pré-processamento. As nuvens contendo pontos corrigidos e informações relativas às áreas de plantio, a empresa entrega um Modelo Digital de Terreno e um Modelo Digital de Superfície, descritos na próxima etapa, como um produto final do serviço.

Figura 9. A primeira à esquerda é a foto do sensor LiDAR RIEGL, ao seu lado *hard disks* (HDs) que armazenam os dados durante o voo e servem como backup das informações; a escotilha aberta, por onde é emitido o pulso laser e, em seguida, o monitor com as informações de saída, utilizados pelo operador. **Fonte:** foto do equipamento selecionado do site da empresa (RIEGL LASER MEASUREMENT SYSTEMS, 2017) e demais fotos pertencentes ao próprio autor.

3.3. Processamento dos dados

3.3.1. Processamento do aerolevantamento a laser

O processamento dos dados do aerolevantamento ALS foram feitos através da ferramenta *Lastools* v160429 (ISENBURG, 2016), do pré-processamento até a extração das métricas dos reflorestamentos. O processamento dos dados foi realizado no Centro de Métodos Quantitativos, LCF, Esalq.

A nuvem de pontos foi recortada em quadrantes de 500 x 500 m permitindo ao programa que realize o processamento com uma fração da nuvem de pontos por vez. Nesta fase um *buffer* de 25 metros foi gerado em cada quadrante para evitar erros em cálculos realizados nas bordas dos fragmentos.

Em cada nuvem de pontos gerada foi realizada uma busca visual por retornos LiDAR isolados, abaixo da linha do terreno ou que extrapole os limites do quadrante onde foi coletado. Os retornos ALS com elevação acima da altura máxima registrada para um plantio de eucalipto foram eliminados, assim como também foi retirado de todos os pontos a classificação atribuída pela prestadora de serviço.

A nova classificação dos retornos foi realizada através do algoritmo modificado de Axelsson (AXELSSON, 2000), onde uma rede de triângulos conectados une os pontos mais baixos aleatoriamente, e novos pontos são acrescentados somente quando atenderem determinados parâmetros derivados dos dados. A classificação dos pontos de solo gera um grupo de pontos da nuvem distinto dos demais que não possuem uma classificação, passo prévio ao de criação de um Modelo Digital de Terreno. Os valores de altura atribuídos aos retornos foram recalculados, representados em relação à distância entre o ponto e o terreno, ou

seja, foram computados a altura a partir dos pontos agora classificados como sendo “ground”.

A classificação dos pontos de vegetação foi realizada excluindo os pontos pertencentes à categoria terreno e os pontos que não pertencem à categoria dos “outliers”. A janela utilizada para classificação em categorias de vegetação foi de 2 metros, ou seja, o algoritmo procura por retornos que não representem vegetação, como uma de casa, prédio ou outro tipo de artefato que não seja uma formação natural e, então, diferencia do que é classificado como vegetação. A distinção entre categorias de vegetação e elementos estruturais deve necessariamente ser realizada depois de concluída a classificação dos pontos de terreno.

A normalização da nuvem é parte importante, onde a unidade de medida de *z* (altura) de cada ponto, que inicialmente representa a altitude do retorno relativo ao nível do mar (inicialmente anotado como altitude em relação ao Marégrafo de Imbituba-SC) e passa a representar a altura do ponto em relação ao terreno. Nesse procedimento são retirados os pontos cujos valores são negativos e estão localizados abaixo do solo, assim como os pontos superiores à altura do dossel e que não representam a vegetação. Esse processo é importante para retirar pontos que não são considerados florestas ou árvores dos Modelos Digitais de Terreno e de Superfície. A importância de se identificar e retirar da cena de estudo os *outliers* é porque sua influência sobre a maioria dos procedimentos de análise de dados padrão é prejudicial (PEARSON, 2002).

A exploração das métricas geradas com os dados ALS podem ser compreendidas pela descrição de forma sucinta de como algumas delas são calculadas pelo programa. Os cálculos são executados com a ferramenta *Lascalopy* e exportadas em formato de planilha digital .csv (MCGAUGHEY, 2015).

Em sua maioria as medidas de percentis de altura são bastante exploradas e mantém uma relação maior com as medidas dos plantios de campo. As principais métricas de altura são as alturas máximas, mínimas, média e os percentis. Dentre os percentis, os que relacionam as alturas dos percentis superiores em uma representação da região da copa e parte superior do dossel da floresta são de 90, 95 e 99.

Tabela 6. Métricas LiDAR que são geradas através do *Lascanopy* (LASTools®) e serão utilizadas nesse projeto.
Fonte: Silva (2013) e Shinzato (2015).

Categoria	Métricas LASER do aerolevanteamento	Símbolo
	Altura máxima dos pontos em um voxel	H_{max}
	Altura mínima dos pontos em um voxel	H_{min}
	Altura média dos pontos em um voxel	H_{med}
	Desvio Padrão da altura em um voxel	H_{desv}
	Percentil 50 da altura	H_{p50}
	Percentil 75 da altura	H_{p75}
	Percentil 90 da altura	H_{p90}
	Percentil 95 da altura	H_{p95}
	Percentil 99 da altura	H_{p99}
	Distância entre percentis 90 e 10 *	H_{p9010}
	Distância proporcional entre percentil 90 e 10 *	H_{p9010r}
Cobertura	Proporção entre os primeiros retornos acima da altura de corte / primeiros retornos	Cov
	Percentual de cobertura da copa	Dns

* Medidas criadas pelo autor

Os percentis são medidas de posição representada pela altura em metros onde a percentagem de pontos que estão abaixo desse valor correspondem ao respectivo valor do percentil. O percentil 90 da altura, por exemplo, seria a altura em metros em que 90 % dos pontos daquele quadrante da nuvem de pontos se encontram abaixo desta altura.

Outras medidas que são utilizadas nesse trabalho podem ser vistas através das fórmulas demonstradas a seguir.

Médias

Média de altura (H_{med}):

$$H_{med} = \frac{1}{n} * \sum_{i=1}^n H_i \quad (1)$$

Onde: n = número de observações na nuvem de pontos; H_i = altura no ponto i .

Desvios

Desvio de altura (H_{desv}):

$$H_{desv} = \sqrt{\frac{1}{n-1} * \sum_{i=1}^n (H_i - H_{med})^2} \quad (2)$$

Onde: n = número de observações na nuvem de pontos; H_i = altura no ponto i ; H_{med} = Altura média dos números de observações.

Variância

Variância de altura (H_{var}):

$$H_{var} = \frac{1}{n-1} * \sum_{i=1}^n (h_i - h_{med})^2 \quad (3)$$

Onde: n = número de observações na nuvem de pontos; h_i = Intensidade no ponto i .

Percentual da cobertura de copa

$$C\% = x_{>2m} / x_{all} \quad (4)$$

Onde: $x_{>2m}$ = quantidade de pontos acima de 2 m da superfície do terreno; x_{all} = quantidade de pontos totais.

Algumas métricas adicionais foram criadas exclusivamente para serem usadas nesse trabalho para diferenciar plantios homogêneos em categorias de idade. A métrica H_{p9010} representa a diferença de altura entre o percentil 90 e percentil 10, de forma absoluta em metros, busca uma relação entre a distribuição do topo da copa da árvore e a parte basal da mesma. A métrica H_{p9010r} representa a mesma diferença medida na H_{p9010} , representada proporcionalmente à altura medida no H_{p90} .

Figura 10. Métrica criada com base nas observações das nuvens de pontos ALS.

3.3.2. Produtos das nuvens de pontos

Como produtos do processamento digital de dados LiDAR podemos apontar os modelos digitais da representação tridimensional das nuvens de pontos. Dentre os modelos encontram-se os Modelos Digitais de Terreno (MDT), Modelos Digitais de Superfície (MDS) e Modelos Digitais de Altura (MDA). Os Modelos Digitais de Terrenos são representações da superfície da Terra sem quaisquer objetos ou elementos que a recobrem. Os Modelos Digitais de Superfície representam a superfície coberta da Terra, com todas as feições e elementos que estão sobre ela dispostos. Já os Modelos Digitais de Altura, cuja representação é sobre a diferença entre os modelos digitais de Superfície e os Modelos Digitais de Terreno, representam os elementos que estão sobre o solo na superfície da Terra nas regiões sobrevoadas com escaneamento aéreo (MALTAMO; NAESSET; VAUKONEN, 2014).

3.3.3. Modelo Digital de Terreno (MDT)

Os modelos digitais de terreno foram gerados através da triangulação dos pontos classificados como solo (*class* = 2) em um TIN temporário, e do raster do TIN é criado um Modelo Digital de Terreno. O *step size* (passo padrão de processamento) utilizado foi de 1 metro, janela de processamento inferior aos 5 metros recomendado em áreas em que a cobertura florestal é predominante (ISENBURG, 2016).

3.3.4. Modelo Digital de Superfície (MDS)

Os modelos digitais de superfície foram gerados através da triangulação dos pontos classificados como primeiros retornos (*first returns*), excluindo os classificados como ruído (*class* = 7) e um passo padrão de processamento de 1 metro, com a configuração “*extra_pass*”, recomendado nesta etapa do processamento (ISENBURG, 2016). Tanto os modelos digitais de superfície quanto os modelos digitais de terreno não são gerados com as nuvens normalizadas, apenas com as nuvens limpas de pontos que não representam elementos naturais da paisagem.

3.3.5. Modelos de Altura do Dossel (CHM)

A diferença entre os modelos digitais de superfície e os modelos digitais de terreno possibilitam a geração dos modelos de altura do dossel (CHM – Canopy Height Model). As fisionomias florestais nativas e os plantios homogêneos de rápido crescimento podem ser diferenciados através do uso deste produto (GÖRGENS et al., 2016), inclusive visualmente é possível notar as diferentes feições, mas sua principal utilidade é gerar métricas da nuvem de pontos para toda a extensão do plantio florestal (HUDAK et al., 2002b; MUSTONEN; PACKALEN; KANGAS, 2008; PITKÄNEN; MALTAMO, 2004). O uso de modelos digitais de elevação (MDEs) podem ser para caracterização de riqueza em povoamentos florestais (LOPATIN et al., 2016) ou em interação com imagens de satélites (MITCHELL et al., 2015) atuar para melhorar as estimativas de parâmetros do povoamento florestal.

3.3.6. Métricas das nuvens de pontos

Após o processamento de dados, as métricas das nuvens de pontos que foram obtidas foram comparadas quanto à sua relação com a variável de interesse no plantio florestal. Uma matriz de correlação, conhecido também como coeficiente de correlação produto-momento de Pearson (r) realizada entre as variáveis dependentes para encontrar quais das variáveis apresentam relação com a idade do plantio e potencialmente integrar um modelo de regressão como variável independente. Todas as variáveis selecionadas como *input* da matriz de correlação de Pearson foram originadas da saída do software LASTools[®].

3.3.7. Processamento dos dados de satélites

Alguns autores apontam o uso das imagens RapidEye como adequadas para estudos de vegetação e classificação de uso da terra, por ter razoável resolução e pelo tempo de revisita diário (ANTUNES; SIQUEIRA, 2013; CONRAD et al., 2014; USTUNER; SANLI; DIXON, 2015). Por se tratar de uma imagem com maior resolução e possuir uma frequência maior de recobrimento da superfície terrestre ela tem um custo maior de ser gerado.

Tabela 7. Índices de vegetação originados que podem ser obtidos com bandas presente nas imagens da série de imagens RapidEye.

Índices	Sigla	Fórmula de cálculo (R=reflectância)	Referência
Índice de vegetação por diferença normalizada	NDVI	$(R_{NIR} - R_{Red}) / (R_{NIR} + R_{Red})$	Rouse <i>et al.</i> , (1973)
Índice de vegetação por diferença normalizada da banda verde	GNDVI	$(R_{NIR} - R_{Green}) / (R_{NIR} + R_{Green})$	Gitelson & Merzlyak, (1996)
Índice de vegetação por diferença normalizada da borda do infravermelho	NDVI ₇₀₅	$(R_{750} - R_{705}) / (R_{750} + R_{705})$	Gitelson & Merzlyak, (1994)
Índice de relação entre vermelho e verde	Red-Green	R_{Red} / R_{Green}	Gamon & Surfus, (1999)
Índice de razão simples	SRI	R_{NIR} / R_{Red}	Tucker, (1979)
Índice de vegetação ajustado ao solo	SAVI	$(1+0,5) * (R_{NIR} - R_{Red}) / (R_{NIR} + R_{Red} + 0,5)$	Huete, (1988)

Fonte: Editado pelo autor.

Figura 11. Processamento digital de imagens em Sensoriamento Remoto. **Fonte:** Próprio autor.

As imagens de satélites foram selecionadas para a área de abrangência das fazendas selecionadas para o estudo. Ao todo foram selecionadas 4 imagens que recobrem todas as fazendas. A imagem é entregue em um único arquivo raster contendo 5 bandas, ortorretificadas e corrigidas geométrica e radiometricamente. As

correções para as distorções de radiância motivadas por colunas de vapor de água e efeito da dispersão atmosférica precisam ser realizadas por software de análise e processamento de imagens geoespaciais, como o *ENVI*® 5.3.

No ambiente do software de processamento de imagens os arquivos foram importados e convertidos para o formato *Band Interleaved by Line* (.bil) e o tratamento realizado igualmente para todas as bandas. O formato BIL permite que exista um ajuste entre o processamento espacial e espectral das imagens, sendo este um dos formatos mais utilizados para os trabalhos de imagens dentro do processamento digital (INCORPORATED RESEARCH SYSTEMS, 2004).

Para o tratamento das imagens foi usado o algoritmo de Análise Atmosférica Rápida de Hipercubos Espectrais (FLAASH, em inglês), um algoritmo de correções atmosféricas baseado no modelo de transferência MODTRAN4 (PERKINS et al., 2005). Concebido para análise espectral e métodos de recuperação atmosférica, ele leva em consideração a profundidade ótica do aerossol para gerar uma estimativa da dispersão e compensar seus efeitos adjacentes e também a suavização da estrutura espectral proveniente de imperfeições geradas em correções atmosféricas (MILLER; LEWIS, 2002; PERKINS et al., 2005). Para melhorar ainda mais o processo de correção atmosférica, o FLAASH detecta artefatos introduzidos pelo sensor e faz sua correção dentro das imagens (Figura 11).

A saída do programa processador de imagens espectrais é em formato de arquivos raster, um para cada banda para cada imagem. Estes são abertos em programas de Sistema de Informações Geográficas (SIG) para unir as bandas em um único arquivo e fazer o recorte da imagem representativa das fazendas. A transformação da projeção é realizada para transformar as coordenadas originais com valores no *datum* WGS84 para coordenadas correspondente no *datum* SIRGAS 2000, correspondente aos arquivos de mapa das fazendas e da nuvem de pontos provenientes do equipamento LiDAR. A transformação foi realizada no software ArcGIS® versão 10.3 (ESRI, 2011) e os rasters cortados no tamanho das fazendas e então calculados os índices de vegetação.

O cálculo do NDVI (Eq. 13) é bastante utilizado por apresentar bons resultados de correlação com valores de reflectância em vegetação, e um dos índices de vegetação mais utilizados para esta finalidade (BOLFE; BATISTELLA; FERREIRA, 2012; RAMOS et al., 2010). Também será utilizado o índice descrito pela equação 14, que é o cálculo do EVI.

$$NDVI = \frac{(NIR-RED)}{(NIR+RED)} \quad (5)$$

Onde: NDVI = *Normalized Difference vegetation index*, NIR = *Near infra-red* (760 µm - 900 µm), RED (630 µm – 690 µm)

$$EVI = G \times \frac{(NIR-RED)}{(NIR+C1 \times RED-C2 \times BLUE+L)} \quad (6)$$

Onde: EVI = *Enhanced Vegetation Index*, NIR = *Near infra-red* (760 µm - 900 µm), RED = (630 µm – 690 µm), BLUE = (450 µm – 515 µm), G (gain factor), L, C1, e C2 são coeficientes do modelo.

Todos os índices de vegetação utilizados nesse trabalho estão descritos em fórmulas na tabela 7, onde é possível notar as referências aos trabalhos de onde são citados os respectivos modelos. Os índices de vegetação são calculados para cada um dos píxeis do raster e eles serão valores que entrarão nos modelos de predição da idade do plantio como variáveis independentes. Os resultados serão utilizados na elaboração de modelos de regressão e a variável resposta será comparada com os valores observados do plantio florestal, comparados com o uso de ferramentas de análise estatística e interpretação das representações gráficas através de mapas preditivos de idade. O melhor modelo será o que apresenta melhores desempenhos nesses dois aspectos, estatísticos e representação gráfica.

A utilização do coeficiente de determinação (R^2) e a raiz do erro médio quadrático (RMSE) servirão como indicativo das melhores equações preditoras associadas à variável resposta. Os modelos serão ajustados com informações de índices de vegetação da metade das fazendas estudadas, ficando a outra metade como informações para avaliação do desempenho do modelo gerado.

Coeficiente de determinação (R^2)

$$R^2 = \frac{SQR}{SQT} = 1 - \frac{SQE}{SQT} = \frac{\beta_1 \sum_{i=1}^n (x_i - \bar{x}) Y_i}{\sum_{i=1}^n (Y_i - \bar{Y})^2} \quad (7)$$

Onde: R^2 = coeficiente de determinação do modelo; SQR = Soma dos quadrados da regressão; SQT = Soma dos quadrados totais; SQE = Soma dos quadrados dos erros; o resíduo; β_1 = coeficiente de ajuste do modelo.

RMSE

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (x_i - \hat{x}_i)^2}{n}} \quad (8)$$

Onde: $RMSE$ = Raíz do erro quadrático médio; n = número total de observações; x_i = i_{esimo} valor predito através do modelo; $\hat{x}_i = i_{esimo}$ valor observado.

rRMSE

$$rRMSE = \frac{RMSE}{\bar{y}} * 100 \quad (L) \quad (9)$$

Onde: $rRMSE$ = Raíz relativa do erro quadrático médio; $RMSE$ = raíz do erro quadrático médio; $\bar{y}$ = média dos valores observados.

Crítério de Akaike

$$AIC = 2k - 2 \ln(L) \quad (10)$$

Onde: AIC = critério de informação de Akaike; k = número de parâmetros do modelo; L = valor maximizado da função de verossimilhança do modelo ajustado.

3.4. Mapa final dos povoamentos

Os resultados da divisão da floresta em duas distintas categorias de idade (jovem ou madura) serão plotados em um mapa contendo as áreas do plantio utilizadas no estudo comparando a resposta do modelo ajustado final com as parcelas de campo, sem a utilização do de informações ALS, para avaliar se os ajustes feitos através da dupla amostragem estão sendo eficazes em representar a realidade existente em campo, ou se de alguma forma existe um viés de resposta do modelo. Investigando estas interações entre as parcelas amostrais de campo, as parcelas amostrais LiDAR e o modelo utilizando variáveis de índices de vegetação calibrados com parcelas amostrais de LiDAR terão potencial para reproduzir informações em áreas avaliadas sem o uso do equipamento LiDAR para quantificar as florestas com bastante precisão e condizentes com a verdade de campo.

4. RESULTADOS

De forma objetiva e sintética serão apresentados os resultados do processamento dos dados LiDAR para as sete fazendas objeto do estudo assim como os resultados provenientes das análises de imagens de satélite, com os cálculos dos índices de vegetação e resultados separados por fazenda. Ao final, serão apresentados os modelos mais bem ajustados e que apresentaram melhor desempenho na diferenciação das fazendas em áreas de florestas jovens e maduras.

4.1. Processamento das nuvens de pontos

A densidade média e o espaçamento médio dos pontos distribuídos por fazenda podem ser observados na tabela 8.

Tabela 8. Relatório descritivo de dados ALS de sobrevoo realizado nas fazendas no Vale do Paraíba.

Fazenda	Número de retornos	Primeiros retornos	Densidade (nº. m ⁻²)	Espaçamento médio (m)
F986	11431132	7832752	11,76	0,29
F950	8596247	6452921	9,59	0,32
F987	6186112	4322793	15,56	0,25
F184	8168099	6110326	13,52	0,27
F849	19030537	14628914	13,26	0,27
F948	11032500	7684154	13,34	0,27
F634	8644251	6204037	9,81	0,32

A densidade de pontos supera as especificadas na contratação do sobrevoo em algumas fazendas e em outras está próxima do contratado. A menor densidade encontrada foi na fazenda Urutay, com valores médios de 9,59 pontos . m⁻² e o maior valor para a fazenda Santa Terezinha VI, com valores de pontos de 15,56 pontos . m⁻². A diferença em valor relativo é grande entre as fazendas que possuem nuvens de pontos mais e menos densas, tendo a Santa Terezinha VI 62% a mais de pontos . m⁻² que a fazenda Urutay. Sobre o espaçamento médio dos pontos dentro da nuvem de pontos é importante destacar que a maior distância média encontrada para as nuvens de pontos é de 0,32 m, ou seja, indica que em uma nuvem tratada

em um grid de células de tamanho quadrado de 1 m de aresta, seriam encontrados ao menos 3 pontos representativos da nuvem de pontos.

Figura 12. Mapa de distribuição dos pontos visto na ferramenta *Lasview* do software *LASTools* para as nuvens de pontos não-normalizadas classificadas por altura dos pontos

4.2. Produtos do processamento da nuvem de pontos

É visível através das imagens do modelo digital de terreno que a região do plantio está em um relevo acidentado e que variam bastante de altitude entre elas (Figura 13, de A a F). A elevação da nuvem de pontos em escala de cinza explicita que as fazendas são compostas por terrenos contínuos de plantios com pouca presença ou ausência de terrenos planos, relevo característico por presença de morros com declividade que podem variar de 20-30%, característico da região do Médio Vale do Paraíba (ROSS; MOROZ, 2011). Os modelos de altura da copa podem ser observados nas Figuras 14.A a 14.F, destacando os plantios florestais pertencentes às fazendas objeto do estudo dos demais itens da paisagem.

4.3. Métricas das nuvens de pontos

As variáveis apresentam alguma relação positiva ou negativa com a variável idade (tabela 9). As maiores relações observadas foram das medidas que apontam para altura dos pontos em relação ao solo da fazenda. As variáveis $H_{máx}$, H_{p75} , H_{p90} , H_{p95} e H_{p99} obtiveram valores de 0,89. As variáveis H_{p50} e H_{med} ficaram próximas, com valores de 0,87 e 0,83, respectivamente. As variáveis Cov e Dns mostraram pouca relação com a variável idade em meses, e foram tiveram desempenho muito semelhante entre si, em todos os aspectos, em comparação com todas as demais variáveis. As correlações se mostraram bastante altas entre as medidas de altura e idade em meses dos diferentes estratos dos povoamentos florestais.

Dentre as medidas que foram adotadas para inclusão nos modelos, apenas uma das medidas de percentil de altura foi escolhida, a H_{p90} , para não haver problemas com colinearidade entre as variáveis do modelo. Dentre as variáveis de dispersão, foi utilizada apenas o desvio padrão da altura dos pontos (H_{desv}). As duas medidas de proporção de cobertura, como a variável de cobertura do dossel (Cov) e a medida de densidade do dossel (Dns).

Figura 13. Modelos digitais de terreno (MDT) em formato de *Hillshade* das fazendas de estudo. **A:** Jataí; **B:** Patizal do Vale Feliz; **C:** São José III; **D:** Urutay; **E:** Santa Cecília; **F:** Santa Terezinha V e VI.

Figura 14. *Canopy Height Model* (CHM) gerado pela diferença entre os Modelos Digitais de Superfície (MDS) e Modelos Digitais de Terreno (MDT). É possível notar as florestas plantadas sobressaindo em escala de cor mais clara. **A:** Jataí; **B:** Patizal do Vale Feliz; **C:** São José III; **D:** Urutay; **E:** Santa Cecília; **F:** Santa Terezinha V e VI.

Tabela 9. Correlação de Pearson entre as variáveis de dados LiDAR

	Idade	H _{min}	H _{max}	H _{med}	H _{desv}	H _{p50}	H _{p75}	H _{p90}	H _{p95}	H _{p99}	Cov	Dns	H _{p9010}	H _{p9010r}
Idade	1.00													
H _{min}	0.04	1.00												
H _{max}	0.89	0.14	1.00											
H _{med}	0.83	0.25	0.97	1.00										
H _{desv}	0.57	-0.36	0.43	0.26	1.00									
H _{p50}	0.87	0.18	0.98	0.99	0.35	1.00								
H _{p75}	0.89	0.16	0.99	0.98	0.40	0.99	1.00							
H _{p90}	0.89	0.15	1.00	0.98	0.42	0.99	1.00	1.00						
H _{p95}	0.89	0.15	1.00	0.97	0.42	0.99	1.00	1.00	1.00					
H _{p99}	0.89	0.15	1.00	0.97	0.43	0.98	1.00	1.00	1.00	1.00				
Cov	0.13	-0.12	0.13	0.11	0.08	0.12	0.13	0.13	0.13	0.13	1.00			
Dns	0.13	-0.12	0.13	0.11	0.08	0.12	0.13	0.13	0.13	0.13	1.00	1.00		
H _{p9010}	0.59	-0.32	0.45	0.22	0.83	0.33	0.40	0.43	0.43	0.45	0.08	0.08	1.00	
H _{p9010r}	0.25	-0.45	0.04	-0.19	0.70	-0.09	-0.01	0.01	0.02	0.03	0.00	0.00	0.90	1.00

Gráficos de dispersão foram utilizados para comparar as variáveis uma a uma com a idade dos talhões florestais em meses. A preocupação em encontrar um padrão gráfico claro que exprima uma relação entre variáveis independentes e a variável resposta (Figuras 15 e 16). Nota-se dentre o comportamento dos gráficos alguns padrões no comportamento das variáveis na sequencia ascendente das idades dentro dos plantios florestais. Um primeiro grupo mostra uma ausência de relação entre o idades avançadas e idades jovens, possuindo distribuições dispersas e pouco relacionadas com categorias específicas. Esse caso pode ser observado quanto à variável H_{min} que representa a altura mínima dentro da parcela.

A mesma ausência de relação é observada nos gráficos que expressam a cobertura do dossel e densidade do dossel, Cov e Dns , possuindo valores que variam bastante dentre as idades, mas que não permite formar uma observação que diferencie categorias.

Os percentis acima de H_{p50} , inclusive, apresentam uma tendência maior de continuidade do incremento da idade observada em campo, assim como o H_{med} , que representa a média das alturas do dossel, e o $H_{máx}$, altura máxima dentro das parcelas observadas. Há, no entanto, um comportamento que não acompanha a proporção entre a idade e as medidas observadas, mesmo nas métricas que possuem maior relação com a idade dos talhões observados. Dentre as idades de 72, 82, 87 e 98 não é possível notar diferença entre valores destas que permitam distinguir as parcelas com idades distintas.

Essa observação é importante porque o modelo que for selecionado deve possuir alguma outra variável capaz de diferenciar as diferenças existentes nessas parcelas, talvez, uma métrica de dispersão. As medidas de H_{desv} , H_{p9010} e H_{p9010r} foram apresentadas com esse propósito.

Figura 15. Gráficos de dispersão exploratórios de relação entre variáveis de dados LiDAR e a idade das parcelas de campo das florestas (continua)

Figura 16. Gráficos de dispersão exploratórios de relação entre variáveis de dados LiDAR e a idade das parcelas de campo das florestas.

4.4. Modelos com variáveis explicativas de dados LiDAR

Os modelos selecionados para a análise englobam a métrica de altura H_{p90} e medidas de dispersão como o H_{desv} , medidas de cobertura, Cov e Dns , bem como as medidas de proporção entre percentis, H_{p9010} e H_{p9010r} .

Tabela 10. Equações de idade com variáveis do sobrevoo ALS

Modelo	Equação	R ² adj	RMSE (meses)	rRMSE (%)	AIC
1	- 20,257 + 3,973 * H_{p90}	0,80	12,99	14,2	772,3
2	- 19,179 + 3,527 * H_{p90} + 3,309 * H_{desv}	0,85	12,07	13,2	746,5
3	- 20,641 + 3,966 * H_{p90} + 0,008 * Cov	0,79	13,03	14,2	774,3
4	- 20,641 + 3,966 * H_{p90} + 0,008 * Dns	0,79	13,03	14,2	774,3
5	- 17,685 + 3,484 * H_{p90} + 1,651 * H_{p9010}	0,85	11,95	13,1	741,4
6	- 30,280 + 3,958 * H_{p90} + 0,467 * H_{p9010r}	0,85	11,74	12,8	739,8

Abaixo foram selecionados os melhores modelos em desempenho, com maiores coeficientes de determinação ajustados e menor raiz do erro quadrático médio, para serem comparados os comportamentos dos resíduos.

Figura 17. Gráfico Quantil-Quantil dos resíduos estudentizados por quantis teóricos do modelo 2 e um gráfico de dispersão dos resíduos por valores ajustados do modelo 2.

O modelo somente com a variável H_{p90} apresentou resultado de rRMSE de 0,142 e AIC de 772,3. Modelos em que as variáveis de cobertura estavam presentes não trouxeram melhoras na precisão das estimativas, apenas trazendo mais incertezas sobre as predições do modelo. Os modelos 3 e 4 apresentaram R² ajustado de 0,79, rRMSE de 0,142 e critério de Akaike de 774,3. O coeficiente de determinação ajustado foi utilizado por permitir que seja feita comparação entre

modelos com número de variáveis explicativas diferentes (PAGANO; GAUVREAU, 2004).

Os melhores modelos observados foram os que utilizaram medidas de dispersão e as proporcionais entre percentis, como os modelos 2, 5 e 6. Nesses modelos, o R^2 ajustado foi de 0,85, um bom coeficiente de determinação para modelos baseados em métricas LiDAR.

Gráficos de quantil-quantil dos resíduos estudentizados por quantis teóricos e dispersão dos resíduos por valores ajustados de idade de cada modelo foram utilizados para comparar o comportamento da distribuição dos resíduos e atendimento à pressuposição da normalidade.

O resultado do teste de normalidade de Shapiro-Wilk (1965) realizado com 5% de significância indicou uma distribuição dos resíduos que não segue os princípios de normalidade nos modelos 5 e 6, mas segue o padrão no modelo 2 (tabela 11). O teste de homogeneidade de Cochran (1941) foi significativo apenas para os modelos 3 e 4 ao nível de 5% de significância, onde os valores calculados ficaram abaixo dos valores críticos da tabela. Abaixo estão representados os gráficos de quantis teóricos que apresentam pontos deslocados da reta nas extremidades. Os gráficos de dispersão de resíduos não apresentam aumento em valores conforme aumentam os valores ajustados (Figuras 17, 18 e 19).

Tabela 11. Teste de normalidade e homocedasticidade da variância nos modelos.

Modelo	Equação	Teste de Shapiro-Wilk (W)	Teste de Cochran (C)
1	- 20,257 + 3,973 * Hp90	0,9718*	0,2905 ^{ns}
2	- 19,179 + 3,527 * Hp90 + 3,309 * Hdesv	0,9804 ^{ns}	0,2310 ^{ns}
3	- 20,641 + 3,966 * Hp90 + 0,008 * Cov	0,9708*	0,3145*
4	- 20,641 + 3,966 * Hp90 + 0,008 * Dns	0,9708*	0,3145*
5	- 17,685 + 3,484 * Hp90 + 1,651 * HP9010	0,9706*	0,2205 ^{ns}
6	- 30,280 + 3,958 * Hp90 + 0,467 * Hp9010r	0,9748*	0,2310 ^{ns}

Figura 18. Gráfico Quantil-Quantil dos resíduos estudentizados por quantis teóricos do modelo 5 e um gráfico de dispersão dos resíduos por valores ajustados do modelo 5.

Figura 19. Gráfico Quantil-Quantil dos resíduos estudentizados por quantis teóricos do modelo 6 e um gráfico de dispersão dos resíduos por valores ajustados do modelo 6.

Não apresentando inconformidades com as pressuposições, os modelos são habilitados para serem usados na próxima etapa. No entanto, por restrição de tempo e análise de dados, apenas um será apresentado na próxima etapa, o que apresenta os melhores valores em relação ao coeficiente de determinação ajustado, o menor rRMSE e o menor valor de AIC. Com base nesses critérios, o modelo selecionado foi o modelo 6, e foram gerados mapas de idades para servir como base para calibrar as imagens de satélites (Figura 20).

Figura 20. Mapas gerados com a aplicação do modelo 6 para idades (meses) nas fazendas **A:** Santa Terezinha V e VI; **B:** Jataí; **C:** Patizal; **D:** São José III; **E:** Santa Cecília; e **F:** Urutay.

As informações das fazendas Santa Terezinha V e Santa Terezinha VI estão em um mesmo mapa, pela proximidade entre as duas. A escala de idade foi utilizada de 0 a 145 meses, apesar das idades dos plantios florestais ir apenas de 32 a 145 meses, por causa das previsões do modelo. Todas as fazendas estão em uma mesma escala de intensidade de coloração das idades, no entanto, não na mesma escala gráfica de representação de área.

Tabela 12. Tabela com as médias e desvios da idade de cada uma das fazendas destacadas no mapa com dados LiDAR.

Projeto / Fazenda	Média de idade (meses)	Desvio Padrão da idade (meses)
F184 - Santa Cecília	93,17	13,52
F634 - Patizal do Vale Feliz	119,47	21,54
F849 - São José III	79,41	15,44
F948 - Jataí	86,99	22,79
F950 - Urutay	83,03	15,69
F987 - Santa Terezinha VI	48,75	19,96
F986 - Santa Terezinha V	64,63	10,73

As estatísticas básicas das idades apresentadas por pixel no raster de cada uma das fazendas foram apresentadas na tabela 12. A fazenda que apresenta maior média, segundo o modelo, é a fazenda Patizal do Vale Feliz, 119,47 meses, e a fazenda Santa Terezinha VI é a que apresenta a menor média das idades, com 48,75 meses representado em seus pixels.

Os valores demonstram que a representação através do modelo tende a subestimar os valores de fazendas que possuem idades avançadas em meses, e tende a superestimar a idade das fazendas que possuem idades menores. As extremidades aparentam sofrer maiores alterações dos valores que realmente apresentam. Essa observação também pode ser feita no desvio padrão das idades apresentadas nas fazendas, onde a fazenda Patizal do Vale Feliz apresentou o segundo maior valor de variação, e a Santa Terezinha VI apresentou o terceiro maior valor de variação.

A proposta de divisão das fazendas em categorias de idade jovem (abaixo de 60 meses) e madura (acima de 60 meses) teriam, em teoria, duas fazendas classificadas como jovens, Santa Terezinha V (59 meses) e Santa Terezinha VI (32, 41 e 43 meses). Através dos números do modelo aplicado, apenas a fazenda Santa Terezinha VI seria classificada como povoamento jovem.

4.5. Modelos com variáveis de índices de vegetação

Os índices de vegetação calculados nas fazendas foram submetidos a uma análise de agrupamento em dendrograma, para evitar que variáveis explicativas muito próximas fossem utilizadas em modelos e resultassem em multicolinearidade entre as variáveis explicativas (Figura 21).

Figura 21. Análise de agrupamento em dendrograma das variáveis candidatas a compor o modelo.

A variável composta pelo índice Razão do Vermelho-Verde (Red-Green), que é composta por uma razão simples da banda do vermelho (banda 3) pela banda do verde (banda 2) por pixel, foi o índice de vegetação mais distante dos demais observados. Os índices SAVI e NDVI ficaram muito próximos um do outro, o que leva a considerar apenas um dentre os dois para compor um mesmo modelo. O índice Razão do Vermelho-Verde (Red-Green) e o índice de vegetação por diferença normalizada utilizando a banda verde (GNDVI), apesar de envolverem a banda verde no cálculo do índice, tem uma relação distante dentro da análise de agrupamento.

A integração das imagens com os dados LiDAR preditos se deu através de um modelo de regressão linear calculado entre os dados de quatro das sete fazendas, para calibração do modelo. As fazendas selecionadas foram Santa Terezinha V, Santa Terezinha VI, São José III e Patizal do Vale Feliz. Foram selecionadas para validação do modelo as fazendas Urutay, Santa Cecília e Jataí. A idade foi baseada no valor do raster por pixel e o cálculo foi feito aplicando a equação do modelo selecionado para os índices de vegetação a cada pixel, gerando medidas de idade em meses para toda a fazenda. Abaixo seguem os modelos montados com esse propósito (tabela 13).

Tabela 13. Modelos compostos por índices de vegetação

Modelo	Equação	R ²	RMSE (meses)	rRMSE (%)	AIC
1	- 4,08 + 116,64 * GNDVI	0,19	22,32	25,24	1234678,4
2	30,49 + 66,12 * NDVI	0,07	22,58	25,52	1252780,7
3	30,51 + 44,07 * SAVI	0,07	17,88	20,22	1252785,6
4	- 129,73 + 184,02 * GNDVI + 92,60 * Red-Green	0,49	40,74	46,06	1172650,6
5	- 98,74 + 265,59 * NDVI ₇₀₅ + 48,23 * Red-Green	0,41	56,21	63,56	1191704,5
6	- 186,47 - 5,26 * NDVI ₇₀₅ + 133,52 * Red-Green + 139,33 * SAVI	0,49	33,42	37,79	1171054,4
7	- 111,68 + 138,42 * NDVI ₇₀₅ + 112,95 * Red-Green + 2,7 * SRI	0,45	37,32	42,20	1131394,8
8	75,87 + 0,54 * SRI	0,01	16,91	19,11	1261083,2
9	-185,7 + 205,77 * NDVI + 132,20 * Red-Green	0,49	97,96	65,53	1171050,9

Os melhores modelos observados foram calculados através da regressão múltipla, ou seja, os que possuem mais de uma variável, sendo representados pelos modelos 4, 6, 7 e 9. Uma observação importante a se fazer é que os modelos que apresentaram os melhores resultados contavam com o índice de vegetação composto pelo índice de razão vermelho-verde (Red-Green).

Em geral, os modelos compostos por variáveis únicas apresentaram coeficientes de determinação muito baixos, entre 0,01 e 0,19. O pior desempenho foi para o modelo 8, composto por razão das bandas *Near Infrared* (NIR) e vermelho, nomeado SRI. O modelo que apresentou melhores resultados foi o modelo 1, composto pelo índice de vegetação por diferença normalizada utilizando a banda verde (GNDVI), com $R^2 = 0,19$ e $rRMSE = 0,2524$. As demonstrações dos nove modelos apresentados para cada fazenda podem se encontram em seção anexa a esse trabalho (Apêndice A).

Entre todos os modelos apenas um foi selecionado para a ser utilizado em uma extensão maior das imagens de satélite, gerando apenas um mapa final com plantios florestais distintos por classes de idade diferente. Nesta etapa final, diferente da etapa em que fizeram uso de três fazendas para validar o modelo, foram utilizadas todas as fazendas e relacionadas em um gráfico para comparação (Figura 22).

Figura 22. Distribuição das idades por fazenda com aplicação do modelo 4. A linha vermelha representa a idade de divisão dos plantios em categoria jovem e madura.

As fazendas Santa Terezinha V e VI foram apresentadas como fazendas pertencentes majoritariamente ao grupo das fazendas que possuem plantios jovens (abaixo de 60 meses) enquanto que São José III, Urutay, Santa Cecília, Jataí e Patizal do Vale Feliz foram classificadas como fazendas pertencentes às categorias de florestas maduras.

A incerteza na classificação das florestas é suficiente para não ser confiável a utilização da categoria meses como parâmetro para distinguir as fazendas por categorias contínuas como idade em meses. A aplicação da modelagem para distinguir os plantios entre jovens e maduros (≤ 60 meses e >60 meses) corresponde à melhor alternativa para não incidir em erros de classificação dos povoamentos.

Muitos pontos são classificados como *outliers* como resultados observados na distribuição de idades por pixels (Figura 23) certamente por considerar pixels que não representam vegetação dentro do domínio da fazenda ou representam corpos d'água que possuem reflectância para os índices de vegetação que são discrepantes. É possível de observar nos mapas de idade alguns pixels gerados pelos modelos com valores que destoam de seus vizinhos, de forma isolada ou em forma contínua representando alguma feição da fazenda que não corresponde à área efetivamente plantada. Esse problema pode ser contornado se o *shapefile*

obtido representar apenas a área efetivamente plantada da fazenda, sem considerar benfeitorias, objetos ou corpos d'água.

Mapas de idade por fazenda – Santa Cecília

Figura 23. Representação gráfica da distribuição da idade do plantio calculado por nove diferentes modelos compostos por índices de vegetação para a fazenda Santa Cecília.

Mapas de idade por fazenda - Jataí

Figura 24. Representação gráfica da distribuição da idade do plantio calculado por nove diferentes modelos compostos por índices de vegetação para a fazenda Jataí.

Mapas de idade por fazenda – Patizal do Vale Feliz

Figura 25. Representação gráfica da distribuição da idade do plantio calculado por nove diferentes modelos compostos por índices de vegetação para a fazenda Patizal.

Mapas de idade por fazenda – São José III

Figura 26. Representação gráfica da distribuição da idade do plantio calculado por nove diferentes modelos compostos por índices de vegetação para a fazenda São José III.

Mapas de idade por fazenda - Santa Terezinha V

Figura 27. Representação gráfica da distribuição da idade do plantio calculado por nove diferentes modelos compostos por índices de vegetação para a fazenda Santa Terezinha V.

Mapas de idade por fazenda – Santa Terezinha VI

Figura 28. Representação gráfica da distribuição da idade do plantio calculado por nove diferentes modelos compostos por índices de vegetação para a fazenda Santa Terezinha VI.

Mapas de idade por fazenda- Urutay

Figura 29. Representação gráfica da distribuição da idade do plantio calculado por nove diferentes modelos compostos por índices de vegetação para a fazenda Urutay.

Análise comparativa de dados LiDAR por estrato de plantio

Figura 30. Métricas de desvio padrão da altura, p9010r e p9010 comparadas entre os estratos das fazendas.

Análise comparativa de dados LiDAR por estrato de plantio

Figura 31. Métricas do desvio padrão da altura, p90 e Cobertura comparadas entre os estratos das fazendas.

Figura 32. Povoamentos florestais categorizados por idade.

5. DISCUSSÃO

A discussão seguirá os mesmos princípios propostos nos resultados, apresentar de forma clara as informações por pontos trabalhados dentro do processamento de dados ALS e das imagens de satélite. Nos subitens seguintes serão discutidos e comparados com outros trabalhos os resultados obtidos nos modelos digitais de elevação descritos (MDT, MDS e CHM) e modelos gerados com as métricas dos dados ALS.

5.1. Processamento das nuvens de pontos ALS

A retirada dos pontos considerados *outliers* no processamento da nuvem de pontos é um dos primeiros passos no trabalho com dados LiDAR. Toda a representação de dados pode conter informações que não estejam relacionadas com o objeto do estudo, e a retirada dos dados considerados *outlier* deve ser realizada de forma cuidadosa (BEN-GAL, 2005). Do contrário, dados contendo informações verdadeiras podem ser descartados com informações que seriam importantes para o modelo.

A densidade de pontos entregue pela empresa prestadora de serviços foi superior a densidade contratada (tabela 5) em cinco das sete fazendas estudadas. Apenas a Urutay e a Patizal do Vale Feliz ficaram ligeiramente menor densidade de pontos relativo ao contratado, 9,59 e 9,81 pontos.m⁻², respectivamente. A alta densidade de pontos obtidos dentro de um ambiente florestal é benéfico pois permite a obtenção de dados em uma resolução espacial maior, mais rica em detalhes (ZANDONÁ; LINGNAU; NAKAJIMA, 2008). Mas a distribuição de pontos não é homogênea, sendo maior nas extremidades das faixas de sobrevoo, comparadas à faixa central (BALSA-BARREIRO; AVARIENTO; LERMA, 2012) e de forma geral essa diferença é maior que a encontrada relatada em bibliografia.

5.2. Produtos do processamento da nuvem de pontos

O espaçamento médio apontado pela análise da nuvem (tabela 8) aponta que o menor espaçamento existente é o de 0,25 cm entre os pontos, para a nuvem que possuía maior densidade de pontos, e de 0,32 cm para as nuvens com a menor densidade de pontos. De acordo com a análise da média de espaçamento dos pontos, é possível afirmar que é bastante provável que em um metro linear de espaçamento haverá pelo menos 3 pontos de retorno LiDAR. Reutebuch et. al. (2003) estudou a acurácia do DTM quanto aos valores de elevação sob florestas plantadas com coníferas em região montanhosa e encontrou erro médio na de 0,22 cm com desvio padrão de 0,24 cm, em 347 parcelas de florestas plantadas com coníferas em região montanhosa. Erros que permitem avaliar o ALS como uma ferramenta que possui uma alta confiabilidade para sua utilização em ferramentas de modelagem de terreno no meio florestal.

Os Modelos Digitais de Terreno (MDT) foram obtidos para toda a área do sobrevoo realizada, excedendo os limites dos povoamentos florestais presente nas fazendas. Estes estão perfeitamente sobrepostos ao Modelo Digital de Superfície (MDS), possibilitando que haja uma operação entre os modelos que geram como resposta o Modelo de Altura do dossel. Uma obtenção de boas métricas LiDAR está diretamente ligada à qualidade dos MDEs obtidos (GIONGO et al., 2010). A observação das figuras de 12 (onde estão representadas as fazendas) demonstram a integridade dos modelos de elevação propostos, ausência de falhas ou buracos, e uma acentuada declividade na área de estudo.

5.3. Métricas das nuvens de pontos

A correlação de Pearson feita entre as métricas ALS apontaram para altas correlações entre as métricas de percentil de altura (tabela 9). Os percentis p50 a p99 todos apresentaram alta correlação entre si ($r \geq 0,80$), enquanto a p10 apresentou alta correlação apenas com p05 e p50, e a p05 apresentou alta correlação apenas com p10. As medidas de percentis acima de p50 tiveram as melhores correlações com a idade das parcelas, variando de 0,87 a 0,89. Silva (2014) encontrou valores de r de 0,98 a 0,99 entre p30, p70 e p90 em situação semelhante, onde predomina a presença de florestas equiâneas de eucalipto.

As relações entre as variáveis de densidade de cobertura do dossel (Dns) e cobertura do dossel (Cov) tiveram pequena relação com a idade das parcelas de campo, e pequena relação com as variáveis de altura.

Entre as variáveis de distribuição das alturas, a seleção do H_{p90} foi selecionada responder bem às diferenças entre estádios de desenvolvimento dos povoamentos florestais (GÖRGENS et al., 2017; RODRIGUEZ et al., 2010) e por seu relativo sucesso como variável dependente em modelos volumétricos em eucalipto (SILVA et al., 2015; ZONETE; RODRIGUEZ; PACKALÉN, 2010).

As variáveis representativas de estrutura do dossel (Cov e Dns) não apresentaram diferenças entre diferentes idades (meses) e não contribuíram para o modelo, apesar de serem significativos em modelos testados em outros trabalhos (MITCHELL et al., 2015; NÆSSET, 1997). Em estudos de modelos predizendo volume de florestas é possível notar valores de r^2 variando entre 0,66 e 0,81 variável de densidade de cobertura do dossel (NÆSSET, 1997). Bons resultados tem sido obtidos em modelos preditivos biométricos com medidas de dispersão, como desvio padrão da altura, e com média de altura (HUDAK et al., 2006; LOPATIN et al., 2016). As correlações entre H_{desv} , H_{p9010} e H_{p9010r} e a idade dos estratos apresentaram valores de 0,59, 0,57 e 0,25, respectivamente. O valor baixo da variável H_{p9010r} comparado com H_{desv} indica uma possível relação maior de resposta dos estratos por idade com a segunda variável.

5.4. Modelos preditivos de idade com dados LiDAR

Ao avaliar os modelos preditivos de idade, os valores de ajuste foram semelhantes, $r^2 = 0,85$ para ambos os modelos, tanto para o modelo 2 com as variáveis de H_{p90} e H_{desv} quanto para o modelo com H_{p90} e H_{p9010r} , e RMSE = 12,069 e 11,736, respectivamente. Comparando com trabalho que utilizou regressão linear múltipla para predição de biomassa em região de São Miguel Arcanjo, foi observado mesmo valor para coeficiente de determinação do modelo, $r^2=0,85$, e RMSE de $0,120 \text{ m}^3.\text{ha}^{-1}$, demonstrando coerência entre os resultados obtidos (LARANJA et al., 2015). Em se tratando de erro relativo, as variáveis apresentaram valores elevados, $r\text{RMSE} = 0,132$, $0,131$ e $0,128$, para os modelos 2, 5 e 6, respectivamente, ante valor de 0,055 para modelos preditivos de biomassa que usaram dados ALS e 0,127 para krigagem ordinária (SILVA et al., 2015). Pelo critério de Akaike a vantagem

para o modelo 6, cujo valor foi de 739,8 , valor 1,6 menor do que o modelo 5, ocupando a segunda posição na avaliação de modelos.

A análise dos resíduos dos modelos aponta para uma tendência de subestimar as idades de plantios com menos de 40 meses (Figuras 17, 18 e 19), para os modelos mais bem avaliados. Para o modelo 2, os valores também seguem uma tendência a serem subestimados à partir da idade de 100 meses, enquanto que para os modelos 5 e 6 a tendência existe, mas não é forte comparada com a existente no modelo 2.

O gráfico quantil-quantil do modelo 2 (Figura 17) aponta para uma variação maior dos resíduos sempre nas extremidades dos valores ajustados pelo modelo, e um ajuste mais adequado, com resíduos menores para os valores que se encontram mais aos valores ajustados próximos do quantil central. O mesmo se aplica para os resíduos do modelo 5 (Figura 18), mas com uma tendência menor em subestimar os valores de idade mais altos. Para o modelo 6 (Figura 19), os resíduos estão maiores na base do gráfico quantil-quantil, onde os valores ajustados pelo modelo para idades mais jovens são quase sempre considerados subestimados perante os dados de campo. Para os demais dados, contudo, apresenta valores mais bem ajustados, com menor desvio entre observados e preditos, e sem tendência a subestimar valores de idade, com exceção da última parcela comparada, que foge à regra.

5.5. Representação gráfica da distribuição de idade

Os mapas gerados para as sete fazendas (Figuras 20 A a F) estão representadas em mesma escala de idades, e indicam as fazendas Santa Terezinha V e VI com idades mais jovens, e a fazenda Patizal (Figuras 20 C) com idade mais avançadas, assim como descritas na tabela 12. Bons resultados foram encontrados com dados LiDAR para estimar a riqueza de espécies vasculares espacialmente (LOPATIN et al., 2016), utilizando como variáveis média da altura do dossel e desvio padrão da declividade. Mapas de atributos e temáticos são perfeitamente possíveis com dados LiDAR, inclusive produtos mais precisos e com maior riqueza de detalhes, como mapas hipsométricos e altimétricos (ZANDONÁ; LINGNAU; NAKAJIMA, 2008).

5.6. Modelos com variáveis de índices de vegetação

Os modelos testados para representar as variáveis por categorias de idade foram nove, alguns com variáveis únicas e outros com mais de uma variável (tabela 13). Dentre os modelos testados, três apresentaram melhores resultados de ajuste, os modelos 4, 6 e 9, com $r^2 = 0,49$, e o modelo 7 com $r^2 = 0,45$. Os RMSEs variaram de 33,42 a 97,96 meses, para os modelos 6 e 9, respectivamente. O valor de rRMSE menor também foi observado no modelo 6, com valor de 37,7 %, enquanto que o maior valor foi o observado para o modelo 65,53 % para o modelo 9. Índices de vegetação foram utilizados em modelagem para volume de madeira em talhões florestais e obtiveram r^2 entre 0,589 a 0,704 com uso do sensor Hyperion, à bordo do satélite EO-1 (CANAVESI; PONZONI; VALERIANO, 2010). Há ainda estudos que utilizam dados LiDAR como dados auxiliares com a intenção de aumentar a precisão de estimativas de estoque de carbono, obtendo valores de erro padrão das estimativas entre 1 e 4% (SAARELA et al., 2015).

Todos os modelos preditivos baseado em variáveis com índices de vegetação apresentaram certo nível de erro em classificar as fazendas quanto a plantios jovens e plantios maduros, proposta deste trabalho. Observando os mapas gerados pelos 4 modelos mais bem avaliados estatisticamente, disponíveis no Apêndice A, é possível notar que a proposta de dividir pelo limiar de idade de 60 meses resultou em predições um tanto quanto incertas. Os quatro modelos falharam em definir a categoria de idade da fazenda Santa Cecília, gerando mapas intermediários entre jovem e maduro (Figura 23). Apenas os modelos que não foram bem avaliados consideraram essa como uma fazenda contendo plantios maduros de eucalipto, enquanto que nenhum considerou como plantio totalmente jovem. Em uma perspectiva geral, o modelo 4 foi o que apresentou melhores predições para as categorias, indicando corretamente 6 das 7 fazendas, com desempenho satisfatório comparado aos demais. Os modelos 6, 7 e 9 erraram as fazendas Santa Terezinha V e VI, e, apenas para o modelo 9, o erro persistiu na fazenda Jataí (Figura 24).

Apesar de apresentar melhores resultados estatísticos relativo aos demais, o modelo 6 não foi capaz de diferenciar corretamente as categorias jovens e maduras de florestas, o que prejudicou sua avaliação como modelo potencial para se estender para toda a extensão das imagens. A melhor seleção é o modelo 4, embora tenha empatado com o modelo 6 em termos de ajuste de R^2 , fica em

desvantagem na avaliação estatística dos erros, mas em vantagem por apontar corretamente as idades nos mapas das fazendas por idade.

5.7. Mapa final dos povoamentos

O mapa final gerado com o uso do modelo selecionado está representado no Apêndice C. A categorização foi utilizada para as todas as fazendas presentes nas 4 imagens de satélite utilizadas no estudo, onde foram utilizados arquivo com as florestas presentes nesta região com dados do Instituto Florestal, da Secretaria de Meio Ambiente do Estado de São Paulo (INSTITUTO FLORESTAL - SECRETARIA DO MEIO AMBIENTE DO ESTADO DE SÃO PAULO, 2013).

A distribuição das florestas demonstra uma tendência a concentrar categorias por setores da imagem, apesar de em algumas regiões polígonos com mais de uma classificação serem encontrados. Nas imagens que se aproximam da parte direita do mapa, a tendência é de povoamentos serem classificados como maduros, com regiões supostamente próximas das Áreas de Preservação Permanente – APPs – sendo classificadas como jovens. Isso ocorre provavelmente pelo ajuste das variáveis LiDAR conter como variável percentil de altura, que pode classificar APPs como jovens por possuir estatura do dossel menor. Apenas a região central do mapa, a ocorrência das duas situações é bastante semelhante, não predomina uma categoria sobre a outra, enquanto que o lado esquerdo do mapa é rico em predominância de plantios jovens.

Os dados dos povoamentos só são conhecidos para as fazendas que deram origem aos modelos, onde possuem informações de sobrevoos ALS e dados de campo, citadas nesse trabalho. Para confirmar outras informações observadas no mapa, é imperativo que se obtenha acesso ao cadastro de empresas de base florestal ou com os produtores rurais donos de plantios. Essa necessidade é patente para certificação das informações constantes no mapa, pois esse trabalho propõe uma aplicação diversa da modelagem de dados ALS mas não detém as informações de campo necessárias para validar seus dados em macroescala.

As variações observadas nas respostas do modelo podem ser derivadas de fatores relacionados às alturas das árvores distintos de sua idade, o que enfraquece a relação das variáveis independentes com a resposta. Fatores esses que não foram levados em consideração e podem influenciar as idades em diferentes talhões, o que demonstra uma certa insensibilidade do modelo em diferenciar tais situações.

As alturas do estrato florestal sofrem influência de fatores ambientais, em muitos casos da altitude do terreno onde está localizado o plantio florestal e do déficit hídrico (FERREIRA; COUTO, 1981). As alturas das maiores árvores plantadas, árvores dominantes, são bastante indicadas para identificar a capacidade produtiva de uma área de plantio, pois variam pouco por diferentes tratamentos silviculturais aplicados (MACHADO; FIGUEIREDO FILHO, 2006b). Entretanto, é importante avaliar que as mesmas alturas podem ser diferentes de região para região, mesmo entre as mesmas espécies de plantio (TONINI et al., 2002). No cômputo do crescimento da altura de um pinheiro marítimo por 29 anos o comportamento observado foi crescente em uma parábola bastante inclinada (BURKHART; TOMÉ, 2012) o que permite inferir que métricas relacionadas a altura podem representar boas variáveis independentes em modelos preditivos de idade, ao menos para uma mesma região.

Os povoamentos de eucalipto que foram quantificados nas fazendas avaliadas são todos clones de matrizes híbridas de *Eucalyptus grandis* x *Eucalyptus urophylla* produzidas especificamente para celulose. A diferença entre o crescimento em diferentes idades pode ficar por tipo de clone aplicado em cada projeto/fazenda, mas em termos de espécie, são todas semelhantes.

O cálculo de área considerando as duas categorias resulta em 11.518,2 ha (79,4 %) para o total de área com plantios maduros e 2.987,13 ha (20,6 %) para o total de área com plantios jovens.

6. CONCLUSÃO

As florestas plantadas foram categorizadas com sucesso em plantios jovens e maduros para a região do Vale do Paraíba, Estado de São Paulo, mesmo possuindo materiais genéticos distintos cultivados em diferentes níveis de altitude e municípios. O potencial de classificar as florestas por idade, objeto deste trabalho, está condicionado à existência de quatro informações preliminares: (i) levantamento de dados de campo; (ii) imagens de satélite com resolução espacial intermediária (5 m) e livre de nuvens; (iii) sobrevoo ALS em cobertura total de, ao menos, uma fazenda em cada categoria; (iv) *shapefile* dos povoamentos de eucalipto para a área onde se pretende projetar a classificação.

Os modelos compostos por variáveis ALS foram capazes de estimar a idade (em meses) dos plantios com bons resultados, R^2 variando entre 0,80 e 0,85, e RMSE entre 11,736 e 13,029. Também foram considerados adequados o desempenho do modelo 6 que usa como variáveis preditivas o percentil 90 (P90) e a razão $(P90-P10)/P90$, representada por H_{p9010r} . Esse modelo permite reproduzir adequadamente as idades em toda a extensão das fazendas e extrapolar as previsões regionalmente com o apoio de imagens de satélite. Os modelos compostos por variáveis de índices de vegetação apresentaram erros maiores nas estimativas das idades e apenas um foi capaz de prever corretamente a categoria de idade, errando na previsão para o caso de apenas uma fazenda.

Dentre os modelos baseados em variáveis de índices de vegetação, o mais bem avaliado usa como variáveis preditivas o GNDVI e o Red-Green, índices que calculam razões entre as refletâncias nas bandas do infravermelho próximo e da banda verde, e das bandas do vermelho e do verde, respectivamente.

O mapa final com distribuição dos povoamentos de toda a região do Vale do Paraíba mostra que predominam mais a Leste as idades maduras e a Oeste as idades jovens. Na região central as duas categorias ocorrem com aproximadamente a mesma frequência. A estimativa para todo o Vale do Paraíba, produzida pelo uso combinado do modelo ALS 6 e do modelo IV 4, aponta para uma área com plantios maduros 3,8 vezes maior que com plantios jovens. Salienta-se, entretanto, a necessidade de validar com informações de campo esses resultados.

Por fim, para melhores resultados com modelagem de idades em povoamentos equiâneos, recomenda-se ampliar a área de estudo e levar em

consideração fatores como mapeamento dos solos, climáticos e material genético cultivado.

REFERÊNCIAS

- ABRAF. Anuário Estatístico-Associação Brasileira de Produtores de Florestas Plantadas. **Anuário Estatístico ABRAF**, p. 146, 2013.
- ALVARES, C. A.; STAPE, J. L.; SENTELHAS, P. C.; DE MORAES GONÇÁLVES, J. L.; SPAROVEK, G. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711–728, 2013.
- ANDERSON, C.; THIELE, M.; BRUNN, A. **Calibration and validation of the RapidEye constellation**. IN: ANAIS XVI SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO - SBSR. **Anais...** 2013. p. 9143–9150.
- ANTUNES, M. A. H.; SIQUEIRA, J. C. DOS S. **Características das imagens RapidEye para mapeamento e monitoramento e agrícola e ambiental**. IN: ANAIS XVI SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO - SBSR. **Anais...** 2013. p. 547–554.
- ARAÚJO, L. V. C. DE; LEITE, J. A. N.; PAES, J. B. Estimativa da Produção de Biomassa de Um Povoamento de Jurema-Preta (*Mimosa tenuiflora*) com cinco anos de idade. **Biomassa & Energia**, v. 1, n. 4, p. 347–352, 2004.
- AXELSSON, P. DEM Generation from Laser Scanner Data Using adaptive TIN Models. **International Archives of Photogrammetry and Remote Sensing**, v. 23, n. B4, p. 110–117, 2000.
- BALSA-BARREIRO, J.; AVARIENTO, J. P.; LERMA, J. L. Airborne light detection and ranging (LiDAR) point density analysis. **Scientific Research and Essays**, v. 7, n. 33, p. 3010–3019, 2012.
- BEN-GAL, I. Chapter 7 OUTLIER DETECTION. In: **Data Mining and Knowledge Discovery Handbook**. [S.l: s.n.]. p. 131–146.
- BINOTI, D. H. B.; DA BINOTI, M. L. M. S.; LEITE, H. G.; SILVA, A. Redução dos custos em inventário de povoamentos equiâneos. **Revista Brasileira de Ciências Agrárias**, v. 8, n. 1, p. 125–129, 2013.
- BLACKBRIDGE. **Satellite Platform Performance**. Disponível em: <<http://blackbridge.com/rapideye/about/satellites.htm>>. Acesso em: 25 maio. 2016.
- BOLFE, É. L.; BATISTELLA, M.; FERREIRA, M. C. Correlação de variáveis espectrais e estoque de carbono da biomassa aérea de sistemas agroflorestais. **Pesquisa Agropecuária Brasileira**, v. 47, n. 9, p. 1261–1269, 2012.
- BURKHART, H. E.; TOMÉ, M. Indices of Individual-Tree Competition. In: **Modeling Forest Trees and Stands**. [S.l: s.n.]. p. 457.
- CAMPOS, J. C. C.; LEITE, H. G. **Mensuração Florestal - 4ª Edição | Editora UFV**. [S.l: s.n.].
- CANAVESI, V.; PONZONI, F. J.; VALERIANO, M. M. Estimativa de volume de madeira em plantios de *Eucalyptus* spp. utilizando dados hiperespectrais e dados topográficos. **Revista Árvore**, v. 34, n. 3, p. 539–549, 2010.
- CHEN, G.; WULDER, M. A.; WHITE, J. C.; HILKER, T.; COOPS, N. C. Lidar

calibration and validation for geometric-optical modeling with Landsat imagery. **Remote Sensing of Environment**, v. 124, p. 384–393, 2012.

COCHRAN, W. G. Some Methods for Strengthening the Common χ^2 Tests. **Biometrics**, v.10, n. 4, p. 417-451, 1941.

ESRI. **ArcGIS Desktop: Release 10.3**. Redlands, CA: Environmental Systems Research Institute: 2011.

FAO. **Global Forest Resources Assessment 2010. FAO FORESTRY PAPER 163**. [S.l: s.n.].

FERRAZ, A.; BRETAR, F.; JACQUEMOUD, S.; GONÇALVES, G.; PEREIRA, L.; TOMÉ, M.; SOARES, P. 3-D mapping of a multi-layered Mediterranean forest using ALS data. **Remote Sensing of Environment**, v. 121, p. 210–223, 2012.

FERREIRA, C. A.; COUTO, H. T. Z. DO. A INFLUÊNCIA DE VARIÁVEIS AMBIENTAIS NO CRESCIMENTO DE ESPÉCIES / PROCEDÊNCIAS DE Eucalyptus spp NOS ESTADOS DE MINAS GERAIS E ESPÍRITO SANTO. **Boletim de Pesquisa Florestal**, n. 3, p. 9–35, 1981.

GAMON, J. A.; SURFUS, J. S. Assessing leaf pigment content and activity with a reflectometer. **New Phytologist**, v. 143, n. 1, p. 105–117, 1999.

GAO, B. C. NDWI - A normalized difference water index for remote sensing of vegetation liquid water from space. **Remote Sensing of Environment**, v. 58, n. 3, p. 257–266, 1996.

GIONGO, M.; KOEHLER, H. S.; MACHADO, A.; KIRCHNER, F. F. LiDAR : princípios e aplicações florestais. **Pesquisa Florestal Brasileira**, v. 30, n. 63, p. 231–244, 2010.

GITELSON, A. A.; MERZLYAK, M. N. Signature Analysis of Leaf Reflectance Spectra: Algorithm Development for Remote Sensing of Chlorophyll. **Journal of Plant Physiology**, v. 148, n. 3–4, p. 494–500, 1996.

GITELSON, A.; MERZLYAK, M. N. Spectral Reflectance Changes Associated with Autumn Senescence of Aesculus hippocastanum L. and Acer platanoides L. Leaves. Spectral Features and Relation to Chlorophyll Estimation. **Journal of Plant Physiology**, v. 143, n. 3, p. 286–292, 1994.

GONZALEZ, P.; ASNER, G. P.; BATTLES, J. J.; LEFSKY, M. A.; WARING, K. M.; PALACE, M. Forest carbon densities and uncertainties from Lidar, QuickBird, and field measurements in California. **Remote Sensing of Environment**, v. 114, n. 7, p. 1561–1575, 2010.

GÖRGENS, E. B.; VALBUENA, R.; CARLOS, L.; RODRIGUEZ, E. A Method for Optimizing Height Threshold When Computing Airborne Laser Scanning Metrics. **Photogrammetric Engineering & Remote Sensing**, v. 83, n. 5, p. 343–350, 2017.

HIGUCHI, N.; SANTOS, J. DOS; LIMA, A. J. N. **Biometria florestal**. [S.l: s.n.].

HUDAK, A. T.; CROOKSTON, N. L.; EVANS, J. S.; FALKOWSKI, M. J.; SMITH, A. M. S.; GESSLER, P. Regression modeling and mapping of coniferous forest basal area and tree density from discrete- return LiDAR and multispectral satellite data. **Canadian Journal of Remote Sensing**, v. 32, n. 2, p. 126–138, 2006.

HUDAK, A. T.; LEFSKY, M. A.; COHEN, W. B.; BERTERRETCHE, M. Integration of lidar and Landsat ETM+ data for estimating and mapping forest canopy height. **Remote sensing of Environment**, v. 82, n. 2, p. 397–416, 2002.

HUETE, A. R. A soil-adjusted vegetation index (SAVI). **Remote Sensing of Environment**, v. 25, n. 3, p. 295–309, 1988.

IBA. **Relatório IBÁ 2015**. [S.l: s.n.]. Disponível em: <<http://iba.org/pt/biblioteca-iba/publicacoes>>.

IBAMA. **GeoCatalogo**. Disponível em: <<http://geocatalogo.mma.gov.br/>>. Acesso em: 10 ago. 2015.

INCORPORATED RESEARCH SYSTEMS. **ENVI User ' s Guide**. [S.l: s.n.].

INDUSTRIA BRASILEIRA DE ÁRVORES. **Ibá 2014Journal of Chemical Information and Modeling**. [S.l: s.n.].

INSTITUTO FLORESTAL - SECRETARIA DO MEIO AMBIENTE DO ESTADO DE SÃO PAULO. **Manejo e Inventário Florestal | Instituto Florestal - Sistema Ambiental Paulista - Governo de SP**. Disponível em: <<http://iflorestal.sp.gov.br/pesquisa/manejo-e-inventario-florestal/>>. Acesso em: 3 maio. 2017.

ISENBURG, M. **LASTOOLS v161029**. 2016. Disponível em: <<http://lastools.org>>

LANG, S. A utilização do conceito de totalidade (holismo) na geração de planos de segmentação regionalizados em conjuntos de imagens de altíssima resolução. **Sensoriamento remoto e SIG avançados–novos sistemas sensores metodos inovadores, oficina de textos, Sao Paulo**, p. 33–40, 2005.

LARANJA, D. C. F.; GORGENS, E. B.; PEDRO, C.; SOARES, B.; GRACIOSO, A. Redução do erro amostral na estimativa do volume de povoamentos de escaneamento laser aerotransportado. **Scientia Forestalis**, v. 43, n. 108, p. 845–852, 2015.

LINDBERG, E.; OLOFSSON, K.; HOLMGREN, J.; OLSSON, H. Estimation of 3D vegetation structure from waveform and discrete return airborne laser scanning data. **Remote Sensing of Environment**, v. 118, p. 151–161, 2012.

LOPATIN, J.; DOLOS, K.; HERNÁNDEZ, H. J.; GALLEGUILLOS, M.; FASSNACHT, F. E. Comparing Generalized Linear Models and random forest to model vascular plant species richness using LiDAR data in a natural forest in central Chile. **Remote Sensing of Environment**, v. 173, p. 200–210, 2016.

LU, D.; CHEN, Q.; WANG, G.; MORAN, E.; BATISTELLA, M.; ZHANG, M.; VAGLIO LAURIN, G.; SAAH, D. Aboveground Forest Biomass Estimation with Landsat and LiDAR Data and Uncertainty Analysis of the Estimates. **International Journal of Forestry Research**, v. 2012, n. 12, p. 1–16, 2012.

MACHADO, S. DO A.; FIGUEIREDO FILHO, A. Introdução. In: **Dendrometria**. [S.l: s.n.]. p. 316.

MACHADO, S. DO A.; FIGUEIREDO FILHO, A. Medição de Alturas. In: **Dendrometria**. [S.l: s.n.]. p. 316.

MAGNUSSEN, S.; WULDER, M. A. Post-fire canopy height recovery in Canada's boreal forests using airborne laser scanner (ALS). **Remote Sensing**, v. 4, n. 6, p. 1600–1616, 2012.

MALTAMO, M.; NÆSSET, E.; VAUKONEN, J. **Forestry Applications of airborne laser scanning**. Forestry Applications of Airborne Laser Scanning: Concepts and Case Studies, [s. l.]. 2014. v. 27

MCGAUGHEY, R. J. FUSION/LDV: Software for LIDAR Data Analysis and Visualization. n. October, p. 182, 2015.

MEUNIER, I. M. J.; SILVA, J. A. A. DA; FERREIRA, R. L. C. **INVENTÁRIO FLORESTAL**. [S.l.: s.n.].

MILLER, D.; LEWIS, P. **Fast Line-of-sight Atmospheric Analysis of Spectral Hypercubes**. IN: ALGORITHMS AND TECHNOLOGIES FOR MULTISPECTRAL, HYPERSPECTRAL, AND ULTRASPECTRAL IMAGERY VIII, PROCEEDINGS OF SPIE VOL. 4725 (2002) © 2002 SPIE · 0277-786X/02/\$15.00 DOWNLOADED. **Anais...** 2002. p. 65–71.

MITCHELL, J. J.; SHRESTHA, R.; SPAETE, L. P.; GLENN, N. F. Combining airborne hyperspectral and LIDAR data across local sites for upscaling shrubland structural information: Lessons for HypSIRI. **Remote Sensing of Environment**, v. 167, p. 98–110, 2015.

NÆSSET, E. Estimating timber volume of forest stands using airborne laser scanner data. **Remote Sensing of Environment**, v. 61, n. 2, p. 246–253, 1997.

NÆSSET, E.; GOBAKKEN, T.; HOLMGREN, J.; HYYPPÄ, H.; HYYPPÄ, J.; MALTAMO, M.; NILSSON, M.; OLSSON, H.; PERSSON, Å.; SÖDERMAN, U. Laser scanning of forest resources: the nordic experience. **Scandinavian Journal of Forest Research**, v. 19, n. 6, p. 482–499, 2004.

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.

NOVO, E. M. L. **Sensoriamento remoto: princípios e aplicações**. Edgard Blücher, [s. l.]. 2010.

PAGANO, M.; GAUVREAU, K. **Princípios de Bioestatística**. [S.l.: s.n.].

PARISE, D. E. O.; VETTORAZZI, C. A. Análise De Dados De Produção Em Um Pomar Jovem De Laranjeiras. **Revista Brasileira de Fruticultura**, v. 27, n. 1, p. 43–47, 2005.

PEARSON, R. K. Outliers in process modeling and identification. **IEEE Transactions on Control Systems Technology**, v. 10, n. 1, p. 55–63, 2002.

PEREIRA, R. M. **Gestão da qualidade aplicada ao inventário de florestas plantadas**. 2009. - [S.l.: s.n.].

PERKINS, T.; ADLER-GOLDEN, S.; MATTHEW, M.; BERK, A.; ANDERSON, G.; GARDNER, J.; FELDE, G. Retrieval of atmospheric properties from hyper and multispectral imagery with the FLAASH atmospheric correction algorithm. IN:

INTERNATIONAL SOCIETY FOR OPTICS AND PHOTONICS. **Anais...** 2005. p. 59790E–59790E–11. Disponível em: <<http://dx.doi.org/10.1117/12.626526>>

PLANET LABS INC. **Rapideye™ Imagery Product Specifications**. [S.l: s.n.].

PONZONI, F. J.; SHIMABUKURO, Y. E. **Sensoriamento remoto no estudo da vegetação**. [S.l: s.n.].

RAMOS, R. R. D.; LOPES, H. L.; JÚNIOR, J. C. F. D. M.; CANDEIAS, A. L. B.; FILHO, J. A. D. S. Aplicação Do Índice Da Vegetação Por Diferença Normalizada (Ndvi) Na Avaliação De Áreas Degradadas E Potenciais Para Unidades De Conservação. **III Simpósio Brasileiro de Ciências Geodésicas e Tecnologias da Geoinformação**, p. 1–6, 2010.

REUTEBUCH, S. E.; MCGAUGHEY, R. J.; ANDERSEN, H.-E.; CARSON, W. W. Accuracy of a high-resolution lidar terrain model under a conifer forest canopy. **Canadian Journal of Remote Sensing**, v. 29, n. 5, p. 527–535, 2003.

RIEGL LASER MEASUREMENT SYSTEMS. **RIEGL - Produktdetail**. Disponível em: <<http://www.riegl.com/products/airborne-scanning/produktdetail/product/scanner/23/>>. Acesso em: 4 maio. 2017.

RODRIGUEZ, L. C. E.; POLIZEL, J. L.; FERRAZ, S. F. D. B.; ZONETE, M. F.; FERREIRA, M. Z. Inventário florestal com tecnologia laser aerotransportada de plantios de Eucalyptus spp no Brasil. **Ambiencia**, v. 6, n. March 2016, p. 67–80, 2010.

ROSS, J. L. S.; MOROZ, I. C. Mapa geomorfológico do estado de São Paulo. **Revista do Departamento de Geografia**, v. 10, p. 41–58, 2011.

ROUSE, J. W.; HAAS, R. H.; SCHELL, J. A.; DEERING, D. W. Monitoring the vernal advancement and retrogradation (green wave effect) of natural vegetation. **Progress Report RSC 1978-1**, 1973.

SAARELA, S.; GRAFSTRÖM, A.; STÅHL, G.; KANGAS, A.; HOLOPAINEN, M.; TUOMINEN, S.; NORDKVIST, K.; HYYPPÄ, J. Model-assisted estimation of growing stock volume using different combinations of LiDAR and Landsat data as auxiliary information. **Remote Sensing of Environment**, v. 158, p. 431–440, 2015.

SHAPIRO, S. S.; WILK, M. B. Biometrika trust an analysis of variance test for normality (complete samples). **Biometrika**, v. 52, n. 3 e 4, p. 591, 1965.

SHINZATO, E. T. **INTEGRAÇÃO DE DADOS LASER SCANNER AEROTRANSPORTADO E IMAGENS AÉREAS NO INVENTÁRIO**. 2015. - [S.l: s.n.].

SILVA, A. G. P. **Estimativa da biomassa de lenho em povoamentos de Eucalyptus grandis baseada em estatísticas do perfil de dossel geradas por escaneamento a laser aerotransportado**. 2014. - [S.l: s.n.].

SILVA, C. A. **Carbono na parte aérea de plantios de Eucalyptus spp. - em nível de árvore por amostragem destrutiva e para talhões inteiros após o ajuste de métricas LiDAR**. 2013. - [S.l: s.n.].

SILVA, A. G. P. DA; GÖRGENS, E. B.; CAMPOE, O. C.; ALVARES, C. A.; STAPE, J. L. Assessing biomass based on canopy height profiles using airborne laser scanning data in eucalypt plantations. **Scientia Agricola**, v. 72, n. 6, p. 504–512, 2015.

SOUZA, E. M. F. D. R. DE; VICENS, R. S.; CRUZ, C. B. M. Anais XVI Simpósio Brasileiro de Sensoriamento Remoto - SBSR, Foz do Iguaçu, PR, Brasil, 13 a 18 de abril de 2013, INPE. **Anais XVI Simposio Brasileiro de Sensoriamento Remoto - SBSR, Foz do Iguaçu, PR, Brasil, 13 a 18 de abril de 2013, INPE**, p. 6917–6922, 2013.

TONINI, H.; FINGER, C. A. G.; SCHNEIDER, P. R.; SPATHELF, P. Comparação gráfica entre curvas de índice de sítio para *Pinus elliottii* e *Pinus taeda* desenvolvidas no sul do Brasil. **Ciência Florestal**, v. 12, n. 1, p. 143–152, 2002.

TUCKER, C. J. Red and photographic infrared linear combinations for monitoring vegetation. **Remote Sensing of Environment**, v. 8, n. 2, p. 127–150, 1979.

WHITE, J. C.; WULDER, M. A.; VARHOLA, A.; VASTARANTA, M.; COOPS, N. C.; COOK, B. D.; PITT, D.; WOODS, M. **CANADIAN WOOD FIBRE CENTRE A best practices guide for generating forest inventory attributes from airborne laser scanning data using an area-based approach**. [S.l: s.n.].

WULDER, M. A.; WHITE, J. C.; NELSON, R. F.; N??SSET, E.; ??RKA, H. O.; COOPS, N. C.; HILKER, T.; BATER, C. W.; GOBAKKEN, T. Lidar sampling for large-area forest characterization: A review. **Remote Sensing of Environment**, v. 121, p. 196–209, 2012.

ZANDONÁ, D. F.; LINGNAU, C.; NAKAJIMA, N. Y. Varredura a Laser aerotransportado para estimativa de variáveis dendrométricas Airborne Laser Scanner technology for estimating dendrometric variables. **Scientia Forestalis**, v. 36, n. 80, p. 295–306, 2008.

ZONETE, M. F. **Análise do uso da tecnologia laser aerotransportado para inventários florestais em plantios clonais de Eucalyptus sp no sul da Bahia**. 2009. - [S.l: s.n.].

ZONETE, M. F.; RODRIGUEZ, L. C. E.; PACKALÉN, P. Estimación de parâmetros biométricos de plantios clonais de eucalipto no sul da Bahia: Uma aplicação da tecnologia laser aerotransportada. **Scientia Forestalis/Forest Sciences**, n. 86, p. 225–235, 2010.