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

**Estimativa da biomassa de lenho em povoamentos de *Eucalyptus grandis*
baseada em estatísticas do perfil de dossel geradas por
escaneamento a laser aerotransportado**

André Gracioso Peres da Silva

**Dissertação apresentada para obtenção do título de
Mestre em Ciências. Área de concentração: Recursos
Florestais. Opção: Silvicultura e Manejo Florestal**

**Piracicaba
2014**

André Gracioso Peres da Silva
Engenheiro Florestal

Estimativa da biomassa de lenho em povoamentos de *Eucalyptus grandis*
baseada em estatísticas do perfil de dossel geradas por
escaneamento a laser aerotransportado
versão revisada de acordo com a resolução CoPGr 6018 de 2011

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

Dissertação apresentada para obtenção do título
de Mestre em Ciências. Área de concentração:
Recursos Florestais. Opção: Silvicultura e Manejo
Florestal

Piracicaba
2014

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

Silva, André Gracioso Peres da

Estimativa da biomassa de lenho em povoamentos de *Eucalyptus grandis* baseada em estatísticas do perfil de dossel geradas por escaneamento a laser aerotransportado / André Gracioso Peres da Silva . - - versão revisada de acordo com a resolução CoPGr 6018 de 2011. - - Piracicaba, 2014.

146 p. : il.

Dissertação (Mestrado) - - Escola Superior de Agricultura "Luiz de Queiroz", 2014.
Bibliografia.

1. LiDAR 2. Área basal 3. Modelo biométrico 4. Inventário florestal 5. Plantações florestais de rápido crescimento I. Título

CDD 634.9734
S586e

"Permitida a cópia total ou parcial deste documento, desde que citada a fonte – O autor"

À Berenice K. de Alcântara, com amor.

OFEREÇO

Aos meus pais, Francisco e Isabel.

Ao meu querido irmão, Thiago.

À minha família.

DEDICO

AGRADECIMENTOS

À Deus,

Aos meus pais Francisco e Isabel, por todo carinho, amor e dedicação incondicionais.

Ao meu irmão Thiago pelo suporte, motivação e exemplo.

À minha família, por todo o apoio ao longo de minha vida.

À Berenice K. Alcântara, pela paciência, companheirismo e dedicação em todos os momentos.

Aos meus sogros Benedito e Lioko, pelo apoio recebido e pensamentos positivos.

Ao professor Luiz Carlos E. Rodriguez pela orientação, apoio e ensinamentos prestados durante o Mestrado. Pela iniciativa em criar o Grupo de Estudos em Tecnologia LiDAR, na ESALQ/USP.

Ao amigo Eric Bastos Gorgens, por todas as contribuições prestadas a este trabalho. Pela disposição em sempre ajudar os colegas de pós-graduação.

Aos pesquisadores Clayton Alcarde Alvares e Otávio Camargo Campoe pelas sugestões e contribuições a este trabalho. Ao professor José Luiz Stape por incentivar e acreditar em nossa pesquisa.

Ao Instituto de Pesquisas e Estudos Florestais (IPEF); Instituto Politécnico e Universidade Estadual da Virgínia (Virginia Tech); e Universidade Estadual da Carolina do Norte (NCSSU), pela disponibilização da base de dados utilizada nesta pesquisa.

Aos amigos do Grupo de Estudos em Tecnologia LiDAR (Jefferson, Eric, Edgar, Julianne, Samuel, Luciana, Débora, Carlos, Bruno, Danitiele e Tiago) pelos bons momentos vividos e por todo o trabalho e aprendizagem resultantes do esforço em equipe.

Aos amigos do Laboratório de Métodos Quantitativos (LMQ) do Departamento de Ciências Florestais da ESALQ/USP, pelo bom convívio e troca de conhecimentos na área quantitativa da engenharia florestal.

Aos amigos do Programa de Pós Graduação em Estatística e Experimentação Agrônômica por todo o apoio e atenção disponibilizados durante a disciplina de Estatística Matemática 1 (LCF 5806).

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela bolsa de Mestrado concedida.

À Escola Superior de Agricultura “Luiz de Queiroz” (ESALQ/USP) pela oportunidade de realizar o curso de Mestrado.

À todos que, de alguma forma, contribuíram para a realização deste trabalho.

“A mente que se abre a uma nova ideia jamais volta ao seu tamanho original”

Albert Einstein

SUMÁRIO

RESUMO	13
ABSTRACT	15
LISTA DE FIGURAS	17
LISTA DE TABELAS	23
LISTA DE SIGLAS	25
1 INTRODUÇÃO	27
1.1 Setor de florestas plantadas.....	27
1.2 Biometria florestal	28
1.3 Potencial evolutivo das técnicas de quantificação da biomassa florestal	29
1.4 Objetivos	32
1.5 Hipóteses.....	33
2 REVISÃO BIBLIOGRÁFICA	35
2.1 Tecnologia de escaneamento a laser aerotransportado (ALS).....	35
2.2 Perfis de alturas de dossel (<i>Canopy Height Profiles</i> – CHPs).....	40
3 MATERIAL E MÉTODOS	45
3.1 Área de estudo	45
3.2 Processamento dos dados de campo	46
3.2.1 Parcelas experimentais	46
3.2.2 Parcelas de validação	50
3.3 Escaneamento a laser aerotransportado (ALS).....	52
3.4 Processamento da nuvem de pontos ALS.....	53
3.4.1 Classificação de retornos de solo	54
3.4.2 Modelos digitais de elevação (DEM).....	56
3.4.3 Extração de métricas	56
3.5 Perfis de alturas de dossel (CHPs).....	59

3.6	Modelos lineares.....	63
3.6.1	Seleção de variáveis preditoras.....	63
3.6.2	Ajuste dos modelos de regressão	65
3.6.3	Verificação de pressuposições	67
3.6.4	Critérios para seleção de modelos	68
3.6.5	Validação	72
3.7	Krigagem ordinária.....	73
3.8	Representação espacial das variáveis de interesse	75
4	RESULTADOS	77
4.1	Homogeneização da nuvem de pontos	77
4.2	Modelo digital de elevação (DEM)	79
4.3	Perfis de alturas de dossel (CHPs)	81
4.4	Variáveis explicativas ALS	84
4.5	Modelos lineares.....	86
4.5.1	Área basal	88
4.5.2	Biomassa do lenho	94
4.5.3	Validação	101
4.6	Krigagem ordinária.....	104
4.6.1	Semi-variogramas	104
4.6.2	Validação	107
4.7	Mapas de predição.....	109
4.7.1	Modelos lineares	109
4.7.2	Krigagem ordinária.....	117
4.7.3	Comparação visual.....	119
5	DISCUSSÃO	121
5.1	Homogeneização da nuvem de pontos	121
5.2	Modelo digital de elevação (DEM)	122

5.3	Perfis de alturas de dossel (CHPs).....	122
5.4	Modelos biométricos com variáveis ALS.....	124
5.5	Mapas de predição	127
6	CONCLUSÕES.....	129
	REFERÊNCIAS	131
	APÊNDICES	139

RESUMO

Estimativa da biomassa de lenho em povoamentos de *Eucalyptus grandis* baseada em estatísticas do perfil de dossel geradas por escaneamento a laser aerotransportado.

Este trabalho contribui para a evolução dos métodos que lidam com a quantificação de biomassa em plantações florestais em grande escala. Mais especificamente, explora o potencial de novos métodos baseados em sistemas de escaneamento a laser aerotransportado (ALS) que produzem uma representação 3D da estrutura vertical e horizontal acima do solo em plantios de *Eucalyptus* spp. A abordagem assume que a biomassa acima do solo pode ser estimada de forma precisa quando o perfil vertical da altura do dossel e a área basal são bem conhecidos. Assim, quatro questões foram analisadas: (i) se a função de densidade probabilidade Weibull com dois parâmetros (escala α e forma β) consegue descrever com precisão a distribuição vertical de pontos gerada pela tecnologia ALS e gerar um perfil aparente de altura de dossel adequado em plantios de eucalipto; (ii) se quando gerada por tecnologia ALS, a proporção de retornos no subdossel e solo tem relação significativa e positiva com a variável área basal; (iii) qual a qualidade da predição de área basal e de biomassa seca de lenho quando são usadas como variáveis explicativas um percentil baixo de altura da nuvem ALS e o parâmetro de escala da distribuição Weibull ajustada para definir o perfil vertical do dossel; e (iv) qual a qualidade dos mapas de biomassa de lenho de plantios de eucaliptos quando produzidos a partir de dois métodos diferentes, um de interpolação de dados das parcelas de campo (krigagem ordinária) e outro que usa a nuvem de pontos ALS para calibrar as informações das parcelas de campo (regressão linear). Os resultados mostraram que a função Weibull de dois parâmetros ajustou com precisão adequada o perfil das alturas do plantio de eucalipto. Do ponto de vista prático, esse resultado reforça as estratégias de uso dos parâmetros da função Weibull (escala e forma) como métricas que caracterizam adequadamente a estrutura vertical dos povoamentos florestais. A estimativa de área basal em função da proporção de retornos no subdossel e no solo mostrou-se moderada ($R^2 = 0.42$ e $rRMSE = 7.6\%$), sendo necessários mais estudos que investiguem essa relação. As predições de área basal e biomassa do lenho foram aprimoradas em função do parâmetro α da função Weibull, usado como estimador de escala para as alturas do dossel (área basal, $R^2 = 0.77$ e $rRMSE = 4.8\%$ e biomassa do lenho, $R^2 = 0.89$ e $rRMSE = 5.1\%$). As variáveis, percentil 30 e parâmetro de forma (β) da função Weibull, também produziram boas estimativas ($R^2 = 0.82$ para área basal e $R^2 = 0.93$ para biomassa de lenho). Os mapas de predição de biomassa de lenho mostraram-se mais precisos quando derivados a partir de dados ALS ($rRMSE = 5.5\%$ versus 12.7% na interpolação por krigagem ordinária).

Palavras-chave: LiDAR; Área basal; Modelo biométrico; Inventário florestal; Plantações florestais de rápido crescimento

ABSTRACT

Stem biomass estimation of a *Eucalyptus grandis* plantation based on canopy height profile statistics generated by airborne laser scanning.

This work contributes to the evolution of methods dealing with the quantification of biomass in large-scale forest plantations. More specifically, it explores the potential of new methods based on airborne laser scanning systems to produce a 3D representation of the vertical and horizontal structure of above ground *Eucalyptus* spp plantations. The approach assumes that above ground biomass can be precisely estimated when the vertical profile of canopy heights and basal area are well known. Thus, four questions are examined: (i) can the Weibull probability density function (pdf) with two parameters (α scale and β shape) describe accurately the vertical distribution of points generated by the ALS technology and generate an adequate apparent profile of canopy heights for the eucalyptus plantation?; (ii) when generated by the ALS technology, is the proportion of understory returns to ground returns significantly and positively related with basal area?; (iii) how well are basal area and dry stem biomass predicted by models using low height percentile values of the ALS point cloud and the scale parameter of the Weibull distribution describing the vertical canopy profile?; and (iv) how accurate are stem biomass maps of the eucalyptus plantation when two different methods are used, one based on interpolation that uses sample plots information (ordinary kriging) and another that uses the ALS point cloud to calibrate the sample plot information (linear regression)? The results showed that the Weibull pdf with two parameters fitted with adequate accuracy the plantation's height profiles. From a practical standpoint, this result reinforces the strategies of using the Weibull parameters (scale and shape) as metrics that adequately characterize the vertical structure of forest stands. Basal area estimates derived from the proportion of understory and ground returns presented only moderated accuracy ($R^2 = 0.42$ e $rRMSE = 7.6\%$) and more research is needed to investigate such relationship. Good results were obtained when basal area and stem biomass were fitted as a function of the Weibull α parameter, as a proxy for the scale of canopy heights (basal area, $R^2 = 0.77$ e $rRMSE = 4.8\%$, and stem biomass, $R^2 = 0.89$ and $rRMSE = 5.1\%$). The explanatory variables percentile 30 and the Weibull shape parameter (β) also produced good estimates ($R^2 = 0.82$ for basal area and $R^2 = 0.93$ for stem biomass). Stem biomass prediction maps showed to be more accurate when derived from ALS data ($rRMSE = 5.5\%$ against 12.7% derived from ordinary kriging interpolation).

Keywords: LiDAR; Basal area; Biometric model; Forest inventory; Fast-growing forest plantations

LISTA DE FIGURAS

- Figura 1 – Marco lógico da evolução proposta neste trabalho, com destaque para o problema (suas causas e consequências), e a solução investigada (com descrição das ações que justificam os objetivos específicos deste trabalho). ALS = *Airborne Laser Scanning* (escaneamento a laser aerotransportado). 30
- Figura 2 – Esquema básico do funcionamento de um sistema de escaneamento a laser aerotransportado. Em “a” ilustram-se vários feixes emitidos do avião (o escaneamento) enquanto que em “b” visualiza-se um único feixe. Fonte: adaptado de Reutebuch; Andersen e McGaughey (2005), e Diaz (2011). 36
- Figura 3 – Representação em três dimensões de nuvens de pontos ALS. Software de visualização utilizado: Fusion LiDAR Data Viewer (McGAUGHEY, 2013). 37
- Figura 4 – Perfis verticais de dossel (CHP). Os histogramas representam a distribuição das alturas observadas na nuvem de pontos ALS. As linhas representam funções de densidade probabilidade ajustadas para representação teórica dos dados observados. Fonte: adaptado de Wasser et al. (2013). 41
- Figura 5 – Localização da área experimental “Eucflux” ao norte do município de Itatinga-SP (a). A área está compreendida entre as coordenadas projetadas UTM (zona 22S) leste: 731750 e 733750 e norte: 7457500 e 7459500. 46
- Figura 6 – Parcelas experimentais do projeto Eucflux. Parcelas de 1 a 12 (azuis) inicialmente acomodaram 84 árvores cada, com área aproximada de 504 m². As parcelas 13 a 23 (vermelhas) foram implantadas com 144 árvores cada, sendo sua área hipotética de 864 m². 47
- Figura 7 – Parcelas de validação. Parcelas de número 10 a 18, 26 a 37 (verdes) inicialmente acomodaram 40 árvores cada, com área aproximada de 240 m². Os polígonos de fundo branco e com contorno preto são as parcelas experimentais (ver também Figura 6). 51
- Figura 8 – Faixas de sobrevoo resultantes do escaneamento a laser na área de estudo. Fonte: Esteio Engenharia e Aerolevantamentos S.A. (2009). 53
- Figura 9 – Algoritmo de Kraus e Pfeifer (1998) para classificação de retornos de solo. 55

- Figura 10 – Fluxograma de processamento da nuvem de pontos ALS. Os comandos de linha utilizados do software Fusion e MCC-LiDAR são mostrados entre parênteses. Na coluna da direita: a = nuvem ALS bruta; b= retornos classificados como solo; c = Modelo Digital de Elevação; d = ilustração do conceito de normalização; e = banco de dados contendo as métricas extraídas para a área de interesse..... 57
- Figura 11 – Percentil 90 extraído de uma parcela da área de estudo. Fonte: adaptado de Alvares et al. (2013b). 58
- Figura 12 – Esquema ilustrativo da métrica de proporção $p\_understory$. Ela representa a porcentagem de pontos da nuvem no estrato entre 0.3 metros e 15 metros em relação a todos os retornos existentes entre 0 metro (pontos de solo) e 15 metros. 58
- Figura 13 – Função de densidade probabilidade Weibull de acordo com diferentes valores do parâmetro de forma (β). O parâmetro de escala (α) foi fixado em um valor igual a 20. 62
- Figura 14 – Função de densidade probabilidade Weibull de acordo com diferentes valores do parâmetro de escala (α). O parâmetro de forma (β) foi fixado em um valor igual a 3.5. 63
- Figura 15 – Densidade de retornos da nuvem ALS sobre a área experimental Eucflux, antes e após o processamento de desbaste (remoção aleatória ou *raleamento*) dos pontos. 78
- Figura 16 – Diferença de altitude do Modelo Digital de Elevação originado a partir da filtragem da nuvem ALS com o algoritmo de Kraus e Pfeifer (1998) e Modelo Digital de Elevação derivado da nuvem classificada com o algoritmo de Evans e Hudak (2007). 79
- Figura 17 – Modelo Digital de Elevação (DEM) – 2D (acima) e 3D (em baixo) gerados a partir da nuvem ALS classificada com o algoritmo *Multiscale Curvature Classification* - MCC (EVANS; HUDAK, 2007). 80
- Figura 18 – Modelo Digital de Elevação sombreado (*hillshade*), com 1 metro de resolução. Azimute da fonte de iluminação igual a 315° e ângulo de inclinação acima do horizonte igual a 45°. 81
- Figura 19 – Perfis aparentes de alturas de dossel (CHPs). O eixo vertical (y) mostra as alturas dos retornos da nuvem e o eixo horizontal (x) ilustra a densidade probabilidade de ocorrência dos pontos em cada classe de altura. As linhas sólidas representam funções de densidade probabilidade Weibull ajustadas para os dados empíricos de altura da nuvem ALS. 82

- Figura 20 – Gráfico do tipo QQ_plot (quantil a quantil) por parcela experimental, entre quantís observados de altura na nuvem ALS e quantís teóricos das funções de densidade probabilidade Weibull..... 83
- Figura 21 – Relação de área basal e biomassa do lenho com variáveis predictoras ALS. As parcelas experimentais estão indicadas no interior de cada painel. 87
- Figura 22 – Área basal regredida em P30 e b_CHP (modelo 1). Valores preditos com intervalo de predição (95% confiança) *versus* valores observados (painel superior esquerdo), normalidade de resíduos (superior direito), homoscedasticidade (inferior esquerdo), e independência de resíduos (inferior direito)..... 90
- Figura 23 – Área basal em função da variável a_CHP (modelo 3). O painel superior esquerdo da figura mostra os valores preditos pelo modelo com seus respectivos intervalos de predição (95% de confiança) *versus* os valores observados. Os outros painéis ilustram: normalidade de resíduos (superior direito), homoscedasticidade (inferior esquerdo) e independência dos erros aleatórios (inferior direito)..... 91
- Figura 24 – Área basal com variáveis explicativas a_CHP e densidade de árvores (modelo 8). Valores preditos com intervalo de predição (95% confiança) *versus* valores observados (painel superior esquerdo), normalidade de resíduos (superior direito), homoscedasticidade (inferior esquerdo) e independência de resíduos (inferior direito)..... 92
- Figura 25 – Raiz quadrada da área basal predita pelo logaritmo natural de P30 e b_CHP não transformado (modelo 6). O painel superior esquerdo ilustra os valores preditos para raiz quadrada da área basal com seus respectivos intervalos de predição (95% de confiança) *versus* os valores observados. O painel direito superior mostra a distribuição dos resíduos, enquanto que os painéis inferiores expressam homoscedasticidade (esquerda) e independência de resíduos (direita)..... 93
- Figura 26 – Biomassa de lenho regredida sobre P30 e b_CHP (modelo 9). Os painéis ilustram: valores preditos com intervalo de predição (95% confiança) *versus* valores observados (superior esquerdo), normalidade de resíduos (superior direito), homoscedasticidade (inferior esquerdo), e independência dos erros aleatórios (inferior direito). 96

- Figura 27 – Biomassa do lenho em função da variável a_CHP (modelo 10). O painel superior esquerdo da figura mostra os valores preditos e os intervalos de predição (95% de confiança) *versus* valores observados. Os outros painéis ilustram: normalidade de resíduos (superior direito), homoscedasticidade (inferior esquerdo) e independência dos erros aleatórios (inferior direito). 97
- Figura 28 – Modelo de biomassa do lenho com variáveis explicativas a_CHP e densidade de fustes (modelo 17). Valores preditos e intervalos de predição (95% de confiança) *versus* valores observados (painel superior esquerdo), normalidade de resíduos (superior direito), homogeneidade de dispersão dos erros aleatórios (inferior esquerdo) e independência de resíduos (inferior direito). 99
- Figura 29 – Modelo do logaritmo natural de biomassa do lenho e variáveis explicativas de logaritmo natural de $P30$ e raiz quadrada do parâmetro de forma da fdp Weibull (b_CHP) (modelo 13). Valores preditos e intervalos de predição (95% de confiança) *versus* valores observados (painel superior esquerdo), normalidade de resíduos (superior direito), homoscedasticidade (inferior esquerdo) e independência dos erros aleatórios (inferior direito). 100
- Figura 30 – Área basal nas parcelas de validação: predito e observado. Dados observados foram coletados com um ano de antecedência ao aerolevanteamento LiDAR. $nRMSE$ = raiz do erro quadrático médio normalizado, e cor = coeficiente de correlação linear de Pearson (ρ). 103
- Figura 31 – Biomassa do lenho nas parcelas de validação: predito e observado. Dados observados foram coletados com um ano de antecedência ao aerolevanteamento LiDAR. $nRMSE$ = raiz do erro quadrático médio normalizado, e cor = coeficiente de correlação linear de Pearson (ρ). 104
- Figura 32 – Semi-variograma empírico e teórico (Gaussiano) para a variável de interesse área basal. Os pontos do semi-variograma representam o número de pares observados na classe k 105
- Figura 33 – Semi-variograma empírico e teórico (Gaussiano) para a variável de interesse biomassa do lenho. Os pontos do semi-variograma representam o número de pares observados na classe k 106

Figura 34 – Área basal e biomassa do lenho nas parcelas de validação: interpolado e observado. Dados das parcelas de validação foram coletados com um ano de antecedência aos dados utilizados para interpolação por krigagem ordinária. nRMSE = raiz do erro quadrático médio normalizado, e cor = coeficiente de correlação linear de Pearson (ρ).	109
Figura 35 – Variáveis explicativas: Percentil 30 (P30), parâmetros de escala (a_CHP) e forma (b_CHP) da função de densidade probabilidade Weibull ajustada para as alturas dos retornos da nuvem ALS.	110
Figura 36 – Mapas de predição de área basal em função das variáveis de Percentil 30 (P30) e parâmetro de forma da distribuição Weibull (b_CHP) (modelo 6).	112
Figura 37 – Mapa de predição de área basal em função da variável parâmetro de escala da distribuição Weibull (a_CHP) (modelo 3).	113
Figura 38 – Mapas de predição de biomassa do lenho em função das variáveis de Percentil 30 (logaritmo natural de P30) e do parâmetro de forma da distribuição Weibull (raiz quadrada de b_CHP) (modelo 13).	114
Figura 39 – Mapa de predição de biomassa do lenho em função da variável parâmetro de escala da distribuição Weibull (a_CHP) (modelo 10).	116
Figura 40 – Mapa de predição de área basal resultante da interpolação dos dados das parcelas experimentais de campo pelo método da krigagem ordinária. As cruzes em branco representam o ponto centroide de cada parcela experimental.....	117
Figura 41 – Mapa de predição de biomassa de lenho resultante da interpolação dos dados das parcelas experimentais de campo pelo método da krigagem ordinária. As cruzes em branco representam o ponto centroide de cada parcela experimental.....	118
Figura 42 – Mapas de predição de área basal. À esquerda mapa de predição com base no parâmetro de escala da distribuição Weibull ajustada para o perfil vertical da floresta aos 6.5 anos de idade. No meio, a área basal obtida a partir de censo dos DAPs para floresta aos 5.5 anos de idade. À direita, mapa de predição resultante da krigagem ordinária com dados das parcelas experimentais de campo.....	120
Figura 43 – Distribuição de DAPs e alturas totais (H) nas parcelas experimentais da área de estudo. No <i>boxplot</i> de DAPs, o eixo x foi ordenado em ordem decrescente pelo critério da mediana.....	142
Figura 44 – Modelo hipsométrico entre logaritmo natural da altura total (H) e inverso do DAP utilizado para predição das alturas totais nas parcelas de validação.....	143

- Figura 45 – Distribuição de DAPs observadas e alturas totais (H) preditas nas parcelas de validação no site experimental. No *boxplot* de DAPs, o eixo x foi ordenado em ordem decrescente pelo critério da mediana. 144
- Figura 46 – Mapa de declividade da área de estudo com resolução espacial de 50 metros. . 145

LISTA DE TABELAS

Tabela 1 – Equação específica desenvolvida para predição de biomassa seca do lenho no projeto Eucflux. Nível de significância < 0.0001. RMSE = raiz do erro quadrático médio.....	49
Tabela 2 – Resumo do inventário nas parcelas experimentais.	49
Tabela 3 – Resumo do inventário nas parcelas de validação.	52
Tabela 4 – Parâmetros do sobrevoo ALS no site experimental.....	53
Tabela 5 – Parametrização utilizada para classificação dos retornos de solo da nuvem ALS.	55
Tabela 6 – Descrição matemática das métricas extraídas da nuvem de pontos para modelagem de área basal e biomassa do lenho.	59
Tabela 7 – Estatísticas de densidade de retornos: nuvem bruta e nuvem desbastada.	78
Tabela 8 – Estatísticas resultantes do processamento da nuvem de pontos nas 23 parcelas experimentais da área de estudo Eucflux.	84
Tabela 9 – Matriz de correlação do coeficiente de Pearson (ρ) entre as variáveis preditoras pré-selecionadas.	85
Tabela 10 – Teste de correlação de Pearson para os atributos de interesse (Y) e variáveis ALS (X). Número de graus de liberdade = 21; nível de confiança = 99%.....	86
Tabela 11 – Modelos lineares de área basal dependentes de variáveis explicativas ALS, com $n = 22$ e $p\_valor < 0.001$. Os valores dentro de parênteses representam o desvio padrão para os parâmetros estimados do modelo.....	89
Tabela 12 – Área basal em função do parâmetro de escala da fdp Weibull (a_CHP) ajustada para as alturas do retornos da nuvem ALS e da variável densidade de fustes, com $n = 22$ e $p\_valor < 0.001$. Os valores dentro de parênteses representam o desvio padrão para os parâmetros estimados do modelo.....	92
Tabela 13 – Testes de hipótese sobre modelos de área basal: normalidade de resíduos estudentizados (Shapiro-Wilk), homoscedasticidade de resíduos estudentizados (Breusch-Pagan) e independência de resíduos não transformados (Durbin-Watson). Os valores de W, BP e DW são as estatísticas obtidas para os respectivos testes...	94
Tabela 14 – Modelos lineares de biomassa do lenho em função dos preditores ALS, com $n = 22$ e $p\_valor < 0.001$. Os valores dentro de parênteses representam o desvio padrão para os parâmetros estimados do modelo.	95

Tabela 15 – Biomassa do lenho em função do parâmetro de escala da fdp Weibull (a_{CHP}) para perfil de altura de dossel (CHP) e da variável densidade de fustes, com $n = 22$ e $p_{\text{valor}} < 0.001$. Os valores dentro de parênteses representam o desvio padrão para os parâmetros estimados do modelo.	98
Tabela 16 – Testes de hipótese sobre modelos de biomassa do lenho: normalidade de resíduos estudentizados (Shapiro-Wilk), homoscedasticidade de resíduos estudentizados (Breusch-Pagan) e independência de resíduos não transformados (Durbin-Watson). Os valores de W, BP e DW são as estatísticas obtidas para os respectivos testes.	101
Tabela 17 – Validação cruzada <i>leave-one-out</i>	101
Tabela 18 – Estatísticas de predição para área basal e biomassa do lenho sobre o conjunto de dados de validação.	102
Tabela 19 – Validação cruzada para krigagem ordinária realizada com base nas parcelas experimentais de campo.	107
Tabela 20 – Estatísticas de interpolação por krigagem ordinária para área basal e biomassa do lenho sobre o conjunto de dados de validação.	108
Tabela 21 – Estatísticas de área basal, biomassa do lenho e volume obtidos nas parcelas experimentais da área de estudo, e dos mapas de predição gerados pelos modelos lineares de regressão e por krigagem ordinária.	119
Tabela 22 – Atributos de interesse para as 23 parcelas experimentais da área de estudo.	141
Tabela 23 – Resultados de inventário florestal para as 21 parcelas de validação.	143
Tabela 24 – Número de retornos ALS por classe de altura.	146

LISTA DE SIGLAS

3D	– <i>Three Dimensional</i> (três dimensões)
AIC	– <i>Akaike Information Criterion</i> (critério de informação de Akaike)
ALS	– <i>Airborne Laser Scanning</i> (escaneamento a laser aerotransportado)
CHP	– <i>Canopy Height Profile</i> (perfil de altura de dossel)
DEM	– <i>Digital Elevation Model</i> (modelo digital de elevação)
DTM	– <i>Digital Terrain Model</i> (modelo digital de terreno)
FOV	– <i>Field of View</i> (campo de varredura)
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)
LiDAR	– <i>Light Detection and Ranging</i> (detecção e distanciamento da luz)
LOOCV	– <i>Leave-one-out Cross Validation</i> (validação cruzada)
MAD	– <i>Mean Absolute Deviation</i> (desvio absoluto médio)
MLE	– <i>Maximum Likelihood Estimation</i> (estimação pela máxima verossimilhança)
OLS	– <i>Ordinary Least Squares</i> (mínimos quadrados ordinários)
RMSE	– <i>Root Mean Square Error</i> (raiz do erro quadrático médio)
TPS	– <i>Thin Plate Spline</i>
VIF	– <i>Variance Inflation Factor</i> (fator de inflação da variância)

1 INTRODUÇÃO

Este trabalho procura contribuir para o processo evolutivo dos métodos de quantificação e qualificação da biomassa de extensas áreas cobertas por plantios florestais. Mais especificamente, explora o potencial de novos métodos baseados em tecnologias laser aerotransportadas de reproduzir tridimensionalmente a estrutura vertical e horizontal acima do solo de plantios de *Eucalyptus* spp na escala da paisagem.

Nesse sentido, as próximas seções contextualizam e procuram justificar a importância deste estudo, e argumentam em favor de uma evolução dos métodos usados para estimar parâmetros biométricos florestais. Para isso, e após uma breve descrição do segmento de florestas plantadas e da importância dos plantios de eucaliptos como fonte essencial de matéria prima para esse setor, são apresentados os principais conceitos relativos à tecnologia de escaneamento a laser aerotransportado, assim como as relações que os dados gerados por esse instrumento têm com certos parâmetros florestais de grande interesse para o gestor florestal.

1.1 Setor de florestas plantadas

Em termos de representação de uso e ocupação do solo, o Brasil conta com aproximadamente uma área de 477.7 milhões de hectares de florestas naturais (56% do território brasileiro) e 7.18 milhões de hectares de florestas plantadas, sendo as culturas dos gêneros *Pinus* (1.56 milhões ha) e *Eucalyptus* (5.1 milhões ha), responsáveis por 92.8% deste total (ASSOCIAÇÃO BRASILEIRA DE PRODUTORES DE FLORESTAS PLANTADAS – ABRAF, 2013).

Apesar do baixo percentual de área ocupada pelos plantios florestais em relação às florestas nativas, os primeiros são importantes porque ajudam a reduzir a pressão de desmatamento sobre os últimos. As plantações florestais de pinus e eucalipto no Brasil possuem as maiores taxas de crescimento volumétrico entre os países considerados florestais: $35 \text{ m}^3.\text{ha}^{-1}.\text{ano}^{-1}$ e $40 \text{ m}^3.\text{ha}^{-1}.\text{ano}^{-1}$, respectivamente (GONÇALVES et al. 2013; ABRAF, 2013).

Em 2012, o valor bruto da produção de florestas plantadas (VBPF) foi equivalente a BRL 53 bilhões e representou um aumento de 4.6% em relação ao ano de 2011. O VBPF em 2012 correspondeu a uma fração de 1.2% do Produto Interno Bruto (PIB) e contribuiu para a

geração de 4.4 milhões de empregos (0.6 milhão diretos, 1.3 milhão indiretos e 2.4 milhões decorrentes do efeito-renda) (ABRAF, 2013).

De acordo com ABRAF (2011), o mercado de florestas plantadas no Brasil tem vivenciado uma nova fase de crescimento econômico, com importância em escala internacional.

Contribuem para esse cenário os seguintes fatores: expansão da base florestal; consolidação do processo de desenvolvimento tecnológico da produção; e acirramento da competição externa e interna entre grandes companhias e empreendimentos florestais.

Um exemplo de acirramento do mercado é a deterioração da competitividade dos produtos florestais brasileiros frente aos concorrentes internacionais. No início da corrente década o Brasil possuía o *status* de menor custo de produção da madeira de processo, e que atualmente, já é superado por Rússia, Indonésia e Estados Unidos (ABRAF, 2013).

1.2 Biometria florestal

A biometria é o setor das ciências florestais que lida com as atividades de mensuração, qualificação e quantificação da biomassa florestal. Conhecer o estoque da floresta e projetar o seu crescimento é imprescindível para o bom planejamento e manejo dos recursos de produção disponíveis (ABREU et al., 2002).

Os atuais métodos de inventário são embasados em levantamentos de campo, cuja coleta de dados remete principalmente à mensuração de diâmetro, altura e forma dos indivíduos arbóreos de uma floresta (CAMPOS; LEITE, 2013).

A partir dessas informações, constroem-se modelos estatísticos capazes de quantificar informações inerentes ao povoamento florestal como, por exemplo, área basal e volume de madeira (SCHUMACHER; HALL, 1933; SOARES; LEITE; GORGENS, 2005).

A intensidade amostral das parcelas em campo é dimensionada para equilibrar os custos de mensuração da floresta e a obtenção de boas estimativas da variável de interesse (FREESE, 1976).

Uma premissa importante deste processo é que a unidade de manejo é vista como uma parte homogênea e indivisível. O produto final é uma estimativa do todo, na área amostrada (PELISSARI, 2012).

Por outro lado, quando se deseja conhecer a variabilidade espacial de um atributo florestal, uma alternativa é o uso de ferramentas e conceitos da geoestatística (CHILÈS; DELFINER, 1999).

A partir das informações coletadas em campo, interpolam-se as informações de interesse para áreas não amostradas. O produto final é um mapa que representa toda a variabilidade existente em uma dada área de manejo.

A informação espacial tem utilidade quando é aproveitada no âmbito da silvicultura de precisão e do manejo da paisagem (BRANDELERO; ANTUNES; GIOTTO, 2007; RIBEIRO, 2002). Os recursos de produção podem ser mais bem alocados dentro de cada unidade de manejo, melhorando a eficiência de uso (VETTORAZZI; FERRAZ, 2000).

Uma limitação das técnicas de interpolação utilizando-se apenas mensurações provenientes do campo é que muitas vezes a intensidade amostral é insuficiente para produzir estimativas precisas e acuradas (VIANA et al., 2012).

Na prática, mesmo quando há indícios estatísticos de que seria necessário aumentar o número de parcelas amostrais para reduzir o erro amostral, isso acaba não acontecendo por razões de custo e tempo (RODRIGUEZ et al., 2010).

1.3 Potencial evolutivo das técnicas de quantificação da biomassa florestal

São necessários métodos que representem espacialmente com maior precisão os atributos quantitativos florestais extraídos de processos amostrais baseados em parcelas de campo. A Figura 1 oferece uma representação gráfica da abordagem lógica deste trabalho adotada para atender a essa necessidade.

Essa representação se baseia na construção de marco lógico de estruturação de projetos de pesquisa (INTERNATIONAL TROPICAL TIMBER ORGANIZATION - ITTO, 2009) e que sugere a clara definição do problema, suas causas e consequências, para que a solução, com suas ações e efeitos, possa também ser claramente expressa.

Figura 1 – Marco lógico da evolução proposta neste trabalho, com destaque para o problema (suas causas e consequências), e a solução investigada (com descrição das ações que justificam os objetivos específicos deste trabalho). ALS = *Airborne Laser Scanning* (escaneamento a laser aerotransportado).

Basicamente, este trabalho procura contribuir para a melhoria da precisão dos métodos de estimação e representação espacial de parâmetros quantitativos que caracterizam povoamentos florestais em extensas áreas.

A qualidade não satisfatória dos métodos atuais se deve a baixa intensidade amostral dos inventários de campo e que acarreta na necessidade do uso de técnicas de interpolação para representação espacial dos atributos de interesse. Ademais, levantamentos baseados no campo são mais efetivos em medições que remetem as variáveis de subdossel como diâmetro a altura do peito (DAP) e área basal, as quais são de difícil mensuração por sensores remotos aéreos ou orbitais.

A proposta de melhoria se resume a explorar os benefícios potenciais disponibilizados pelas modernas técnicas de escaneamento a laser aerotransportado (*Airborne Laser Scanning* – ALS). Especificamente, este trabalho se propõe a quantificar atributos florestais de interesse por meio de modelos dependentes de variáveis capazes de representar de forma detalhada a estrutura vertical do povoamento florestal. Os dados remotos ALS estão disponíveis em 100% da área, e por isso as variáveis de interesse podem ser preditas e espacialmente desenhadas sem necessidade de interpolação dos dados de campo.

1.4 Objetivos

O objetivo geral deste trabalho é contribuir para a evolução dos métodos de estimação de atributos quantitativos que caracterizam a biomassa de plantios florestais. Para tanto, explora-se o potencial estimativo de métricas ALS como preditoras desses atributos de interesse nesses plantios.

Pontualmente, citam-se os seguintes objetivos específicos:

- Representar a distribuição empírica das alturas dos retornos provenientes da nuvem ALS por meio de funções de densidade probabilidade Weibull.
- Avaliar a existência de correlação entre a variável de interesse área basal e a quantidade de pontos laser incidentes na região do estrato inferior do povoamento florestal.
- Ajustar modelos de regressão linear com base em variáveis explicativas provenientes da nuvem tridimensional de pontos.
- Comparar os mapas de predição para as variáveis de interesse área basal e biomassa do lenho resultantes dos modelos de regressão com estatísticas provenientes da nuvem ALS, com os mapas de predição resultantes de interpolação das informações de campo pela técnica de krigagem ordinária.

As próximas seções apresentam as hipóteses deste trabalho e uma revisão dos principais conceitos que ajudam a compreender a potencial utilidade das novas tecnologias ALS para a melhoria evolutiva dos métodos de estimação de parâmetros quantitativos florestais.

1.5 Hipóteses

As hipóteses da pesquisa são:

- A função de densidade probabilidade Weibull com dois parâmetros (escala α e forma β) descreve a distribuição vertical dos pontos gerados pela tecnologia ALS e gera precisos perfis aparentes de altura de dossel em plantios de eucalipto.
- Em dados provenientes de aerolevantamento com escaneamento a laser sobre povoamentos equiânicos, a relação da proporção de pontos no subdossel com pontos de solo têm relação significativa e positiva com área basal.
- Área basal e biomassa seca do lenho de plantios de eucalipto podem ser estimadas a partir da sua relação com estatísticas da nuvem ALS, como por exemplo, os parâmetros de escala (α) e forma (β) da distribuição Weibull que define e sintetiza o perfil vertical aparente do dossel.
- As representações espaciais de área basal e biomassa do lenho de plantios de eucalipto estimadas a partir de parcelas amostrais são mais precisas quando complementadas com dados da tecnologia ALS do que quando baseadas em métodos de interpolação.

2 REVISÃO BIBLIOGRÁFICA

A seguir listam-se os tópicos de revisão de literatura mais diretamente relacionados com o escopo da dissertação. O primeiro item é uma contextualização da tecnologia de escaneamento a laser aerotransportado (*Airborne Laser Scanning* - ALS)¹. Nele estão descritos os principais componentes que compõe um sistema ALS, como eles funcionam, propriedades do escaneamento e configurações de parâmetros de um sobrevoo. O segundo tópico aborda o conceito de perfil aparente de altura de dossel e como ele pode ser mensurado com a tecnologia ALS.

2.1 Tecnologia de escaneamento a laser aerotransportado (ALS)

O acrônimo LASER (*Light Amplification by Stimulated Emission of Radiation*), em português, significa a “amplificação da luz por emissão estimulada de radiação”. O laser tem característica monocromática (comprimento de onda bem definido) e por isso pode ser propagado como um feixe de luz unidirecional.

Na área de sensoriamento remoto os tipos mais comuns de laser utilizados são aqueles com comprimento de onda próximo do azul/verde (532 nanômetros) para estudos batimétricos e o laser com comprimento de onda próximo ao infravermelho (1064 nanômetros). Esse último é o mais utilizado em aerolevantamentos para estudos de vegetação.

Sensores remotos de escaneamento a laser são classificados como ativos porque emitem energia eletromagnética própria sobre os alvos. Esta característica confere aos sensores ativos, a vantagem da produção de informações com propriedades tridimensionais. Além disso, os sensores de varredura a laser podem operar durante o período noturno.

O avanço das ciências de física ótica, transmissão remota de dados e da informática tem tornado a tecnologia de escaneamento a laser aerotransportado cada vez mais acessível para o uso em aplicações florestais (REUTEBUCH; ANDERSEN; McGAUGHEY, 2005).

Os equipamentos que compõem um sistema ALS são: a) unidade de emissão e recebimento a laser acoplado à aeronave; b) unidades de posicionamento global (GPS) no avião e no solo; c) sensor inercial acoplado à unidade laser para mensuração de movimentos

---

¹ Na literatura em português a palavra “*airborne*” tem sido traduzida como “aerotransportado” e “aero embarcado”. Da mesma forma, para o termo “*scanning*” têm-se as traduções de “escaneamento”, “varredura” e “perfilamento”. Neste trabalho optou-se pelo uso dos termos “aerotransportado” e “escaneamento”.

do avião: rolamento, arfada e guinada e; d) um computador para controlar e armazenar os dados do levantamento (Figura 2).

Figura 2 – Esquema básico do funcionamento de um sistema de escaneamento a laser aerotransportado. Em “a” ilustram-se vários feixes emitidos do avião (o escaneamento) enquanto que em “b” visualiza-se um único feixe. Fonte: adaptado de Reutebuch; Andersen e McGaughey (2005), e Diaz (2011).

Um sistema laser pode armazenar as informações em formato de ondas completas (*full waveform*) e por retornos discretos (*discrete return*), sendo que a última opção é a forma mais comum. Segundo Rodriguez et al. (2010), os retornos discretos resultam de pulsos emitidos com certa frequência e que formam uma série discreta (não contínua) de emissões e retornos.

Os atuais escaneadores a laser podem emitir até 530 mil pulsos de luz por segundo, iluminando qualquer superfície que se interponha no seu caminho (RIEGL LASER MEASUREMENT SYSTEMS). A frequência de emissão é um dos componentes de maior importância para o sucesso da tecnologia ALS.

O tempo entre a emissão de um pulso laser, interceptação e reflexão por um objeto, e o seu retorno ao equipamento sensor é utilizado para estimar a distância entre o alvo e a aeronave.

Atribui-se a cada ponto² refletido, uma coordenada geográfica coletada por meio dos equipamentos de posicionamento global (ex: GPS) presentes na aeronave e no solo. O sistema de medição inercial (IMU) realiza as correções em x, y e z dos desvios provocados por movimentos de rolamento, arfada e guinada da aeronave. Como produto deste conjunto tem-se a nuvem tridimensional de pontos georreferenciada (Figura 3).

Figura 3 – Representação em três dimensões de nuvens de pontos ALS. Software de visualização utilizado: Fusion LiDAR Data Viewer (McGAUGHEY, 2013).

Outras propriedades importantes do sistema laser podem ser citadas: ângulo de visada (FOV- *Field of View*), frequência de escaneamento, altura e velocidade do sobrevoo, divergência do feixe e *footprint*.

O ângulo de visada do equipamento de escaneamento a laser é o intervalo fora do nadir no qual o equipamento consegue emitir e receber pulsos de forma consistente. As propriedades de ângulo de visada e altura de sobrevoo resultam na largura da faixa de

---

² Um ponto (ou retorno, ou *hit*) nem sempre é equivalente a um pulso. O pulso pode originar mais do que um retorno quando partes de um mesmo feixe incidem sobre objetos diferentes.

cobertura do aerolevantamento. Quanto maior o ângulo de visada e maior a altura do voo, maior será a largura da faixa.

A frequência de escaneamento, frequência de emissão do pulso, altura do sobrevoo, velocidade da aeronave e propriedades inerentes ao alvo, estão relacionados com a quantidade de pontos resultantes por unidade de área em uma determinada nuvem. A densidade de pontos aumenta principalmente com o aumento da frequência de varredura a laser, com o aumento da frequência de emissão do pulso e com a diminuição da altura e diminuição da velocidade de sobrevoo.

A densidade de retornos também pode ser alterada de acordo com a complexidade e permeabilidade vertical da paisagem. Por exemplo, existirão mais pontos refletidos em uma área com cobertura florestal do que em uma pastagem, se mantidas todas as outras propriedades do escaneamento constantes.

A propriedade de *footprint* (ou pegada) é o diâmetro com que um feixe de luz laser chega ao solo. Quanto maior a divergência do feixe e altura de sobrevoo, maior o *footprint* (Figura 2).

As funções básicas de um sistema de escaneamento a laser aerotransportado e as configurações de sobrevoo podem ser devidamente planejadas por meio de relações matemáticas entre as propriedades descritas (BALTSAVIAS, 1999).

No contexto florestal, a tecnologia ALS vem sendo utilizada sob dois propósitos principais:

- Para construção de Modelos Digitais de Elevação (DEMs).
- Para qualificação e quantificação da biomassa florestal.

Modelos digitais de elevação (DEMs) são também conhecidos como modelos digitais de terreno (DTMs) (BEHRENDT, 2012). A principal vantagem de se obter um DEM com a tecnologia ALS é o menor custo de produção em relação às técnicas de agrimensura convencionais (BERNARDI, 2012; VENTURI, 2012).

Com relação à quantificação e qualificação da biomassa florestal, a tecnologia ALS tem utilidade porque fornece inúmeras variáveis independentes (métricas) que podem ser testadas e modeladas juntamente com outros atributos de interesse da floresta (NAESSET, 2002).

Um modelo gerado a partir de estatísticas do conjunto de pontos LiDAR³ tem a vantagem de poder ser extrapolado espacialmente para toda a área compreendida pela nuvem, desde que o conjunto esteja devidamente representado nas amostras.

A modelagem de variáveis florestais com uso da tecnologia ALS envolve duas abordagens principais (VASTARANTA, 2012):

- i) Baseada em árvore, em que as estatísticas são computadas considerando-se cada árvore separadamente.
- ii) Baseada em área (ou povoamento), onde as informações são representadas por um conjunto indivisível de árvores (parcela).

As métricas provenientes de uma nuvem de pontos podem ser classificadas de acordo com três grandes grupos: métricas topográficas, métricas de intensidade e métricas de altura. Como exemplo de métricas topográficas, citam-se as seguintes: declividade do terreno e aspecto da face (direção da face). Métricas de intensidade dizem respeito ao conjunto de estatísticas relacionadas à quantidade de energia refletida pelo feixe laser em cada objeto interceptado. O grupo de métricas de altura engloba o portfólio de estatísticas mais frequentemente utilizadas para quantificação e qualificação da biomassa florestal.

As estatísticas do grupo de altura podem ainda dividir-se em três subcategorias: métricas de posição, métricas de dispersão e métricas de densidade (ou proporção). Métricas de posição são aquelas diretamente relacionadas à mensuração de alturas, como, por exemplo, percentís, alturas mínimas e máximas, mediana da altura e moda da altura. O subgrupo das estatísticas de dispersão é composto por: desvio padrão da altura, variância da altura, curtose, assimetria, desvio absoluto médio (MAD), entre outras métricas. Por último, as estatísticas de densidade (ou proporção) compreendem as razões de quantidades de retornos presentes nos diferentes estratos da nuvem de pontos. Por exemplo: quantidade de pontos acima de 2 metros de altura dividida pela quantidade total de retornos da amostra.

Naesset, (1997a) e Magnussen e Boudewyn (1998) foram pioneiros no uso da tecnologia ALS para modelagem de atributos florestais. Eles obtiveram boas estimativas de altura de árvores por meio da modelagem de métricas de altura ALS.

Além do atributo de altura, variáveis geradas pelo sistema ALS também puderam estimar corretamente o volume, área basal e índice de área foliar em povoamentos florestais, a

---

³ O termo LiDAR (*Light Detection and Ranging*) é utilizado para se referir genericamente ao processo de escaneamento a laser. É uma terminologia mais ampla que ALS, pois engloba além do laser aéreo, o laser terrestre.

partir de modelos calibrados com informações coletadas no campo (MALTAMO; SUVANTO; PACKALÉN, 2007; NAESSET, 1997b; PEDUZZI et al., 2012).

Embora já consolidada em países desenvolvidos, a tecnologia de escaneamento a laser aerotransportado é ainda incipiente no Brasil. Alguns trabalhos desenvolvidos com plantios florestais, nos últimos anos são: Silva (2013), Packalén; Mehtätalo e Maltamo (2011), Oliveira (2011), Zonete; Rodriguez e Packalén (2010), Macedo (2009), Zandoná; Lingnau e Nakajima (2007).

De acordo com Packalén; Mehtätalo e Maltamo (2011) o uso da modelagem de atributos florestais com base nas métricas ALS tem enorme potencial de uso sobre os plantios florestais. Eles estudaram a modelagem de atributos de volume e índice de sítio (IS) em plantios clonais de *Eucalyptus urograndis*, no Estado da Bahia, Brasil. Além de conseguirem boas estimativas para as variáveis de interesse os autores concluíram que os métodos utilizados para modelagem de florestas seminaturais poderiam ser também utilizados para plantios florestais.

2.2 Perfis de alturas de dossel (*Canopy Height Profiles – CHPs*)

Segundo Parker (1995 apud HARDING et al., 2001), a caracterização da estrutura de dossel, pode ser definida como “a organização no espaço e no tempo, incluindo a posição, extensão, quantidade, tipo e conectividade, dos compartimentos da vegetação acima do solo”.

As duas variáveis mais frequentemente utilizadas para caracterizar a estrutura vertical e horizontal de uma área florestal são: fechamento de dossel (porcentagem de cobertura horizontal) e índice de área foliar (IAF) (COOPS et al., 2007).

A quantificação do fechamento de dossel, quando realizada de forma visual pode sofrer com a subjetividade do método e imprecisões nas estimativas obtidas (RHOADS et al. 2004). Por sua vez, a estatística de IAF, apesar de robusta constitui-se na projeção da área foliar em apenas um único plano, sem distinção sobre a sua distribuição no eixo vertical (COOPS et al., 2007).

Os métodos mais tradicionais de mensuração da estrutura do dossel florestal são baseados em levantamentos de campo e em imagens produzidas por sensores passivos⁴. Enquanto os métodos de campo são considerados demorados, laboriosos e caros (COOPS et

---

⁴ Sensores passivos dependem de fontes externas de emissão da energia eletromagnética. São exemplos de sensores passivos: câmeras fotográficas, sensores termais, satélites com receptores multiespectrais, entre outros.

al. 2007; LOVELL et al., 2003), os sensores passivos tem a limitação de coletar informações apenas da parte superficial do dossel (HARDING et al., 2001).

Uma alternativa que vem sendo estudada é o uso da tecnologia de escaneamento a laser aerotransportado (ALS) para caracterização do perfil de alturas de dossel (*Canopy Height Profiles* - CHPs) (COOPS et al., 2007; HARDING et al., 2001; MAGNUSSEN; EGGERMONT; LaRICCIA, 1999). O CHP constitui-se em uma forma quantitativa de representar o perfil vertical da floresta.

A Figura 4 ilustra o que é um CHP e como ele pode ser representado. Nela observam-se os perfis verticais de altura empíricos (histogramas das distribuições observadas) e teóricos (funções probabilísticas) para quatro tipos de vegetação e para duas estações do ano: inverno (sem folhas) e verão (com folhas) (WASSER et al., 2013).

Figura 4 – Perfis verticais de dossel (CHP). Os histogramas representam a distribuição das alturas observadas na nuvem de pontos ALS. As linhas representam funções de densidade probabilidade ajustadas para representação teórica dos dados observados. Fonte: adaptado de Wasser et al. (2013).

É importante mencionar que os perfis de alturas de dossel (CHP) empíricos e teóricos extraídos da nuvem ALS não representam o perfil real do dossel florestal (COOPS et al.,

2007; HARDING et al., 2001; MAGNUSSEN; EGGERMONT; LaRICCIA, 1999). Eles são considerados perfis aparentes. O perfil vertical aparente supõe algumas premissas que objetivam simplificar a estrutura da vegetação: aleatoriedade de distribuição dos componentes arbóreos, angulação uniforme de folhas e ausência de agrupamentos. Em estudos que objetivem a quantificação real da distribuição do dossel por meio da tecnologia ALS deve-se levar em consideração essa diferença.

Resultados das pesquisas de Coops et al. (2007), Harding et al. (2001) e Magnussen; Eggermont e LaRiccia (1999), indicaram a presença de relações significativas entre a distribuição vertical da folhagem mensurada no campo e as distribuições probabilísticas das alturas dos retornos da nuvem de LiDAR aéreo. Eles concluíram que os modelos de distribuição verticais do dossel poderiam ser transferíveis entre mensurações de campo e bases de dados ALS.

Magnussen; Eggermont e LaRiccia (1999) utilizaram dados ALS para propor modelos que recuperassem alturas de árvores de uma floresta secundária de Douglas-fir (*Pseudotsuga menziesii* spp. *menziessi* (Mirb.) Franco). Entre os modelos testados, destacou-se aquele que era baseado na distribuição de probabilidade de penetração do laser no dossel. Para descrever teoricamente o perfil vertical da floresta os autores utilizaram a função de densidade probabilidade Weibull com três parâmetros.

Coops et al. (2007) também utilizaram a tecnologia de escaneamento a laser aerotransportado para estudar e caracterizar a estrutura vertical da floresta. O estudo foi conduzido utilizando-se um sensor ALS com gravação por retornos discretos (0.7 retornos/m²) em seis talhões com predominância das espécies Douglas-fir e cicuta ocidental (*Tsuga heterophylla* (Raf.) Sarg.), com diferentes idades e tipos de estruturas, na costa leste da ilha de Vancouver, Canadá.

Eles utilizaram a distribuição probabilística Weibull com dois parâmetros para modelar o perfil de densidade de folhagem ao longo do dossel. O uso da distribuição Weibull teve o propósito de estabilizar mudanças abruptas na diminuição da ocorrência de retornos (*hits*) em profundidades mais baixas do dossel.

De acordo com Magnussen; Eggermont e LaRiccia (1999) é razoável assumir que um talhão florestal seja composto por diferentes distribuições de altura e não de apenas uma. No entanto, a função teórica é também um meio para se fornecer um sumário conveniente da complexidade do perfil vertical da floresta (COOPS et al., 2007; MAGNUSSEN; EGGERMONT; LaRICCIA, 1999).

Uma vantagem de se utilizar funções probabilísticas para sumarização da estrutura vertical do dossel, é que os parâmetros da função podem ser correlacionados com atributos de interesse do povoamento florestal.

COOPS et al. (2007) verificaram correlação significativa entre os parâmetros da função de densidade probabilidade Weibull com os atributos florestais de diâmetro médio à altura do peito (DAP médio) e densidade de árvores. Mori e Hagiraha (1991) correlacionaram os parâmetros da distribuição Weibull para perfil vertical de dossel mensurado no campo, com a variável de DAP médio, em florestas de cipreste japonês (*Chamaecyparis obtusa* (Sieb. et Zucc.) Endl.).

3 MATERIAL E MÉTODOS

A seção de Material e Métodos foi subdividida em tópicos para facilitar o entendimento da sequência metodológica utilizada. Faz-se um breve relato da área de estudo, descrevem-se os métodos de processamento dos dados de campo, da extração de métricas ALS e do procedimento de geração do modelo digital de elevação (DEM). Detalha-se a metodologia de obtenção do perfil de alturas de dossel (CHP) bem como a rotina para ajuste e seleção de modelos de regressão de área basal e biomassa do lenho. Explicam-se os passos para geração e validação dos mapas de predição sob duas abordagens: i) originados pela extrapolação dos modelos baseados em variáveis ALS e ii) oriundos de interpolação dos dados de campo por krigagem ordinária.

3.1 Área de estudo

A área de estudo está localizada no município de Itatinga, Estado de São Paulo (22°58'04''S; 48°43'40''O). O experimento faz parte de um programa cooperativo do Instituto de Pesquisas e Estudos Florestais (IPEF) e é denominado “Torre de Fluxo” (Eucflux) (www.ipef.br/eucflux) (STAPE; NOUVELLON; LACLAU, 2006) (Figura 5). O clima da região é classificado como Cfa, subtropical sem estação seca e com verão quente, com temperatura média anual de 19.4°C e chuva média anual de 1300 mm (ALVARES et al., 2013a). O relevo do sítio é principalmente plano à suave ondulado e com aproximadamente 750 metros de altitude (CAMPOE, 2012).

A área experimental do projeto Eucflux tem área aproximada de 200 hectares e é composta por um povoamento seminal de *Eucalyptus grandis* (W. Hill ex Maiden) com 6.5 anos de idade. O sítio está inserido na Fazenda Americana, pertencente à empresa florestal Duratex S.A. e que é responsável pelo manejo da floresta.

De acordo com Campoe et al. (2012), o material genético da plantação é proveniente de pomar de sementes por mudas de quarta geração (origem em Coff's Harbour, Austrália). A área de estudo correspondente ao projeto Eucflux foi plantada em dezembro de 2002 adotando-se práticas de preparo de solo em cultivo mínimo (GONÇALVES et al., 2004). O plantio possui espaçamento de 6 m² por planta e arranjo de plantio de 3.75 metros entre linhas e 1.6 metros entre plantas.

Figura 5 – Localização da área experimental “Eucflux” ao norte do município de Itatinga-SP (a). A área está compreendida entre as coordenadas projetadas UTM (zona 22S) leste: 731750 e 733750 e norte: 7457500 e 7459500.

3.2 Processamento dos dados de campo

3.2.1 Parcelas experimentais

A rede de parcelas experimentais do projeto Eucflux é mostrada na Figura 6. São 23 parcelas divididas em dois grupos de acordo com o número de árvores mensuradas:

- Parcelas de 1 a 12 com 84 covas⁵ cada (área aproximada de 504 m²), e;
- Parcelas 13 a 23 com 144 covas por amostra (área aproximada de 864 m²).

⁵ O termo “cova” contempla tanto árvores vivas, como árvores mortas e falhas.

As parcelas de 1 a 12 foram instaladas no campo para atender a demanda de múltiplos projetos de pesquisa do programa cooperativo Torre de Fluxo (STAPE et al., 2008).

A instalação desse grupo de parcelas objetivou amostrar o gradiente de produtividade encontrado na área de estudo, conforme apresentado por Campoe (2012). A produtividade do povoamento foi mensurada por meio da realização de censo de diâmetros à altura de 1.3 metros (diâmetro à altura do peito - DAP).

Por outro lado, as parcelas de número 13 a 23 foram alocadas no campo especificamente para ampliar a rede de parcelas disponíveis para os estudos com a tecnologia de escaneamento a laser aerotransportado (STAPE et al., 2008).

Figura 6 – Parcelas experimentais do projeto Eucflux. Parcelas de 1 a 12 (azuis) inicialmente acomodaram 84 árvores cada, com área aproximada de 504 m². As parcelas 13 a 23 (vermelhas) foram implantadas com 144 árvores cada, sendo sua área hipotética de 864 m².

Os cantos de cada parcela foram georreferenciados com GPS Trimble Pro XRS, depois que a floresta foi colhida, em agosto de 2009. A opção pela coleta das coordenadas geográficas após o abate das árvores objetivou diminuir o erro de medição provocado pela obstrução e interferência das copas.

Com o uso das coordenadas calculou-se a área real do polígono correspondente a cada parcela experimental do projeto (Apêndice A, Tabela 22).

Os dados de inventário de campo foram coletados em julho de 2009. Mensurou-se em cada parcela: *i*) circunferência à altura do peito (CAP, 1.3 metros acima do nível do solo) de todas as árvores, *ii*) altura total em 100% dos indivíduos e *iii*) características qualitativas das árvores, a exemplo de falhas, árvores bifurcadas, árvores mortas, etc.

O CAP de cada indivíduo foi convertido em DAP utilizando-se a equação 1.

$$DAP = \frac{CAP}{\pi} \quad (1)$$

onde:

DAP e CAP = diâmetro e circunferência, respectivamente, mensurados à 1.3 metros de altura com base no nível do solo (cm).

π = constante matemática que representa a razão do perímetro de uma circunferência e o seu diâmetro e que equivale a aproximadamente 3.14159.

Então, calculou-se a área basal da parcela de acordo com a equação 2.

$$G_j = \frac{\pi}{4 * A_j} \sum_{i=1}^n DAP_{ij}^2 \quad (2)$$

onde:

G_j = área basal da parcela j ($m^2 \cdot ha^{-1}$).

DAP_{ij} = diâmetro à altura do peito da árvore i na parcela j (cm).

A_j = área total da parcela j (m^2).

A biomassa seca do lenho (B_i) foi estimada com o uso de uma equação específica para o local, ajustada a partir de cubagem rigorosa de árvores (até altura com diâmetro = 4 cm), em setembro de 2008 (CAMPOE et al., 2012). O modelo ajustado é dependente das variáveis explicativas DAP^2 (D_i^2) e altura total (H_i). (Tabela 1).

Tabela 1 – Equação específica desenvolvida para predição de biomassa seca do lenho no projeto Eucflux. Nível de significância < 0.0001. RMSE = raiz do erro quadrático médio.

Componente	Local da amostra	Modelo	n	R^2	RMSE	Média
	# parcela	biomassa (kg.árvore ⁻¹)	# árvores		(kg.árv ⁻¹)	(kg.árv ⁻¹)
Lenho	7, 8, 9, 10 e 11	$B_i = -0.58 + 147.1 D_i^2 H_i$	20	0.97	9.3	59.4

Fonte: Campoe et al. (2012).

Os dados de inventário foram processados e a informação foi organizada em um banco de dados em formato de planilha eletrônica (Apêndice A, Tabela 22). A Tabela 2 ilustra o resumo descritivo dos dados de inventários das parcelas experimentais. O Apêndice A, Figura 43 ilustra a distribuição empírica dos diâmetros e altura total dos indivíduos nas parcelas de 1 a 23.

Tabela 2 – Resumo do inventário nas parcelas experimentais.

	Sobr. %	Dens. fustes.ha ⁻¹	DAP cm	G m ² .ha ⁻¹	H m	B Mg.ha ⁻¹
Mínimo	82.1	1103	13.1	22.5	21.5	112.6
Média	90.0	1503	14.9	29.8	24.6	155.1
Máximo	96.5	1715	16.6	34.4	27.5	194.7
Desv.pad.	3.9	130	0.96	3.49	1.50	26.56

Sobr. = sobrevivência; Dens. = densidade de fustes; DAP = diâmetro médio à altura do peito; G = área basal; H = altura total média; B = biomassa seca do lenho; Mínimo = parcelas com a menor média; Média = média das parcelas; Máximo = maior valor médio entre parcelas; Desv.pad = desvio padrão entre as médias das parcelas.

A fim de verificar informações discrepantes provenientes das amostras de campo, utilizou-se o teste estatístico de Dixon (também conhecido como teste Q) para detecção de *outliers* nas variáveis de interesse do estudo (DIXON, 1950). A motivação para realização do teste foi a de evitar inconsistências nas extrapolações derivadas dos modelos.

O teste Q calcula a seguinte estatística (eq. 3):

$$Q = \frac{x_3 - x_1}{x_{n-2} - x_1} \quad (3)$$

onde:

Q = estatística Q para tamanho de amostra (n) igual ou maior do que 15 e variância da população desconhecida.

n = tamanho da amostra.

x_1 e x_{n-2} = menor e terceiro maior valores no vetor de dados, respectivamente.

A estatística Q é uma razão de subintervalos na amostra ordenada e a sua distribuição é assumida como sendo desenhada da mesma população normal. Se Q for maior do que o valor de referência correspondente Q_{tabelado} , isto significa a existência de um *outlier* presente na amostra.

O teste Q não pode ser aplicado a um mesmo conjunto de dados mais do que uma vez.

3.2.2 Parcelas de validação

A área de estudo também conta com uma rede amostral de parcelas de inventário contínuo pertencentes à empresa Duratex S.A.

As mensurações realizadas aos 5.5 anos de idade da floresta foram utilizadas como conjunto de dados para validação dos resultados da pesquisa.

Ao todo foram 21 parcelas de 240 m² cada, com 40 indivíduos inicialmente implantados (4 linhas de plantio *versus* 10 plantas por linha). A Figura 7 ilustra a distribuição geográfica das parcelas de validação na área de estudo e sua posição relativa em relação às parcelas experimentais.

Figura 7 – Parcelas de validação. Parcelas de número 10 a 18, 26 a 37 (verdes) inicialmente acomodaram 40 árvores cada, com área aproximada de 240 m². Os polígonos de fundo branco e com contorno preto são as parcelas experimentais (ver também Figura 6).

Apenas a árvore de número 1 em cada parcela de validação foi georreferenciada no campo. Por esse motivo, os polígonos das parcelas de validação foram delimitados considerando-se as suas dimensões teóricas de largura e comprimento (15 m x 16 m).

Optou-se por manter a numeração original das parcelas de inventário da empresa Duratex por uma questão de facilidade no processamento das informações.

Nas parcelas de validação mensuram-se os seguintes atributos da floresta: i) diâmetro à altura do peito de todas as árvores, ii) altura total em 25% dos indivíduos incluindo duas árvores dominantes por parcela, e iii) características qualitativas dos indivíduos.

O cálculo da área basal procedeu-se da mesma forma que nas parcelas experimentais (ver eq. 2).

As alturas não mensuradas em campo foram calculadas com base no ajuste de um modelo hipsométrico para predição do logaritmo neperiano da altura em função do inverso do DAP. O modelo foi ajustado pela técnica de regressão linear simples e método dos mínimos quadrados ordinários (Apêndice B, Figura 44). O cálculo de biomassa seca do lenho seguiu a mesma metodologia utilizada para as parcelas experimentais (ver Tabela 1).

A Tabela 3 ilustra o resumo do processamento das informações de inventário nas parcelas de validação.

Tabela 3 – Resumo do inventário nas parcelas de validação.

	Sobr. %	DAP cm	G m ² .ha ⁻¹	H m	B Mg.ha ⁻¹
Mínimo	72.1	12.7	21.6	20.7	94.0
Média	87.7	14.2	26.7	22.6	125.1
Máximo	97.7	16.4	34.8	24.9	166.7
Desv. pad.	6.8	0.93	3.43	1.00	18.80

Sobr. = sobrevivência; DAP = diâmetro médio à altura do peito; G = área basal; H = altura total média; B = biomassa seca do lenho; Mínimo = parcela com a menor média; Média = média das parcelas; Máximo = maior valor médio entre parcelas; Desv. Pad = desvio padrão entre as médias das parcelas.

O Apêndice B, Tabela 23 e Figura 45 contêm o detalhamento das informações de inventário por parcela e também as distribuições empíricas dos diâmetros observados e das alturas totais preditas dentro de cada parcela, respectivamente.

3.3 Escaneamento a laser aerotransportado (ALS)

O aerolevantamento com escaneamento a laser foi realizado em abril de 2009. Essa época do ano coincide com o período em que o Índice de Área Foliar (IAF) da floresta é máximo (LE MAIRE et al, 2011).

O sobrevoo foi efetuado pela empresa prestadora de serviço Esteio Engenharia e Aerolevantamentos S.A. com aeronave EMB 810C SENECA II, e equipamento escaneador a laser Leica ALS 50-II, sob a orientação do projeto Eucflux (STAPE et al., 2008; STAPE; WYNNE⁶, comunicação pessoal).

Inicialmente, o voo foi parametrizado para se obter uma densidade nominal de retornos na ordem de 6 pontos por m². A Figura 8 ilustra a configuração das 11 faixas de voo utilizadas, as quais tiveram sobreposição lateral de aproximadamente 30%.

⁶ STAPE, J.L.; WYNNE, R. North Carolina State University; Virginia Polytechnic Institute and State University.

Figura 8 – Faixas de sobrevoo resultantes do escaneamento a laser na área de estudo. Fonte: Esteio Engenharia e Aerolevantamentos S.A. (2009).

A Tabela 4 contém informações adicionais sobre a configuração dos parâmetros do sobrevoo ALS realizado na área de estudo.

Tabela 4 – Parâmetros do sobrevoo ALS no site experimental

Parâmetro	Unidade	Valor
Densidade nominal de retornos	retornos.m ⁻²	6
Altura de voo	m	900
Velocidade de voo	km.h ⁻¹	131.9
Ângulo de escaneamento	graus	15
Frequência de escaneamento	Hz	74.1
Comprimento da faixa de varredura	m	237
Sobreposição lateral da faixa	%	30
Frequência de emissão do pulso laser	kHz	109.7
Datum horizontal	nome	SAD 69
Datum vertical	nome	Imbituba-SC

Fonte: Esteio Engenharia e Aerolevantamentos S.A. (2009).

3.4 Processamento da nuvem de pontos ALS

As observações de GPS coletadas no solo e na aeronave foram pré-processadas de modo a obter uma solução cinemática única e ajustada para um sistema de coordenadas conhecido, com a assistência do software Leica Waypoint – GraphNav 7.8.

Para a maior parte do processamento da nuvem tridimensional de pontos utilizou-se o software gratuito *Fusion LiDAR Tool Kit* (Fusion LTK) (McGAUGHEY, 2013).

Primeiramente, quantificou-se a densidade de retornos obtida na nuvem ALS e como esse atributo variou espacialmente dentro da área de interesse. Para isso, produziu-se um mapa com o atributo de interesse densidade de retornos, com resolução espacial de 1.73 m.

A nuvem de pontos foi homogeneizada para uma densidade de retornos próxima a densidade nominal de 6 pontos/m². Pulsos sobressalentes foram removidos aleatoriamente utilizando-se o algoritmo e comando de linha *ThinData* presente no software Fusion.

O algoritmo *ThinData*, pode ser parametrizado de acordo com dois argumentos: densidade de pulsos desejada e tamanho da janela de processamento. O algoritmo foi configurado com densidade de 5 pulsos por m² e 10m² de janela de processamento, respectivamente.

Quanto menor a janela de processamento menor é a probabilidade de remoção de pulsos da nuvem original porque algumas células poderão possuir apenas um pulso e, portanto, permanecerão inalteradas (McGAUGHEY, 2013).

3.4.1 Classificação de retornos de solo

Para separar retornos pertencentes ao solo de retornos de vegetação utilizou-se o algoritmo de classificação *Multiscale Curvature Classification* (MCC) (EVANS; HUDAK, 2007).

O MCC utiliza o método de interpolação *Thin Plate Spline* (TPS) para criar uma superfície de referência aos pontos não classificados.

De acordo com os autores, o MCC identifica retornos que não pertencem ao solo por meio de um parâmetro de curvatura limite (t) e variando-se a escala (s) (resolução) de atuação do algoritmo para cada iteração.

O parâmetro de escala inicial (s) deve ser um valor próximo ao espaçamento de pontos da nuvem. A variação da escala se dá em três domínios (l): 0.5s, 1s e 1.5s. O algoritmo itera até que a quantidade de retornos classificados como solo seja menor do que 0.1% (parâmetro de convergência j) dos pontos classificados na iteração anterior.

Neste estudo o algoritmo MCC foi parametrizado com escala (s) igual 1.5 e parâmetro de tolerância da curvatura (t) igual 0.09 (Tabela 5).

Como um processamento paralelo de classificação de retornos de chão, também foi utilizado o algoritmo de Kraus e Pfeifer (1998) (Figura 9).

$$p_i = \begin{cases} 1 & v_i \leq g \\ \frac{1}{1 + (a * (v_i - g)^b)} & g < v_i \leq g + w \\ 0 & g + w < v_i \end{cases}$$

Figura 9 – Algoritmo de Kraus e Pfeifer (1998) para classificação de retornos de solo.

O algoritmo atua calculando inicialmente uma superfície de referência baseado na elevação média dos retornos da nuvem dentro de um dado pixel. Inicialmente, todos os pontos possuem o mesmo peso.

Cada elevação de retorno é subtraída da superfície de referência para a obtenção de um valor residual individual (v_i). Se v_i é menor do que o parâmetro de limiar (g) ele recebe um peso (p_i) igual a 1. Se o valor residual se situa entre g e a soma de g mais o parâmetro de tolerância (w) ele recebe um peso (p_i) entre 0 e 1. Neste caso, p_i é ponderado por uma função sigmoidal modelada pelos parâmetros a e b .

Um determinado retorno receberá peso (p_i) igual a zero se o valor do resíduo v_i for maior do que $g+w$. Por conseguinte, estes retornos são descartados do processo de filtragem como pontos não pertencentes ao solo.

Na última etapa, todos os valores de elevação dos retornos são multiplicados pelos pesos atribuídos. O algoritmo faz a iteração calculando-se uma nova superfície de referência com base nos pontos remanescentes.

O algoritmo de Kraus e Pfeifer foi parametrizado para o site do projeto Eucflux utilizando-se o melhor ajuste encontrado em Silva et al. (2012) (Tabela 5).

Tabela 5 – Parametrização utilizada para classificação dos retornos de solo da nuvem ALS.

Evans e Hudak (2007)		Kraus e Pfeifer (1998)				
Escala - s	Curvatura - t	Limiar - g	Tolerância - w	Parâmetro a	Parâmetro b	Célula (m)
1.5	0.09	-2	2.5	1	4	2

3.4.2 Modelos digitais de elevação (DEM)

Para cada nuvem ALS filtrada na etapa anterior gerou-se um Modelo Digital de Elevação (DEM). Os valores obtidos nos DEMs foram calculados com base na média de elevação dos retornos de solo em cada pixel da grade (1 metro de resolução).

Os DEMs foram comparados pela diferença da elevação no pixel i (eq. 4).

$$\varepsilon_i = H\_DEM_{KP\_i} - H\_DEM_{EH\_i} \quad (4)$$

onde:

ε_i = diferença da elevação no pixel i (m).

$H\_DEM_{KP\_i}$ = Elevação no pixel i (m). DEM gerado com algoritmo de classificação de retornos de solo de Kraus e Pfeifer (1998).

$H\_DEM_{EH\_i}$ = Elevação no pixel i (m). DEM gerado com algoritmo de rotulação de retornos de solo de Evans e Hudak (2007).

3.4.3 Extração de métricas

A nuvem de pontos tridimensional foi normalizada previamente à extração das métricas de interesse. O processo de normalização subtrai as elevações do Modelo Digital de Elevação, da elevação de cada retorno na nuvem, em suas respectivas coordenadas geográficas. A Figura 10 (d) ilustra o efeito do processo de normalização da nuvem 3D em uma floresta hipotética.

A partir da nuvem de pontos normalizada, recortaram-se as amostras correspondentes aos locais das parcelas experimentais da área de estudo. De cada parcela de nuvem, extraíram-se as métricas (estatísticas) de interesse e as informações foram armazenadas em um banco de dados de planilha eletrônica.

A Figura 10 ilustra o fluxograma com todas as etapas de processamento dos dados ALS e os respectivos comandos de linha utilizados, do software Fusion.

Figura 11 – Percentil 90 extraído de uma parcela da área de estudo. Fonte: adaptado de Alvares et al. (2013b).

Foram selecionados os percentis de altura que apresentaram melhor desempenho na estimação de área basal e volume no trabalho de Zonete; Rodriguez e Packalén (2010): percentis 10, 30, 70, 90 provenientes de primeiros retornos. Ademais, foram selecionadas métricas de altura média, desvio padrão da altura e variância da altura, sendo todas elas para primeiros retornos observados. As métricas foram computadas desconsiderando-se pontos com altura menor do que 2 metros (NAESSET, 2002; ZONETE; RODRIGUEZ; PACKLÉN, 2010).

Em adição às métricas padrões de posição e dispersão de altura de retornos, foi inserida uma métrica de densidade (proporção) nomeada nesta pesquisa de *p_understory*. Ela é a proporção de retornos entre 0.3 metros e 15 metros de altura (A) e a quantidade de pontos entre o solo (0 m) e 15 metros de altura (B). A Figura 12 explica como se dá o cálculo desta métrica.

Figura 12 – Esquema ilustrativo da métrica de proporção *p_understory*. Ela representa a porcentagem de pontos da nuvem no estrato entre 0.3 metros e 15 metros em relação a todos os retornos existentes entre 0 metro (pontos de solo) e 15 metros.

O limiar de 15 metros escolhido para representação da região de subdossel da floresta foi definido com base em inspeção visual da nuvem de pontos.

A métrica de *p_understory* tem o objetivo de corroborar uma das hipóteses da pesquisa de que áreas com maiores valores de área basal e biomassa de lenho possuem maior proporção de retornos no subdossel da floresta. Ela foi idealizada com o objetivo de investigar a variação da estrutura horizontal do povoamento florestal.

A Tabela 6 resume as métricas da nuvem tridimensional de pontos que foram selecionadas para a etapa de modelagem.

Tabela 6 – Descrição matemática das métricas extraídas da nuvem de pontos para modelagem de área basal e biomassa do lenho.

#	Nome	Retorno	Descrição	Grupo	Subgrupo
1	Percentil 10	Primeiro	10% menores < altura < 90% maiores retornos	Altura	Posição
2	Percentil 30	Primeiro	30% menores < altura < 70% maiores retornos	Altura	Posição
3	Percentil 70	Primeiro	70% menores < altura < 30% maiores retornos	Altura	Posição
4	Percentil 90	Primeiro	90% menores < altura < 10% maiores retornos	Altura	Posição
5	Média	Primeiro	$(\sum \text{das alturas}) / (\text{total de retornos})$	Altura	Posição
6	Desv. padrão	Primeiro	$\text{Sqrt} [\sum (\text{alturas} - \text{altura média})^2 / (\text{total de retornos})]$	Altura	Dispersão
7	Variância	Primeiro	$(\text{desvio padrão da altura})^2$	Altura	Dispersão
8	<i>p_understory</i>	Todos	$(0.3 \text{ m} < \# \text{ pontos} < 15 \text{ m}) / (0 \text{ m} < \# \text{ pontos} < 15 \text{ m})$	Altura	Proporção

3.5 Perfis de alturas de dossel (CHPs)

Os perfis aparentes de alturas de dossel (CHPs) foram avaliados por meio da visualização das distribuições empíricas e teóricas das alturas observadas na nuvem ALS (COOPS et al. 2007; MAGNUSSEN; EGGERMONT; LaRICCIA, 1999).

As distribuições probabilísticas teóricas consistem em funções com características e propriedades já bem definidas em literatura (MOOD; GRAYBILL; BOES, 1974).

Para construção dos perfis de altura teóricos, foram amostrados os retornos (primeiros, intermediários e últimos) maiores do que 5 metros nas 23 parcelas experimentais da área de estudo. O limite estabelecido de 5 metros objetivou excluir os retornos de solo, sub-bosque e de árvores dominadas para eliminar o efeito bimodal sobre as representações dos CHPs (COOPS et al., 2007; DEAN et al., 2009; LOVELL et al., 2003; MAGNUSSEN; EGGERMONT; LaRICCIA, 1999).

A partir de um conjunto possível de distribuições, escolheu-se a função de densidade probabilidade (fdp) Weibull com dois parâmetros pela sua flexibilidade e potencial de ajuste para dados com distribuições assimétricas, uma característica comum em nuvens de pontos geradas por aerolevantamentos sobre vegetações florestais (COOPS et al., 2007; DEAN et al., 2009; MAGNUSSEN; EGGERMONT; LaRICCIA, 1999).

De acordo com Campos e Leite (2013), a função Weibull é utilizada com frequência na área florestal porque é capaz de modelar tanto tendências com alto grau de assimetria a exemplo da exponencial até distribuições normais. Além disso, os parâmetros da distribuição podem ser correlacionados com atributos do povoamento.

Mood; Graybill e Boes (1974) ilustram a função de densidade probabilidade Weibull com dois parâmetros (escala α , e forma β) (eq. 5).

$$f(x|\alpha, \beta) = \alpha\beta x^{\beta-1} \exp[-\alpha x^\beta], \quad 0 < x < \infty; \alpha > 0; \beta > 0 \quad (5)$$

onde:

$f(x/\alpha, \beta)$ = densidade probabilidade de x .

α = parâmetro de escala.

β = parâmetro de forma.

Os parâmetros de escala e forma da fdp Weibull foram encontrados por meio do método da máxima verossimilhança (MLE), de acordo com Cohen (1965). O método da estimação por máxima verossimilhança é o mais eficiente para ajustamento de distribuições Weibull (CAMPOS; LEITE, 2013).

A análise foi realizada no software para processamento estatístico R (R CORE TEAM, 2013) utilizando-se a função *fitdistr* disponível no pacote MASS (VENABLES; RIPLEY, 2002). A equação 6 mostra a função de verossimilhança para a distribuição Weibull.

$$L(\alpha, \beta | x_1, \dots, x_n) = \prod_{i=1}^n \left(\frac{\beta}{\alpha} \right) x_i^{\beta-1} \exp\left(-\frac{x_i^\beta}{\alpha}\right) \quad (6)$$

onde:

$L(\alpha, \beta | x_1, \dots, x_n)$ = função de verossimilhança da fdp Weibull.

α = parâmetro de escala.

β = parâmetro de forma.

De acordo com Cohen (1965), o logaritmo natural da função de verossimilhança da fdp Weibull é diferenciado em relação aos parâmetros forma (β) e escala (α) e as duas equações são igualadas a zero para que se obtenham equações de estimação dos parâmetros candidatos (eq. 7 e eq. 8).

$$\frac{d \ln L}{d\beta} = \frac{n}{\beta} + \sum_{i=1}^n \ln x_i - \frac{1}{\alpha} \sum_{i=1}^n x_i^\beta * \ln x_i = 0 \quad (7)$$

$$\frac{d \ln L}{d\alpha} = -\frac{n}{\alpha} + \frac{1}{\alpha^2} \sum_{i=1}^n x_i^\beta = 0 \quad (8)$$

onde:

L = valor de verossimilhança da fdp Weibull.

α = parâmetro de escala.

β = parâmetro de forma.

x_i = valor observado.

n = número de amostras.

Se o parâmetro de forma (β) é isolado concomitantemente nas equações 7 e 8 como função de x_i e do parâmetro de escala (α), é possível igualar as expressões para obter o estimador $\hat{\beta}$ (eq. 9). A estimação de $\hat{\beta}$ foi conduzida por meio do método de otimização quasi-Newton BFGS (BROYDEN, 1969; FLETCHER, 1970; GOLDFARB, 1970; SHANNO, 1970 apud KELLEY, 1999). O método BFGS realiza simulações de valores para $\hat{\beta}$ até que a equação 9 seja satisfeita.

$$\hat{\beta} = \frac{\sum_{i=1}^n x_i^\beta \ln x_i}{\sum_{i=1}^n x_i^\beta} - \frac{1}{\beta} - \frac{1}{n} \sum_{i=1}^n \ln x_i = 0 \quad (9)$$

onde:

$\hat{\beta}$ = estimador do parâmetro de forma (β).

Então, com o parâmetro de forma ($\hat{\beta}$) estimado, o parâmetro de escala ($\hat{\alpha}$) é obtido pela equação 7 (ou equação 8).

A Figura 13 e Figura 14 fornecem exemplos de como a fdp Weibull pode variar em função dos valores assumidos para os parâmetros de forma e escala, respectivamente. O parâmetro de forma (β), como o próprio nome diz está relacionado com o formato que a curva de densidade probabilidade possui.

Figura 13 – Função de densidade probabilidade Weibull de acordo com diferentes valores do parâmetro de forma (β). O parâmetro de escala (α) foi fixado em um valor igual a 20.

Enquanto que a função de densidade probabilidade Weibull com parâmetro de forma entre três e quatro é muito próxima de uma distribuição normal, quando ela possui $\beta = 1$ a fdp se resume a uma distribuição exponencial (MOOD; GRAYBILL; BOES, 1974).

Quando o parâmetro de forma é igual a dois, a fdp Weibull assume distribuição de Rayleigh, que é um caso especial da distribuição qui-quadrado (χ^2) (CAMPOS; LEITE, 2013).

Figura 14 – Função de densidade probabilidade Weibull de acordo com diferentes valores do parâmetro de escala (α). O parâmetro de forma (β) foi fixado em um valor igual a 3.5.

O parâmetro de escala (α) da fdp Weibull é o percentil 63.2 da distribuição. Isto significa dizer que 63.2% das informações descritas na distribuição ocorrem abaixo de α (McCOOL, 2012).

3.6 Modelos lineares

3.6.1 Seleção de variáveis preditoras

Para eliminar multicolinearidade entre os candidatos à preditores dos modelos utilizou-se o coeficiente de correlação produto-momento de Pearson (ρ) (doravante denominado de coeficiente de correlação de Pearson) (eq. 10). Foram consideradas variáveis explicativas colineares aquelas que apresentaram coeficiente de correlação ρ maior do que 0.9 ou menor do que -0.9.

$$\hat{\rho}_{XY} = \frac{\sum_i^n (X_i - \bar{X}) (Y_i - \bar{Y})}{\sqrt{\sum_i^n (X_i - \bar{X})^2} \sqrt{\sum_i^n (Y_i - \bar{Y})^2}} \quad (10)$$

onde:

$\hat{\rho}_{XY}$ = estimativa amostral do coeficiente de correlação linear de Pearson.

X_i e Y_i = valores observados das variáveis X e Y, respectivamente.

$\bar{X}$ e $\bar{Y}$ = média das variáveis X e Y, respectivamente.

Utilizou-se também o Fator de Inflação da Variância (VIF) como uma segunda verificação da presença de multicolinearidade entre as variáveis selecionadas na etapa anterior (eq. 11).

O VIF pode detectar relações entre preditores em que a correlação em pares é pequena, mas que quando combinados podem apresentar relação linear significativa (THE PENNSYLVANIA STATE UNIVERSITY, 2014). Preditores com VIF maior do que 5 foram considerados como não apropriados para inclusão conjunta nos modelos de predição de área basal e biomassa do lenho.

$$VIF_k = \frac{1}{1 - R_k^2} \quad (11)$$

onde:

R_k^2 = valor do coeficiente de determinação (R^2) obtido pela regressão do k -ésimo preditor sobre os preditores remanescentes.

Anteriormente à etapa de modelagem explorou-se o grau de relação linear entre as variáveis explicativas selecionadas e as variáveis de interesse área basal e biomassa do lenho.

Foi realizado um teste t de correlação de amostras pareadas, o qual pressupõe que a distribuição amostral do coeficiente de correlação de Pearson (ρ) sob a hipótese nula de correlação ($\rho = 0$), apresenta a estatística t desenhada de uma distribuição t de Student com $n-2$ graus de liberdade (eq. 12).

$$t = \rho \sqrt{\frac{n-2}{1-\rho^2}} \sim t_{n-2} \quad (12)$$

onde:

t = estatística t.

n = tamanho da amostra.

ρ = coeficiente de correlação linear de Pearson.

O teste t entre amostras pareadas é útil porque permite a construção de intervalos de confiança para as estimativas de ρ . Essa análise foi desenvolvida com a função *cor.test*, a qual está disponível nos pacotes básicos de processamento do software R (R CORE TEAM, 2013).

De acordo com Lira (2004), uma das pressuposições básicas para a utilização do coeficiente de correlação de Pearson em inferência estatística é de que as duas variáveis em estudo tenham distribuição normal bivariada. Essa hipótese tem maior importância quando a amostra é pequena.

A hipótese de distribuição normal conjunta foi verificada com o teste de Doornik-Hansen (DOORNIK; HANSEN, 2008). Esse teste está disponível no software R por meio da função *normality.test1* do pacote denominado *normwhn.test* (*Normality and White Noise Testing*) (WICKHAM, 2012).

As variáveis preditoras que apresentaram baixa correlação linear com as variáveis de interesse e cujos intervalos de confiança para ρ contemplaram o valor zero foram descartadas das análises subsequentes.

3.6.2 Ajuste dos modelos de regressão

Foram construídos modelos de regressão linear simples e múltiplos para predição das variáveis de interesse área basal e biomassa de lenho.

Os modelos lineares foram obtidos pelo método dos mínimos quadrados ordinários (OLS) que consiste na minimização da soma de quadrados dos resíduos ($\sum_{i=1}^n \hat{\epsilon}_i^2$). Os resíduos de um dado modelo são resultantes da diferença entre valores observados (Y_i) e valores preditos pelos modelos de regressão ($\hat{Y}_i$) (eq. 13).

$$\sum_{i=1}^n \hat{\varepsilon}_i^2 = \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 = \sum_{i=1}^n (Y_i - \hat{\beta}_0 - \hat{\beta}_1 X_i)^2 \quad (13)$$

onde:

$\sum_{i=1}^n \hat{\varepsilon}_i^2$ = soma de quadrados dos resíduos.

Y_i e $\hat{Y}_i$ = valores observados e preditos da variável resposta, respectivamente.

$\hat{\beta}_0$ e $\hat{\beta}_1$ = estimadores do modelos de regressão, em que β_0 é o intercepto e β_1 é o coeficiente angular.

X_i = valores observados da variável independente.

De acordo com Gujarati (2004), os estimadores $\hat{\beta}_0$ e $\hat{\beta}_1$ podem ser calculados pela diferenciação da equação 13, em relação aos parâmetros $\hat{\beta}_0$ e $\hat{\beta}_1$ e igualando-se as equações resultantes à zero. Deste processo, resultam as chamadas “equações normais” (eq. 14 e eq. 15).

$$\sum_{i=1}^n Y_i = n\hat{\beta}_0 + \hat{\beta}_1 \sum_{i=1}^n X_i \quad (14)$$

onde:

$\sum_{i=1}^n Y_i = n\hat{\beta}_0 + \hat{\beta}_1 \sum_{i=1}^n X_i$ = equação normal resultante da diferenciação da equação 13, com relação à $\hat{\beta}_0$.

n = tamanho da amostra.

$$\sum_{i=1}^n Y_i X_i = \hat{\beta}_0 \sum_{i=1}^n X_i + \hat{\beta}_1 \sum_{i=1}^n X_i^2 \quad (15)$$

onde:

$\sum_{i=1}^n Y_i X_i = \hat{\beta}_0 \sum_{i=1}^n X_i + \hat{\beta}_1 \sum_{i=1}^n X_i^2$ = equação normal resultante da diferenciação da equação 13, com relação à $\hat{\beta}_1$.

Resolvendo-se simultaneamente as equações normais (eq. 14 e eq. 15), os parâmetros $\hat{\beta}_1$ e $\hat{\beta}_0$ são estimados de acordo com a equação 16 e equação 17, respectivamente.

$$\hat{\beta}_1 = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sum_{i=1}^n (X_i - \bar{X})^2} \quad (16)$$

onde:

$\hat{\beta}_1$ = estimador do parâmetro de coeficiente angular que minimiza a soma dos quadrados dos resíduos do modelo de regressão.

$\bar{X}$ = média da amostra de X.

$\bar{Y}$ = média da amostra de Y.

$$\hat{\beta}_0 = \bar{Y} - \hat{\beta}_1 \bar{X} \quad (17)$$

onde:

$\hat{\beta}_0$ = estimador do parâmetro de intercepto que minimiza a soma dos quadrados dos resíduos do modelo de regressão.

$\bar{X}$ = média da amostra de X.

$\bar{Y}$ = média da amostra de Y.

De acordo com Gujarati (2004), os estimadores dos quadrados mínimos ordinários ($\hat{\beta}_0$ e $\hat{\beta}_1$) são expressos puramente em termos das variáveis observáveis (Y e X) e por isso, são de fácil obtenção. Eles se constituem em estimadores pontuais, ou seja, dado uma amostra, cada estimador resultará em um único valor para representar o parâmetro da população.

Os modelos de regressão lineares e múltiplos foram ajustados utilizando-se a função *lm* (de *linear model*) dos pacotes básicos de análise estatística do software R.

3.6.3 Verificação de pressuposições

As pressuposições básicas que devem ser atendidas em modelos de regressão linear são:

- Existência de linearidade entre variável resposta e variáveis explicativas.
- Normalidade de resíduos.
- Homoscedasticidade (também conhecida como homogeneidade de variâncias, ou variância constante dos resíduos).
- Independência entre resíduos.

Para verificação do atendimento às pressuposições citadas, utilizaram-se duas técnicas complementares: análise gráfica e teste de hipóteses.

Com relação aos testes de hipótese foram utilizados os seguintes testes: Shapiro-Wilk para normalidade de resíduos (SHAPIRO; WILK, 1965), Breusch-Pagan para homoscedasticidade (BREUSCH; PAGAN, 1979) e, teste de Durbin-Watson para independência de resíduos (DURBIN; WATSON, 1971).

3.6.4 Critérios para seleção de modelos

Entre os modelos de regressão ajustados, foram selecionados aqueles que apresentaram estimativas dos parâmetros de coeficiente angular dentro do nível de significância a 5% ($\alpha = 0.05$), de acordo com testes t realizados (eq. 18) (DEMÉTRIO; ZOCCHI, 2011).

$$t = \frac{\hat{\beta}_j - \beta_0}{SE_{\hat{\beta}_j}} \sim t_{n-p} \quad (18)$$

onde:

t = estatística t.

$\hat{\beta}_j$ = estimativa do coeficiente angular j.

β_0 = termo constante (pode ser considerado como igual a zero).

$SE_{\hat{\beta}_j}$ = erro padrão do coeficiente angular j.

Sob a hipótese nula do teste, não há relação entre variável resposta e variável explicativa, pois o intervalo de confiança para $\hat{\beta}$ passa por zero.

Para seleção do melhor ajuste da regressão foram escolhidas as seguintes estatísticas: i) coeficiente de determinação ajustado (adj. R^2) (eq. 20), ii) raiz do erro quadrático médio (RMSE) (eq. 21), iii) raiz do erro quadrático médio relativa (rRMSE) (eq. 22), iv) viés (eq. 23) e v) critério de informação de Akaike (AIC) (eq. 24).

Previamente ao cálculo da estatística do R^2 ajustado, obteve-se o coeficiente de determinação não ajustado (R^2) (eq. 19).

$$R^2 = 1 - \frac{SQ_{resíduos}}{SQ_{total}} \quad (19)$$

onde:

R^2 = coeficiente de determinação.

$SQ_{resíduos}$ = soma de quadrados dos resíduos $\sum_{i=1}^n (y_i - \hat{y}_i)^2$.

SQ_{total} = soma total de quadrados: $\sum_{i=1}^n (y_i - \bar{y})^2$.

O coeficiente de determinação ajustado ($adj.R^2$) é ponderado pelo tamanho da amostra (n) e pelo número de regressores do modelo (p). Mantidos todos os outros parâmetros fixados, quanto maior o tamanho da amostra, maior o R^2 ajustado. Por outro lado, quanto maior o número de variáveis preditoras em um dado modelo, menor será o valor de $adj.R^2$ (eq. 20).

$$adj.R^2 = R^2 - (1 - R^2) \frac{p}{n - p - 1} \quad (20)$$

onde:

$adj.R^2$ = coeficiente de determinação ajustado.

R^2 = coeficiente de determinação não ajustado.

p = número de variáveis independentes.

n = tamanho da amostra.

O coeficiente de determinação ajustado deve ser analisado concomitantemente com a análise gráfica de dispersão entre a variável resposta e as variáveis preditoras estudadas. Isto porque relações não lineares podem resultar em valores falsos positivos de $adj.R^2$.

Foram utilizadas também os indicadores estatísticos RMSE e rRMSE. O RMSE representa o desvio padrão das diferenças entre os valores preditos e os valores observados (eq. 21).

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n - 1}} \quad (21)$$

onde:

RMSE = raiz do erro quadrático médio.

y_i = valores observados.

$\hat{y}_i$ = valores preditos.

n = número de observações.

A estatística tem a mesma unidade de medida da variável aleatória estudada. O RMSE foi utilizado como uma medida de exatidão.

O RMSE relativo, expressa a distância entre valores preditos e observados de uma variável aleatória em relação à média dos valores observados (eq. 22). A vantagem desta estatística é que ela não é dependente de escala, e por isso, pode ser utilizada para comparação de variáveis com magnitudes diferentes.

$$rRMSE = \frac{RMSE}{\bar{y}} * 100 \quad (22)$$

onde:

$rRMSE$ = raiz do erro quadrático médio relativo (%).

$RMSE$ = raiz do erro quadrático médio.

$\bar{y}$ = média dos valores observados.

A estatística de viés foi utilizada para verificação de tendências de superestimação e subestimação dos modelos (eq. 23). Ela mensura o total de desvio entre valores observados e preditos do modelo e distribui o desvio entre os valores observados na amostra.

$$Viés = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)}{n} \quad (23)$$

onde:

$Viés$ = viés.

y_i = valores observados.

$\hat{y}_i$ = valores preditos.

n = número de observações.

Assim como a estatística de RMSE, o viés tem unidade de medida igual aos valores observados e preditos. Quanto mais próximo de zero é o viés melhor a capacidade de predição do modelo.

Também foi utilizada como critério de seleção, a estatística de informação de Akaike (AIC) (eq. 24). Ela tem utilidade porque além do ajuste da regressão, considera a simplicidade dos modelos como um fator positivo. O AIC é uma medida relativa de qualidade.

Pelo método do AIC escolhe-se o modelo com o menor valor obtido para a estatística.

$$AIC = 2k - 2\ln(L) \quad (24)$$

onde,

AIC = critério de informação de Akaike.

k = número de parâmetros do modelo.

L = valor maximizado da função de verossimilhança do modelo ajustado. $L = (\theta|X)$.

3.6.5 Validação

Os modelos selecionados na etapa anterior foram avaliados utilizando-se a técnica de validação cruzada pelo método *leave-one-out* (*leave-one-out cross validation* - LOOCV). A validação LOOCV utiliza o conjunto de dados de treinamento (parcelas experimentais, Figura 6) deixando uma das observações de fora ($n-1$) para ajustar um novo modelo e prever o valor removido da amostra (n é o tamanho da amostra). Esse processo ocorre n vezes, de modo que todas as observações são excluídas uma única vez.

A análise da validação cruzada dos modelos de regressão foi realizada com o auxílio das funções *cvFolds* e *cvFit* do pacote de nome *cvTools* (ALFONS, 2012), disponível no software para computação estatística R.

Posteriormente, os modelos lineares dependentes de variáveis ALS foram utilizados para prever os valores de área basal e biomassa de lenho nas parcelas de validação do site de estudo (ver Figura 7).

Para avaliar o resultado da validação cruzada e das previsões sobre as parcelas de validação utilizaram-se as estatísticas de RMSE (eq. 21), RMSE relativo (eq. 22), RMSE normalizado (nRMSE) (eq. 25) e coeficiente de correlação linear de Pearson (eq. 10).

$$nRMSE = \frac{RMSE}{y_{max} - y_{min}} * 100 \quad (25)$$

onde:

$nRMSE$ = RMSE normalizado.

$RMSE$ = raiz do erro quadrático médio.

y_{max} = valor máximo observado.

y_{min} = valor mínimo observado.

3.7 Krigagem ordinária

Como método alternativo aos modelos de regressão ajustados na seção anterior, utilizou-se a técnica de krigagem ordinária para interpolação dos atributos de interesse área basal e biomassa do lenho.

De acordo com Chilès e Delfiner (1999), a técnica de krigagem é uma forma de regressão linear. A principal diferença é que na krigagem considera-se a correlação espacial entre resíduos para os cálculos de predição.

A técnica da krigagem é o melhor método linear não enviesado para estimação de variáveis regionalizadas a partir de observações da variável regionalizada de interesse e características estruturais de variogramas (SUN; KANG; ZHANG, 2009).

O modelo da krigagem ordinária é função de uma média populacional não conhecida e dos erros aleatórios do modelo (eq. 26).

$$Z(x) = m(x) + \varepsilon(x) \quad (26)$$

onde:

$Z(x)$ = variável de interesse na coordenada x .

$m(x)$ = média desconhecida da população para a variável de interesse na coordenada x .

$\varepsilon(x)$ = resíduo na coordenada x .

Os modelos de krigagem ordinária seguem as premissas de que as variáveis de interesse devem ser aleatórias e estacionárias. O termo estacionário significa dizer que a dependência espacial entre observações está atrelada apenas às suas distâncias e não na posição que elas ocupam no campo geométrico.

Para cada variável de interesse calculou-se o semi-variograma experimental por meio da equação 27:

$$\hat{\gamma}(\bar{h}_k) = \frac{1}{2N_k} \sum_{i=1}^{N_k} (\hat{\varepsilon}(x_i) - \hat{\varepsilon}(x_i + h))^2 \quad (27)$$

onde:

$\hat{\gamma}(\bar{h}_k)$ = estimativa da semi-variância para a classe k na distância média $\bar{h}$;

$\bar{h}_k$ = distância média da classe k;

N_k = número de pares observados na classe k

$\hat{\varepsilon}(x_i)$ = resíduo (erro aleatório) observado em x_i .

x_i = local i com coordenadas geográficas x e y .

Na sequência, ajustou-se o melhor modelo teórico para os semi-variogramas experimentais encontrados. O melhor ajuste resultou da minimização dos quadrados dos resíduos entre o semi-variograma teórico e o semi-variograma experimental (HIEMSTRA et al., 2009).

Para essa etapa da análise foram considerados os seguintes modelos: esférico, exponencial, gaussiano e linear. De acordo com Soares (2006), estes modelos são capazes de cobrir a maior parte da generalidade das situações de dispersão de fenômenos espaciais que são encontrados na natureza.

Os semi-variogramas teóricos foram ajustados com o auxílio de rotinas de processamento disponíveis no pacote geoestatístico *automap* do ambiente para computação estatística R (HIEMSTRA et al., 2009).

De acordo com Sun; Kang e Zhang (2009), a expressão que representa os valores preditos na krigagem ordinária pode ser dada pela equação 28:

$$\hat{Z}(x_0) = \sum_{i=1}^n \lambda_i Z(x_i) \quad (28)$$

onde:

$\hat{Z}(x_0)$ = estimativa da variável de interesse no local x_0 .

$Z(x_i)$ = valor mensurado da variável de interesse no local x_i .

λ_i = peso associado ao resíduo da observação $Z(x_i)$. A soma dos pesos deve ser igual a 1.

Os coeficientes λ_i são calculados por meio da mínima variância dos erros que se constitui em um estimador não enviesado (HIEMSTRA et al., 2009; SUN; KANG; ZHANG, 2009; VIANA et al., 2012).

Para interpolação das variáveis de interesse sobre a área de estudo com a técnica da krigagem ordinária, utilizou-se a função *auto.Krige* do pacote geoestatístico *automap*, no software R.

Semelhantemente aos modelos de regressão, foram utilizados dois métodos para validação da krigagem ordinária: validação cruzada (*leave-one-out cross validation* - LOOCV) e comparação entre interpolado na krigagem e observado nas parcelas de campo de validação. Em ambos os casos utilizaram-se as estatísticas de RMSE, rRMSE, nRMSE e coeficiente de correlação de Pearson para comparação dos resultados.

3.8 Representação espacial das variáveis de interesse

Foram utilizados os melhores modelos de regressão encontrados para predição de área basal e biomassa do lenho sobre a área de estudo.

Para representação dos mapas de predição utilizou-se uma resolução espacial de 256 m² (pixel de 16 m), a qual foi um valor aproximado da área das parcelas de validação do site experimental Eucflux.

A mesma resolução foi utilizada para representação dos valores interpolados de área basal e biomassa do lenho pelo método da krigagem ordinária.

No final, compararam-se as estatísticas de validação entre valores observados e preditos, entre as duas técnicas utilizadas.

Informações complementares também foram utilizadas para validação dos resultados finais, com base na interpretação visual dos mapas gerados (HIEMSTRA; SLUITER, 2011).

Utilizou-se o mapa de predição de área basal gerado por Campoe (2012) a partir de dados obtidos de um censo dos DAPs para uma parte da área de estudo, aos 5.5 anos de idade da floresta. O mapa de área basal possui resolução espacial de 25 m² (pixel de 5 m).

4 RESULTADOS

A seguir apresentam-se as principais contribuições e resultados do presente trabalho. Inicia-se pelo relato sobre o processamento de desbaste da nuvem de pontos, passando pela geração do Modelo Digital de Elevação (DEM) e os perfis de alturas de dossel ajustados para cada parcela experimental. Apresentam-se os resultados encontrados para a análise exploratória das variáveis ALS estudadas e os melhores modelos de regressão encontrados para predição de área basal e biomassa do lenho. Por último ilustram-se os mapas de predição gerados pela extrapolação dos modelos baseados em dados ALS e pela interpolação dos dados de campo resultante de krigagem ordinária.

4.1 Homogeneização da nuvem de pontos

A Figura 15 mostra a informação de densidade de retornos por pixel (1.71 m), sobre a área de estudo. O painel do lado esquerdo da figura representa a nuvem ALS não homogeneizada (nuvem bruta). As áreas em azul indicam pixels com densidade de retornos maior do que o parâmetro nominal de 6 pontos por m².

O aumento da densidade de pontos em relação ao esperado deve-se principalmente ao efeito de sobreposição das faixas do sobrevoo.

No painel direito da Figura 15, visualiza-se a variável densidade de retornos, na nuvem homogeneizada.

Figura 15 – Densidade de retornos da nuvem ALS sobre a área experimental Eucflux, antes e após o processamento de desbaste (remoção aleatória ou raleamento) dos pontos.

A Tabela 7 contém as estatísticas do processo de desbaste de pulsos da nuvem ALS. Enquanto que a nuvem homogeneizada manteve a proporção entre primeiros retornos e outros retornos em 264%, o coeficiente de variação da densidade diminuiu de 72.8% para 30.8%, representando um decréscimo na ordem de 42.3%.

Tabela 7 – Estatísticas de densidade de retornos: nuvem bruta e nuvem desbastada.

Característica	Unidade	Nuvem bruta	Nuvem desbastada
Total de retornos	milhão	28.14	13.08
Primeiros retornos	milhão	20.40	9.49
Outros retornos	milhão	7.74	3.59
Proporção primeiro/todos	%	72.4	72.6
Densidade de retornos	retornos/m ²	14.02	6.52
Desvio padrão	retornos/m ²	10.21	2.01
Coeficiente de variação	%	72.82	30.81

A densidade média do conjunto de dados desbastado resultou em um valor de 6.5 pts/m² ($\sigma = 2\text{pts/m}^2$) ficando bem próxima ao parâmetro inicial configurado (densidade nominal).

4.2 Modelo digital de elevação (DEM)

Não existiram diferenças relevantes entre os Modelos Digitais de Elevação (DEMs) gerados a partir da nuvem de pontos classificada com o algoritmo de Kraus e Pfeifer, e da nuvem classificada com o algoritmo de Evans e Hudak (Figura 16).

Figura 16 – Diferença de altitude do Modelo Digital de Elevação originado a partir da filtragem da nuvem ALS com o algoritmo de Kraus e Pfeifer (1998) e Modelo Digital de Elevação derivado da nuvem classificada com o algoritmo de Evans e Hudak (2007).

A Figura 17 ilustra em duas dimensões (2D) e três dimensões (3D) o Modelo Digital de Elevação do projeto Eucflux construído com 1 metro de resolução espacial. O relevo apresenta gradiente de elevação de aproximadamente 60 metros, variando de 720 m na parte mais baixa até 780 metros na parte alta do terreno.

Figura 17 – Modelo Digital de Elevação (DEM) – 2D (acima) e 3D (em baixo) gerados a partir da nuvem ALS classificada com o algoritmo *Multiscale Curvature Classification* - MCC (EVANS; HUDAK, 2007).

De acordo com Gonçalves (2002), o relevo da área experimental pode ser classificado como plano à suave ondulado, pois a sua maior parte é classificada em até 8% de declividade (Apêndice C, Figura 46).

Na Figura 18, apresenta-se o Modelo Digital de Elevação sombreado (*hillshade*). É possível observar que não há rupturas abruptas de elevação no relevo.

Figura 18 – Modelo Digital de Elevação sombreado (*hillshade*), com 1 metro de resolução. Azimute da fonte de iluminação igual a 315° e ângulo de inclinação acima do horizonte igual a 45°.

Na Figura 18, podem-se visualizar as estradas que delimitam os talhões florestais presentes na área de estudo.

4.3 Perfis de alturas de dossel (CHPs)

A Figura 19 ilustra as distribuições empíricas (histogramas) das alturas provenientes da nuvem ALS nas parcelas experimentais da área de estudo. As curvas em vermelho sobre os histogramas representam as distribuições teóricas modeladas pela fdp Weibull de dois parâmetros. As distribuições de altura foram nomeadas como perfis aparentes de alturas de dossel (*Canopy Height Profiles* - CHPs) (HARDING et al., 2001).

Todas as parcelas apresentaram distribuições de altura com assimetria negativa. Ainda assim, houve considerável variabilidade quanto às características da forma e posição (escala) das funções de densidade probabilidade Weibull ajustadas. Por exemplo, veja os painéis das parcelas de número 04 e 10 (Figura 19).

Na média, 88% dos retornos observados nas parcelas experimentais encontraram-se acima de 20 metros de altura (Apêndice D, Tabela 24). Como pode ser observado na Figura 20, o ajuste das funções de densidade probabilidade Weibull foi mais coerente para o estrato superior da floresta.

Figura 19 – Perfis aparentes de alturas de dossel (CHPs). O eixo vertical (y) mostra as alturas dos retornos da nuvem e o eixo horizontal (x) ilustra a densidade probabilidade de ocorrência dos pontos em cada classe de altura. As linhas sólidas representam funções de densidade probabilidade Weibull ajustadas para os dados empíricos de altura da nuvem ALS.

Figura 20 – Gráfico do tipo QQ_plot (quantil a quantil) por parcela experimental, entre quantís observados de altura na nuvem ALS e quantís teóricos das funções de densidade probabilidade Weibull.

4.4 Variáveis explicativas ALS

O conjunto de variáveis investigadas nesta pesquisa, incluindo-se os parâmetros resultantes das funções de distribuição Weibull pode ser visualizado na Tabela 8.

Tabela 8 – Estatísticas resultantes do processamento da nuvem de pontos nas 23 parcelas experimentais da área de estudo Eucflux.

Parcela	a_CHP	b_CHP	P10	P30	P70	P90	Média	Desv.pad	Variância	<i>p_understory</i>
1	28.84	6.26	21.14	27.70	30.43	31.97	27.64	5.57	30.98	15.41
2	28.91	5.70	19.36	28.00	30.67	31.97	27.69	5.91	34.88	14.24
3	28.65	6.17	20.32	27.29	30.33	31.89	27.39	5.49	30.11	14.36
4	28.77	5.94	18.56	27.17	30.34	32.16	27.24	6.03	36.36	14.05
5	25.13	9.55	20.10	23.77	25.84	27.06	24.02	3.69	13.60	7.93
6	24.26	9.15	21.31	22.82	24.99	26.31	23.28	3.80	14.45	10.42
7	25.18	8.54	18.74	23.56	26.10	27.38	23.77	4.52	20.41	10.88
8	24.95	10.31	20.81	23.58	25.66	26.72	23.88	3.73	13.89	8.26
9	27.94	8.43	22.83	26.27	28.91	30.53	26.94	3.89	15.10	7.51
10	24.12	10.28	20.51	22.55	24.71	26.10	23.22	2.91	8.50	5.84
11	26.92	8.09	20.34	25.27	27.99	29.33	25.49	4.89	23.90	10.44
12	25.99	8.60	20.66	23.70	26.64	28.66	24.80	3.52	12.38	6.19
13	27.29	6.56	19.47	25.90	28.73	30.22	25.96	5.32	28.35	14.75
14	27.32	9.29	22.89	25.91	28.15	29.34	26.18	4.13	17.10	9.64
15	28.26	8.98	24.43	26.76	29.20	30.56	27.25	4.20	17.66	13.78
16	26.61	8.79	21.67	24.94	27.45	29.05	25.42	4.06	16.46	6.58
17	28.12	7.53	21.66	27.00	29.32	30.49	26.89	5.00	25.04	16.53
18	25.00	10.88	21.18	23.39	25.47	26.92	24.06	3.06	9.38	6.68
19	23.36	11.28	19.53	21.89	23.84	24.99	22.42	2.82	7.96	3.99
20	24.66	8.93	20.28	23.21	25.43	26.66	23.48	4.10	16.78	9.83
21	27.56	7.27	20.79	26.23	28.82	30.02	26.20	5.18	26.88	16.13
22	26.72	8.76	20.56	25.05	27.53	29.06	25.42	4.30	18.45	8.84
23	27.78	7.93	21.76	26.26	28.80	30.32	26.53	4.74	22.50	13.22
desv.pad.	1.72	1.56	1.36	1.82	2.05	2.14	1.64	0.93	8.25	3.73
min	23.36	5.70	18.56	21.89	23.84	24.99	22.42	2.82	7.96	3.99
média	26.62	8.40	20.82	25.14	27.62	29.03	25.44	4.39	20.05	10.67
max	28.91	11.28	24.43	28.00	30.67	32.16	27.69	6.03	36.36	16.53

α_{CHP} = parâmetro de escala da fdp Weibull; β_{CHP} = parâmetro de forma da fdp Weibull, P## = percentis ## de altura de primeiros retornos (m), Média = média de altura dos primeiros retornos (m), Desv. pad. = desvio padrão da altura de primeiros retornos (m), Variância = variância da altura de primeiros retornos (m²), *p_understory* = proporção de retornos no estrato de subdossel da floresta (%)

O parâmetro de escala (a_CHP) da distribuição Weibull apresentou intervalo de valores observados semelhante aos intervalos das estatísticas de P30, P70 e altura média (média). O parâmetro de forma da fdp Weibull (b_CHP) variou de 5.7 (parcela 2) até 11.3 (parcela 19) confirmando o padrão de assimetria negativa observado nos histogramas da Figura 19.

A Tabela 9 é a matriz de correlação do coeficiente linear de Pearson (ρ) entre as variáveis ALS candidatas.

Tabela 9 – Matriz de correlação do coeficiente de Pearson (ρ) entre as variáveis preditoras pré-selecionadas.

	a_CHP	b_CHP	P10	P30	P70	P90	Média	Desv.pad	Variância
b_CHP	-0.84								
P10	0.22	0.24							
P30	0.99	-0.84	0.20						
P70	0.99	-0.88	0.14	0.99					
P90	0.99	-0.88	0.13	0.98	0.99				
Média	0.99	-0.80	0.28	0.99	0.99	0.98			
Desv.pad.	0.83	-0.96	-0.25	0.85	0.87	0.85	0.79		
Variância	0.81	-0.96	-0.30	0.84	0.86	0.85	0.77	0.99	
<i>p_understory</i>	0.75	-0.82	0.00	0.79	0.79	0.75	0.73	0.88	0.86

A partir da Tabela 9 os preditores foram alocados em quatro grupos para contabilização de colinearidade ($\rho > 0.9$ ou $\rho < -0.9$).

- a_CHP, P30, P70, P90 e Média.
- b_CHP, Desv.pad. e Variância.
- P10.
- *p_understory*.

Exceto por P10, todos os grupos representaram tipos diferentes de métricas: posição, dispersão e proporção, respectivamente. A variável P10 é uma métrica de posição de altura.

Foi considerada a inclusão de apenas uma variável de cada grupo, para teste e ajuste dos modelos de regressão.

4.5 Modelos lineares

A Tabela 10 mostra a correlação entre as variáveis explicativas ALS e as variáveis respostas área basal e biomassa do lenho.

Tabela 10 – Teste de correlação de Pearson para os atributos de interesse (Y) e variáveis ALS (X). Número de graus de liberdade = 21; nível de confiança = 99%.

Resposta Y	Preditor X	Estimativa ρ	Intervalo de confiança (IC)		Amplitude de IC $\max \rho - \min \rho$
Área basal (G)	P30	0.80	0.49	0.93	0.45
	Média	0.79	0.45	0.93	0.47
	P70	0.78	0.44	0.93	0.48
	a_CHP	0.78	0.43	0.92	0.49
	P90	0.75	0.38	0.91	0.53
	Desv. pad.	0.65	0.20	0.87	0.68
	Variância	0.64	0.19	0.87	0.69
	b_CHP	-0.61	-0.86	-0.13	0.73
	P10	0.29	-0.27	0.71	0.97
	<i>p_understory</i>	0.64	0.18	0.87	0.69
Biomassa do lenho (B)	P30	0.90	0.71	0.97	0.25
	Média	0.89	0.70	0.96	0.27
	a_CHP	0.88	0.67	0.96	0.29
	P70	0.88	0.67	0.96	0.29
	P90	0.86	0.61	0.95	0.34
	Desv. pad.	0.73	0.33	0.90	0.57
	Variância	0.72	0.32	0.90	0.58
	b_CHP	-0.70	-0.89	-0.28	0.62
	P10	0.31	-0.25	0.72	0.96
	<i>p_understory</i>	0.71	0.31	0.90	0.59

As variáveis a_CHP, P30, P70, P90, Média, Desvio padrão, Variância e *p_understory* apresentaram relação positiva com as variáveis de interesse área basal e biomassa do lenho.

Por outro lado, a variável b_CHP mostrou correlação negativa com as variáveis respostas estudadas. A variável P10 não apresentou correlação significativa com área basal e biomassa do lenho (o intervalo de confiança para ρ abrangeu o valor zero).

Não houve violação da pressuposição de distribuição normal bivariada pelo teste de Doornik-Hansen (DOORNIK; HANSEN, 2006).

A Figura 21 mostra a relação entre variáveis não colineares e os atributos florestais de interesse, área basal e biomassa do lenho.

Figura 21 – Relação de área basal e biomassa do lenho com variáveis predictorais ALS. As parcelas experimentais estão indicadas no interior de cada painel.

Na maioria dos painéis da Figura 21, a parcela experimental 22 se comportou como um valor discrepante (*outlier*).

Os valores de área basal e biomassa do lenho nesta parcela podem ter sido subestimados devido ao desvio de +28% entre a área da parcela com base nos pontos georreferenciados em campo (1106 m²) e a área da parcela teórica esperada (864 m²) (Apêndice A, Tabela 22).

A variável de densidade de fustes na parcela 22 foi menor do que três vezes o desvio padrão das parcelas experimentais (Tabela 2). Investigações conduzidas por inspeção visual da nuvem de pontos, e análise dos dados de inventário, não indicam um percentual de falhas e árvores mortas acima do normal. A hipótese mais provável é a de que um dos cantos da parcela 22 não tenha sido georreferenciada corretamente.

O teste de Dixon baseado no atributo florestal densidade de árvores indicou a parcela 22 como sendo um valor discrepante dentro do conjunto de observações. A estatística Q do teste foi igual a 0.4677 e o valor de probabilidade (p valor) igual a 0.0437. Portanto, essa parcela foi excluída das análises posteriores.

4.5.1 Área basal

Na Tabela 11 estão os modelos desenvolvidos para predição de área basal como função das variáveis explicativas selecionadas nas etapas anteriores do processamento. O viés entre valores observados e valores preditos foi quase nulo (<0.01) em todos os modelos ajustados.

Tabela 11 – Modelos lineares de área basal dependentes de variáveis explicativas ALS, com $n = 22$ e $p\_valor < 0.001$. Os valores dentro de parênteses representam o desvio padrão para os parâmetros estimados do modelo.

#	Modelo	adj.R ²	RMSE (m ² .ha ⁻¹)	rRMSE %	AIC	VIF	Obs
01	$G = -25.18 + 1.99*P30 + 0.64*b\_CHP$ (9.77) (0.29) (0.34)	0.82	1.24	4.10	79.9	3.43	-
02	$G = -8.26 + 1.53*P30$ (4.18) (0.17)	0.80	1.35	4.50	81.7	-	-
03	$G = -12.04 + 1.59*a\_CHP$ (5.01) (0.19)	0.77	1.45	4.80	84.7	-	-
04	$G = 24.15 + 0.56*p\_understory$ (1.57) (0.14)	0.42	2.29	7.60	104.9	-	-
05	$G = 41.17 - 1.31*b\_CHP$ (2.82) (0.33)	0.41	2.31	7.70	105.3	-	-
06	$\sqrt{G} = -9.75 + 4.57*\ln(P30) + 0.06*b\_CHP$ (2.3) (0.65) (0.03)	0.83	..	2.00-	-25.9	3.38	-
07	$\sqrt{G} = -7.05 + 0.01*P10^{ns} + 3.79*\ln(média)$ (1.49) (0.02) (0.48)	0.77	..	2.40	-19.1	1.09	a

adj.R² = coeficiente de determinação ajustado, RMSE = raiz do erro quadrático médio, rRMSE = RMSE relativo, AIC = critério de informação de Akaike, VIF = fator de inflação da variância, ns = variável não significativa, a = Zonete; Rodriguez e Packalén (2010).

Os preditores mais significativos de área basal foram o percentil 30 (P30), e os parâmetros de escala e forma da fdp Weibull (a_CHP e b_CHP , respectivamente).

O modelo 1 foi o melhor entre aqueles com a variável de área basal não transformada. Ele apresentou o maior R² ajustado (0.82), o menor valor de raiz do erro quadrático médio (1.24 m².ha⁻¹) e também o menor índice de AIC (79.9). Não foi observado colinearidade entre os preditores P30 e b_CHP , os quais apresentaram fator de inflação da variância igual a 3.43.

O modelo 7 reproduzido de Zonete; Rodriguez e Packalén (2010) apresentou bom ajuste para predição da raiz quadrada da área basal, principalmente devido a variável independente de logaritmo natural da média – $\ln(média)$. Entretanto, a variável P10 não se mostrou significativa na explicação da variável resposta (ver também Tabela 10 e Figura 21).

O melhor modelo obtido para predição de área basal transformada com raiz quadrada foi o de número 6, por meio das variáveis explicativas logaritmo natural de P30 e b_CHP .

As próximas figuras ilustram a relação entre os valores observados e preditos de área basal, assim como a verificação do atendimento às pressuposições da regressão linear: i) distribuição normal de resíduos, ii) homoscedasticidade e iii) independência dos erros aleatórios.

Na análise gráfica, foram utilizados os resíduos estudentizados. A Figura 22 mostra esses resultados para o modelo 1 da Tabela 11.

Figura 22 – Área basal regredida em P30 e b_CHP (modelo 1). Valores preditos com intervalo de predição (95% confiança) *versus* valores observados (painel superior esquerdo), normalidade de resíduos (superior direito), homoscedasticidade (inferior esquerdo), e independência de resíduos (inferior direito).

É possível observar que todos os intervalos de predição na Figura 22 tocam a linha 1:1 entre valores preditos pelo modelo e valores observados, o que é uma indicação de bom ajuste da regressão. O menor e maior valores preditos para área basal foram iguais a $25.5 \text{ m}^2.\text{ha}^{-1}$ e $34.1 \text{ m}^2.\text{ha}^{-1}$, respectivamente. Os resíduos estudentizados apresentaram distribuição normal e não houve heterogeneidade de variâncias. O comportamento espalhado dos resíduos no painel inferior direito indica a não existência de relação entre eles (portanto, independência).

A Figura 23 mostra os mesmos gráficos da figura anterior, porém inerentes ao modelo 3 da Tabela 11.

Figura 23 – Área basal em função da variável a_CHP (modelo 3). O painel superior esquerdo da figura mostra os valores preditos pelo modelo com seus respectivos intervalos de predição (95% de confiança) *versus* os valores observados. Os outros painéis ilustram: normalidade de resíduos (superior direito), homoscedasticidade (inferior esquerdo) e independência dos erros aleatórios (inferior direito).

Neste modelo, a parcela de número 12 se destoa das demais observações. No painel superior esquerdo, ela é o ponto mais baixo no eixo das ordenadas. Repare que o intervalo de predição não abrange a linha 1:1 entre valores observados e preditos.

A distribuição de resíduos estudentizados apresentou leve grau de assimetria, mas ainda assim verificou-se condição de normalidade pelo teste de hipóteses de Shapiro-Wilk (Tabela 13). As pressuposições de homoscedasticidade e independência de resíduos também foram atendidas.

Este modelo pode ser melhorado pela inclusão da variável densidade de fustes, a qual foi obtida a partir do inventário nas parcelas de campo (Apêndice A, Tabela 22). A Tabela 12 mostra os resultados para o modelo 8.

Tabela 12 – Área basal em função do parâmetro de escala da fdp Weibull (a_{CHP}) ajustada para as alturas do retornos da nuvem ALS e da variável densidade de fustes, com $n = 22$ e $p\text{-valor} < 0.001$. Os valores dentro de parênteses representam o desvio padrão para os parâmetros estimados do modelo.

#	Modelo	adj.R ²	RMSE (m ² .ha ⁻¹)	rRMSE %	AIC	VIF
08	$G = -37.6 + 1.8 \cdot a_{\text{CHP}} + 0.013 \cdot \text{dens.fustes}$ (5.02) (0.11) (0.002)	0.92	0.83	2.75	62	1.1

adj.R² = coeficiente de determinação ajustado, RMSE = raiz do erro quadrático médio, rRMSE = RMSE relativo, AIC = critério de informação de Akaike, VIF = fator de inflação da variância.

A Tabela 12 e a Figura 24 mostram boas estatísticas de ajuste para área basal em função de a_{CHP} e densidade de fustes.

Figura 24 – Área basal com variáveis explicativas a_{CHP} e densidade de árvores (modelo 8). Valores preditos com intervalo de predição (95% confiança) versus valores observados (painel superior esquerdo), normalidade de resíduos (superior direito), homoscedasticidade (inferior esquerdo) e independência de resíduos (inferior direito).

A Figura 25 apresenta os resultados gráficos para área basal transformada com raiz quadrada e predita pelas variáveis logaritmo natural de P30 e o parâmetro de forma da fdp Weibull (b_CHP) não transformado (modelo 6).

Figura 25 – Raiz quadrada da área basal predita pelo logaritmo natural de P30 e b_CHP não transformado (modelo 6). O painel superior esquerdo ilustra os valores preditos para raiz quadrada da área basal com seus respectivos intervalos de predição (95% de confiança) *versus* os valores observados. O painel direito superior mostra a distribuição dos resíduos, enquanto que os painéis inferiores expressam homoscedasticidade (esquerda) e independência de resíduos (direita).

O modelo de área basal transformado pela raiz quadrada (modelo 6) apresentou resultados ligeiramente melhores quanto a distribuição de resíduos em relação ao mesmo modelo com variáveis não transformadas (modelo 1) (ver Figura 22 e Figura 25). Entretanto, não houve melhorias nas pressuposições de homoscedasticidade e independência dos termos de erro aleatório (Tabela 13).

A Tabela 13 sumariza os resultados dos testes estatísticos utilizados para uma segunda verificação do atendimento dos modelos às pressuposições da regressão.

Os testes de normalidade e de homoscedasticidade foram conduzidos utilizando-se os resíduos estudentizados, enquanto que a verificação da independência de resíduos foi conduzida com os resíduos não transformados.

Tabela 13 – Testes de hipótese sobre modelos de área basal: normalidade de resíduos estudentizados (Shapiro-Wilk), homoscedasticidade de resíduos estudentizados (Breusch-Pagan) e independência de resíduos não transformados (Durbin-Watson). Os valores de W, BP e DW são as estatísticas obtidas para os respectivos testes.

#	Modelo	Shapiro-Wilk		Breusch-Pagan		Durbin-Watson	
		W	p valor	BP	p.valor	DW	p.valor
1	$G = -25.18 + 1.99*P30 + 0.64*b\_CHP$	0.98	0.83	1.9546	0.38	2.47	0.37
2	$G = -8.26 + 1.53*P30$	0.98	0.95	0.0271	0.87	2.15	0.79
3	$G = -12.04 + 1.59*a\_CHP$	0.93	0.10	0.008	0.93	2.45	0.25
4	$G = 24.15 + 0.56*p\_understory$	0.98	0.84	0.7691	0.38	1.65	0.44
5	$G = 41.17 - 1.31*b\_CHP$	0.98	0.89	0.7476	0.39	1.58	0.25
6	$\sqrt{G} = -9.75 + 4.57*\ln(P30) + 0.06*b\_CHP$	0.99	0.98	2.1958	0.33	2.58	0.22
8	$G = -37.6 + 1.8*a\_CHP + 0.013*dens.fustes$	0.96	0.53	0.124	0.94	2.23	0.51

Todos os testes mostrados na Tabela 13 falharam em rejeitar a hipótese nula (p valor maior do que 0.05). Isto significa dizer que as pressuposições de regressão linear foram completamente atendidas.

4.5.2 Biomassa do lenho

Na Tabela 14, apresentam-se os modelos lineares ajustados para predição de biomassa do lenho. O viés observado para as equações ajustadas foi próximo de zero (<0.01).

Tabela 14 – Modelos lineares de biomassa do lenho em função dos preditores ALS, com $n = 22$ e $p\_valor < 0.001$. Os valores dentro de parênteses representam o desvio padrão para os parâmetros estimados do modelo.

#	Modelo	adj.R ²	RMSE (Mg.ha ⁻¹)	rRMSE %	AIC	VIF	Obs
9	$B = -287.3 + 16.23*P30 + 4.34*b\_CHP$ (49.37) (1.46) (1.70)	0.93	6.26	3.99	151.1	3.43	-
10	$B = -207.24 + 13.69*a\_CHP$ (27.63) (1.03)	0.89	7.98	5.08	159.8	-	-
11	$B = 253.98 - 11.56*b\_CHP$ (20.91) (2.45)	0.50	17.13	10.91	193.4	-	-
12	$B = 104.86 + 4.85*p\_understory$ (11.77) (1.03)	0.50	17.17	10.93	193.5	-	-
13	$\ln(B) = -3.9 + 2.63*\ln(P30) + 0.16*\sqrt{b\_CHP}$ (0.88) (0.23) (0.06)	0.93	..	0.79	-71.6	3.33	-
14	$\ln(B) = 2.89 + 0.09*P30$ (0.15) (0.006)	0.91	..	0.99	-65.6	-	b
15	$\ln(B) = 4.55 + 0.11*P30 - 0.7*\ln(P90)^{ns}$ (1.60) (0.03) (0.67)	0.91	..	0.99	-64.8	22.4	b
16	$\ln(B) = 2.64 + 0.09*média + 0.0002*\sqrt{P70}^{ns}$ (0.86) (0.04) (0.38)	0.89	..	0.99	-60.9	40.4	b

adj.R² = coeficiente de determinação ajustado, RMSE = raiz do erro quadrático médio, rRMSE = RMSE relativo, AIC = critério de informação de Akaike, VIF = fator de inflação da variância, ns = não significativo, b = adaptado de Zonete; Rodriguez e Packalén (2010).

Semelhantemente aos modelos de área basal, o melhor ajuste entre aqueles com variável resposta não transformada foi o de biomassa de lenho dependente dos preditores P30 e b_CHP (modelo 9). Ele apresentou estatística de adj.R² igual a 0.93 e RMSE na ordem de 6 Mg.ha⁻¹.

Em segundo lugar, o parâmetro de escala da fdp Weibull (a_CHP) resultou em um bom ajuste para biomassa de lenho, com RMSE de 8 Mg.ha⁻¹ e RMSE relativo na ordem de 5.1% (modelo 10).

Embora os preditores b_CHP e p_understory tenham mostrado correlação com biomassa de lenho (modelos 11 e 12, respectivamente), as estatísticas escolhidas para seleção não indicaram bom desempenho de ajuste.

O modelo 13, com logaritmo natural de P30 e a raiz quadrada de b_CHP resultaram no melhor ajuste para a variável transformada de logaritmo natural da biomassa do lenho ($R^2 = 0.93$ and $AIC = -71.6$). O modelo adaptado de Zonete; Rodriguez e Packalén (2010) que teve o logaritmo natural da biomassa de lenho em função da variável P30 não transformada

apresentou o segundo melhor ajuste entre os modelos com variável resposta transformada ($R^2 = 0.91$ and $AIC = -65.6$) (modelo 14).

Os outros modelos adaptados de Zonete; Rodriguez e Packalén (2010) (15 e 16, na Tabela 14) não apresentaram resultados satisfatórios, devido à presença de colinearidade entre os preditores ($VIF = 22.4$ no modelo 15 e $VIF = 40.4$ no modelo 16).

A Figura 26 mostra os resultados do modelo 9 para valores preditos e observados de biomassa do lenho. Também são mostrados os resultados gráficos da regressão para os resíduos estudatizados: normalidade, homoscedasticidade e independência.

Figura 26 – Biomassa de lenho regredida sobre P30 e b_CHP (modelo 9). Os painéis ilustram: valores preditos com intervalo de predição (95% confiança) *versus* valores observados (superior esquerdo), normalidade de resíduos (superior direito), homoscedasticidade (inferior esquerdo), e independência dos erros aleatórios (inferior direito).

No painel superior esquerdo da Figura 26, pode-se visualizar que os valores observados ficaram próximos à linha 1:1 de valores preditos e observados indicando um bom ajuste do modelo e sem a presença de valores discrepantes.

O mínimo valor predito para biomassa de lenho foi de 116.8 Mg.ha^{-1} , enquanto que o máximo foi de 191.8 Mg.ha^{-1} . Os resíduos estudatizados apresentaram as seguintes características: distribuição normal (painel superior direito), homoscedasticidade ao longo do intervalo de valores preditos (painel inferior esquerdo) e ausência de autocorrelação (painel inferior direito).

Na sequência, a Figura 27 ilustra o ajuste da variável de interesse biomassa do lenho modelada como função do parâmetro de escala da fdp Weibull (a_{CHP}) (modelo 10).

Figura 27 – Biomassa do lenho em função da variável a_{CHP} (modelo 10). O painel superior esquerdo da figura mostra os valores preditos e os intervalos de predição (95% de confiança) *versus* valores observados. Os outros painéis ilustram: normalidade de resíduos (superior direito), homoscedasticidade (inferior esquerdo) e independência dos erros aleatórios (inferior direito).

Na fileira inferior da Figura 27 visualiza-se um ponto separado e abaixo dos pontos remanescentes (parcela 12). Neste local, o valor observado de biomassa do lenho foi de aproximadamente 125.5 Mg.ha^{-1} enquanto que o valor predito pelo modelo foi de 148.5 Mg.ha^{-1} (superestimação de 17.3%).

Assim como observado para a variável de área basal, o preditor a_{CHP} mostrou resultados satisfatórios para predição de biomassa do lenho quando combinada com a variável densidade de fustes (modelo 17, Tabela 15).

Tabela 15 – Biomassa do lenho em função do parâmetro de escala da fdp Weibull (a_{CHP}) para perfil de altura de dossel (CHP) e da variável densidade de fustes, com $n = 22$ e $p\_valor < 0.001$. Os valores dentro de parênteses representam o desvio padrão para os parâmetros estimados do modelo.

#	Modelo	adj.R ²	RMSE (m ² .ha ⁻¹)	rRMSE %	AIC	VIF
17	$B = -304.13 + 14.52*a_{\text{CHP}} + 0.05*dens.fustes$ (40.1) (0.92) (0.02)	0.92	6.59	4.19	153.4	1.1

adj.R² = coeficiente de determinação ajustado, RMSE = raiz do erro quadrático médio, rRMSE = RMSE relativo, AIC = critério de informação de Akaike, VIF = fator de inflação da variância.

A adição da variável explicativa densidade de fustes aumentou o coeficiente de determinação ajustado (adj. R²) em 3.3% (de 0.89 no modelo 10, para 0.92 no modelo 17). A estatística de RMSE diminuiu em 17.5% com relação ao modelo 10 (8 Mg.ha⁻¹ to 6.6 Mg.ha⁻¹) e também apresentou melhor ajuste pelo critério de informação de Akaike (AIC) (159.8 no modelo 10 *versus* 153.4 no modelo 17).

A Figura 28 ilustra o comportamento dos resíduos no modelo 17, da Tabela 15.

Figura 28 – Modelo de biomassa do lenho com variáveis explicativas a_{CHP} e densidade de fustes (modelo 17). Valores preditos e intervalos de predição (95% de confiança) *versus* valores observados (painel superior esquerdo), normalidade de resíduos (superior direito), homogeneidade de dispersão dos erros aleatórios (inferior esquerdo) e independência de resíduos (inferior direito).

No painel inferior direito, é possível visualizar que os resíduos estudentizados ficaram concentrados principalmente no intervalo $[-2,2]$, inclusive a parcela de número 12 (Figura 28).

As informações do melhor ajuste encontrado para a variável de biomassa do lenho transformada pelo logaritmo natural são apresentadas na Figura 29 (modelo 13). O modelo 13 utiliza as seguintes variáveis independentes: logaritmo natural de P30 e o parâmetro de forma (b_{CHP}) da fdp Weibull transformada pela raiz quadrada.

Figura 29 – Modelo do logaritmo natural de biomassa do lenho e variáveis explicativas de logaritmo natural de P30 e raiz quadrada do parâmetro de forma da fdp Weibull (b_{CHP}) (modelo 13). Valores preditos e intervalos de predição (95% de confiança) *versus* valores observados (painel superior esquerdo), normalidade de resíduos (superior direito), homoscedasticidade (inferior esquerdo) e independência dos erros aleatórios (inferior direito).

Os resultados observados na Figura 29 foram similares aos resultados obtidos no mesmo modelo, mas com variáveis não transformadas (modelo 9, Figura 26).

Na Tabela 16 encontram-se as estatísticas resultantes dos testes de hipótese para verificação das pressuposições de normalidade de resíduos, homogeneidade de variâncias e independência entre os erros aleatórios da regressão, em todos os modelos ajustados para predição de biomassa do lenho.

Tabela 16 – Testes de hipótese sobre modelos de biomassa do lenho: normalidade de resíduos estudentizados (Shapiro-Wilk), homoscedasticidade de resíduos estudentizados (Breusch-Pagan) e independência de resíduos não transformados (Durbin-Watson). Os valores de W, BP e DW são as estatísticas obtidas para os respectivos testes.

Modelo	Shapiro-Wilk		Breusch-Pagan		Durbin-Watson	
#	W	p.valor	DP	p.valor	DW	p.valor
09 $B = -287.3 + 16.23*P30 + 4.34*b\_CHP$	0.97	0.72	0.998	0.61	2.1	0.94
10 $B = -207.24 + 13.69*a\_CHP$	0.93	0.13	0.066	0.80	2.12	0.83
11 $B = 253.98 - 11.56*b\_CHP$	0.93	0.11	0.948	0.33	1.42	0.15
12 $B = 104.86 + 4.85*p\_understory$	0.96	0.42	0.014	0.91	1.53	0.24
13 $\ln(B) = -3.9 + 2.63*\ln(P30) + 0.16*\sqrt{b\_CHP}$	0.97	0.73	0.348	0.84	2.31	0.58
14 $\ln(B) = 2.89 + 0.09*P30$	0.96	0.54	0.485	0.49	1.98	0.86
17 $B = -304.1 + 14.52*a\_CHP + 0.05*dens.fustes$	0.97	0.82	1.0898	0.58	2.12	0.75

Na Tabela 16, os p valores observados em todos os testes estatísticos foram superior ao nível de significância de 0.05, e por isso não foi possível rejeitar nenhuma das hipóteses nulas testadas: normalidade, homoscedasticidade e independência de resíduos.

4.5.3 Validação

Na Tabela 17 estão apresentados os resultados obtidos para a validação cruzada pelo método *leave-one-out* (LOOCV), sobre os melhores modelos ajustados para predição de área basal e biomassa do lenho.

Tabela 17 – Validação cruzada *leave-one-out*.

#	Modelo	rRMSE	nRMSE
		%	%
1	$G = -25.18 + 1.99*P30 + 0.64*b\_CHP$	4.6	15.2
3	$G = -12.04 + 1.59*a\_CHP$	5.2	16.9
6	$\sqrt{G} = -9.75 + 4.57*\ln(P30) + 0.06*b\_CHP$	2.3	15
9	$B = -287.3 + 16.23*P30 + 4.34*b\_CHP$	4.6	9.1
10	$B = -207.24 + 13.69*a\_CHP$	5.5	10.7
13	$\ln(B) = -3.9 + 2.63*\ln(P30) + 0.16*\sqrt{b\_CHP}$	0.9	8.6

rRMSE = raiz do erro quadrático médio relativo, nRMSE = RMSE normalizado, G = área basal, B = Biomassa do lenho.

Não houve ocorrência de *overfitting* de nenhum modelo aos dados amostrados. Os RMSE relativos foram de aproximadamente até 5%, enquanto que os RMSEs normalizados variaram de 15% a 17% em área basal e de 8.6% até 10.7% em biomassa do lenho.

A Tabela 18 apresenta os resultados de predição dos modelos lineares ajustados para a variável de interesse área basal sobre o conjunto de dados provenientes das parcelas de validação (ver item 3.2.2.; Parcelas de validação).

É importante lembrar que os dados do conjunto de validação foram coletados com um ano de antecedência ao sobrevoo ALS e a realização do inventário de campo das parcelas experimentais.

Tabela 18 – Estatísticas de predição para área basal e biomassa do lenho sobre o conjunto de dados de validação.

#	Modelo	RMSE	rRMSE	nRMSE	cor
		-	%	%	[-1,1]
3	$G = -12.04 + 1.59*a\_CHP$	4.07	15.27	30.93	0.78
6	$\sqrt{G} = -9.75 + 4.57*\ln(P30) + 0.06*b\_CHP$	0.43	8.34	34.47	0.75
1	$G = -25.18 + 1.99*P30 + 0.64*b\_CHP$	4.70	17.63	35.71	0.74
13	$\ln(B) = -3.9 + 2.63*\ln(P30) + 0.16*\sqrt{b\_CHP}$	0.25	5.19	43.59	0.83
10	$B = -207.24 + 13.69*a\_CHP$	33.44	26.74	45.96	0.82
9	$B = -287.3 + 16.23*P30 + 4.34*b\_CHP$	38.13	30.49	52.41	0.80

RMSE = raiz do erro quadrático médio, rRMSE = RMSE relativo, nRMSE = RMSE normalizado, cor = coeficiente de correlação linear de Pearson (ρ).

As melhores estatísticas de predição na análise de validação foram encontradas para os modelos 3 e 6 (área basal) e modelos 13 e 10 (biomassa do lenho).

A Figura 30 e Figura 31 mostram a relação entre valores preditos e valores observados nos modelos de melhor ajuste para área basal e biomassa do lenho, ao conjunto de dados de validação utilizado.

Figura 30 – Área basal nas parcelas de validação: predito e observado. Dados observados foram coletados com um ano de antecedência ao aerolevantamento LiDAR. nRMSE = raiz do erro quadrático médio normalizado, e cor = coeficiente de correlação linear de Pearson (ρ).

Em ambos os painéis da Figura 30 pode-se visualizar que os valores preditos foram superestimados em relação aos valores observados, principalmente devido à diferença de 1 ano entre variáveis ALS e inventário nas parcelas de validação. Ainda assim, observou-se uma tendência linear entre eles ($\rho = 0.78$ e $\rho = 0.75$).

As parcelas mais produtivas em área basal (13 e 33) apresentaram uma relação próxima entre predição e mensurações de campo, mesmo com a diferença de idade.

Embora as estatísticas de validação tenham mostrado bom ajuste aos dois modelos apresentados na Figura 30, o primeiro cuja área basal foi predita em função do parâmetro de escala da distribuição Weibull (a_CHP) foi ligeiramente melhor do que o de área basal transformada pela raiz quadrada.

Figura 31 – Biomassa do lenho nas parcelas de validação: predito e observado. Dados observados foram coletados com um ano de antecedência ao aerolevantamento LiDAR. nRMSE = raiz do erro quadrático médio normalizado, e cor = coeficiente de correlação linear de Pearson (ρ).

Igualmente à variável de área basal, os valores preditos e observados de biomassa do lenho apresentaram uma relação com tendência linear ($\rho = 0.82$ and $\rho = 0.83$). Como já eram esperados, os pontos do gráfico deslocaram-se à esquerda da linha 1:1, pois as variáveis de predição do modelo foram mensuradas um ano após o inventário das parcelas de validação.

4.6 Krigagem ordinária

4.6.1 Semi-variogramas

A Figura 32 mostra os semi-variogramas empírico e teórico, construídos a partir das informações de área basal das parcelas experimentais na área de estudo.

Figura 32 – Semi-variograma empírico e teórico (Gaussiano) para a variável de interesse área basal. Os pontos do semi-variograma representam o número de pares observados na classe k .

O melhor ajuste de semi-variograma foi observado para o modelo Gaussiano com os seguintes parâmetros: pepita igual a 1.9 (m²/ha)², patamar de 17 (m²/ha)² e alcance de 519 metros (eq. 29). A soma dos quadrados dos resíduos foi aproximadamente zero (0.00046).

$$\gamma G(\bar{h}_k) = 1.9 + (17 - 1.9) \left(1 - e^{\left(-\frac{\bar{h}_k^2}{519^2} \right)} \right) \text{ para } 0 < \bar{h}_k < 519 \quad (29)$$

onde:

$\gamma G(\bar{h}_k)$ = semi-variância da área basal na distância $\bar{h}_k$ (m²/ha)².

$\bar{h}_k$ = distância média $\bar{h}$ da classe k (metros).

Figura 33 – Semi-variograma empírico e teórico (Gaussiano) para a variável de interesse biomassa do lenho. Os pontos do semi-variograma representam o número de pares observados na classe k .

Assim como para área basal, o melhor modelo de semi-variograma teórico para biomassa do lenho foi o de Gauss (pepita=128, patamar=1129 e alcance=574) (eq. 30). A soma de quadrados dos resíduos foi igual a 4.11.

$$\gamma B(\bar{h}_k) = 128 + (1129 - 128) \left(1 - e^{\left(-\frac{\bar{h}_k^2}{574^2} \right)} \right) \text{ para } 0 < \bar{h}_k < 574 \quad (30)$$

onde:

$\gamma B(\bar{h}_k)$ = semi-variância da biomassa de lenho na distância $\bar{h}_k$ (Mg/ha)².

$\bar{h}_k$ = distância média $\bar{h}$ da classe k (metros).

Os dados provenientes das parcelas experimentais de campo para área basal e biomassa de lenho mostraram correlação espacial até uma distância aproximada de 600 metros (alcance de 519 m e 574 m, respectivamente).

4.6.2 Validação

A Tabela 19 contém as estatísticas da análise de validação cruzada para os dados de área basal e biomassa do lenho, interpolados nas mesmas localidades das parcelas experimentais de campo.

Tabela 19 – Validação cruzada para krigagem ordinária realizada com base nas parcelas experimentais de campo.

Variável	Viés	RMSE	rRMSE	nRMSE	cor
	-	-	%	%	[-1,1]
Área basal (G)	-0.04	2.7	8.9	29.3	0.56
Biomassa do lenho (B)	-0.61	20.0	12.7	25.0	0.63

RMSE = raiz do erro quadrático médio, rRMSE = RMSE relativo, nRMSE = RMSE normalizado. cor = coeficiente de correlação linear de Pearson (ρ).

A estatística de viés mostra uma pequena tendência de superestimação dos valores interpolados na krigagem ordinária ($0.04 \text{ m}^2.\text{ha}^{-1}$ de área basal e $0.61 \text{ Mg}.\text{ha}^{-1}$ para biomassa do lenho).

Os valores de RMSE relativo (rRMSE) e RMSE normalizado (nRMSE) foram maiores do que os observados na validação cruzada dos modelos de regressão.

Para área basal o rRMSE foi 71% maior do que o observado na validação cruzada do modelo 3 (G em função de a_CHP). O nRMSE na krigagem ordinária foi superior em 73.3% para o mesmo modelo (Tabela 17 e Tabela 19).

Com relação a variável de biomassa do lenho, as estatísticas de rRMSE e nRMSE foram maiores do que na validação cruzada do modelo linear 10 (B em função de a_CHP) em 130% e 133%, respectivamente.

Os coeficientes de correlação linear de Pearson obtidos na validação cruzada da krigagem ordinária indicam correlação moderada entre valores observados e valores interpolados, para as parcelas experimentais.

A Tabela 20 mostra as estatísticas de exatidão e precisão da interpolação de área basal e biomassa do lenho na krigagem ordinária para as localidades das parcelas de validação da área de estudo.

Tabela 20 – Estatísticas de interpolação por krigagem ordinária para área basal e biomassa do lenho sobre o conjunto de dados de validação.

Variável	RMSE	rRMSE	nRMSE	cor
	-	%	%	[-1,1]
Área basal (G)	3.92	14.71	29.79	0.71
Biomassa do lenho (B)	31.29	25.02	43.01	0.71

RMSE = raiz do erro quadrático médio. rRMSE = RMSE relativo, nRMSE = RMSE normalizado, cor = coeficiente de correlação linear de Pearson (ρ).

As estatísticas de raiz do erro quadrático médio (absoluta, relativa e normalizada) na krigagem ordinária foram semelhantes às encontradas para os modelos lineares de área basal e biomassa do lenho (modelos 1, 3, 10 e 13) (Tabela 18 e Tabela 20).

Entretanto, a correlação linear entre valores preditos e observados na krigagem ordinária foi menor em relação aos melhores modelos de regressão obtidos para predição das variáveis de interesse.

Esta diferença foi mais acentuada para a variável de biomassa do lenho, em que a correlação (ρ) entre interpolado e observado foi de 0.71, enquanto que para os modelos de regressão o valor de ρ foi de 0.83 para o modelo 13 ($\ln(B) = \ln(P30) + \sqrt{b\_CHP}$) e de 0.82 para o modelo 10 (B em função de a_CHP).

A Figura 34 ilustra graficamente os valores interpolados pela técnica de krigagem ordinária e os valores observados nas parcelas de validação.

Figura 34 – Área basal e biomassa do lenho nas parcelas de validação: interpolado e observado. Dados das parcelas de validação foram coletados com um ano de antecedência aos dados utilizados para interpolação por krigagem ordinária. nRMSE = raiz do erro quadrático médio normalizado, e cor = coeficiente de correlação linear de Pearson (ρ).

Assim como observado nos modelos de regressão linear as parcelas de validação mais produtivas (13 e 33) fugiram da tendência linear formada pelas outras observações.

4.7 Mapas de predição

4.7.1 Modelos lineares

A Figura 35 mostra a variação espacial das métricas ALS, pertencentes aos modelos selecionados, sobre a área experimental Eucflux.

Figura 35 – Variáveis explicativas: Percentil 30 (P30), parâmetros de escala (a_CHP) e forma (b_CHP) da função de densidade probabilidade Weibull ajustada para as alturas dos retornos da nuvem ALS.

As variáveis de altura P30 e parâmetro de escala da fdp Weibull (a_CHP) se comportaram de forma parecida, em que os valores mais altos foram obtidos nas partes mais baixas do terreno.

A variável do parâmetro de forma da distribuição Weibull (b_{CHP}) apresentou comportamento inverso às variáveis a_{CHP} e P_{30} , em que os maiores valores foram observados nas partes mais altas do terreno. Nota-se uma leve influência do desenho das faixas de sobrevoo no mapa de b_{CHP} .

A Figura 36 ilustra o mapa de predição da variável raiz quadrada da área basal dependente dos preditores logaritmo natural de P_{30} e b_{CHP} não transformada (modelo 6). O painel de baixo da Figura 36 expressa os valores de área basal retransformados para a escala original de acordo com a equação 31:

$$E(G|P_{30}, b_{\text{CHP}}) = E(B_0 + B_1 * \ln(P_{30}) + B_2 * b_{\text{CHP}} + \epsilon)^2 \quad (31)$$

onde:

$E(G|P_{30}, b_{\text{CHP}})$ = esperança de área basal condicionada aos valores de P_{30} e b_{CHP} .

G = área basal ($\text{m}^2.\text{ha}^{-1}$).

P_{30} = percentil 30 (metros).

b_{CHP} = parâmetro de forma da função de densidade probabilidade Weibull ajustada para altura de retornos da nuvem ALS.

Os valores de área basal foram agrupados em classes com intervalos de $3 \text{ m}^2.\text{ha}^{-1}$ para facilitar a visualização de áreas contíguas da variável de interesse.

A área basal média da Figura 36 foi de $29.9 \text{ m}^2.\text{ha}^{-1}$ com desvio padrão (σ) de aproximadamente $3.2 \text{ m}^2.\text{ha}^{-1}$. Essa área basal está de acordo com os dados obtidos em inventários de campo (Tabela 2).

Figura 36 – Mapas de predição de área basal em função das variáveis de Percentil 30 (P30) e parâmetro de forma da distribuição Weibull (b_CHP) (modelo 6).

Na Figura 37, visualiza-se o mapa de predição de área basal em função do parâmetro de escala da fdp Weibull (a_{CHP}).

Figura 37 – Mapa de predição de área basal em função da variável parâmetro de escala da distribuição Weibull (a_{CHP}) (modelo 3).

A Figura 37 proveniente do melhor modelo de regressão ajustado segundo as estatísticas de validação (Tabela 18 e Figura 30) mostrou melhor nitidez de áreas contíguas para área basal do que os mapas da Figura 36.

A área basal média do povoamento de acordo com os valores preditos na Figura 37 é de $29.8 \text{ m}^2.\text{ha}^{-1}$ ($\sigma = 2.5 \text{ m}^2.\text{ha}^{-1}$). Esse valor é igual à média de área basal encontrada com os valores de inventário das parcelas experimentais (Tabela 2).

A Figura 38 e Figura 39 ilustram os mapas de predição de biomassa do lenho sobre a área de estudo, de acordo com os modelos de regressão 13 e 10, respectivamente.

Figura 38 – Mapas de predição de biomassa do lenho em função das variáveis de Percentil 30 (logaritmo natural de P30) e do parâmetro de forma da distribuição Weibull (raiz quadrada de b_CHP) (modelo 13).

O painel de baixo da Figura 38 expressa a variável de biomassa do lenho (B) retransformada do logaritmo natural no modelo de regressão 13, de acordo com a equação 32:

$$E(B|P_{30}, b_{\text{CHP}}) = \left(e^{(B_0 + B_1 \ln(P_{30}) + B_2 \sqrt{b_{\text{CHP}}})} \right) \left(\frac{\sum_{i=1}^n e^{\varepsilon_i}}{n} \right) \quad (32)$$

onde:

$E(B|P_{30}, b_{\text{CHP}})$ = esperança de biomassa do lenho condicionada aos valores de P_{30} e b_{CHP} .

B = biomassa do lenho ($\text{Mg} \cdot \text{ha}^{-1}$).

P_{30} = percentil 30 (metros).

b_{CHP} = parâmetro de forma da função de densidade probabilidade Weibull ajustada para altura de retornos da nuvem ALS.

A biomassa de lenho média por hectare na Figura 38 foi de $154.24 \text{ Mg} \cdot \text{ha}^{-1}$ e o desvio padrão (σ) igual a $25.61 \text{ Mg} \cdot \text{ha}^{-1}$. Os valores médios preditos ficaram próximos dos valores médios das parcelas experimentais de campo ($155.1 \text{ Mg} \cdot \text{ha}^{-1}$ e $\sigma = 26.56 \text{ Mg} \cdot \text{ha}^{-1}$).

O volume médio de madeira sem casca estimado foi de $351.3 \text{ m}^3 \cdot \text{ha}^{-1}$ (média de $0.44 \text{ g} \cdot \text{cm}^{-3}$ de densidade básica da madeira obtida de 50 árvores, CAMPOE et al., 2012). O incremento médio anual (IMA) aos 6.7 anos de idade foi igual a $52.6 \text{ m}^3 \cdot \text{ha}^{-1} \cdot \text{ano}^{-1}$.

O volume total sem casca predito na área experimental Eucflux foi de 68313 m^3 , o que representou +13.6% do que o volume de madeira colhido (sem casca) de 60139 m^3 (CHAVES; MARRICHI⁷, comunicação pessoal). Essa diferença tende a ser um pouco menor porque os resíduos de madeira que ficam no campo podem ultrapassar o diâmetro mínimo de quatro centímetros (4 cm), quando a última tora da árvore é parcialmente maior do que o limite mínimo.

Na Figura 39, o mapa de biomassa de lenho predito a partir das variáveis transformadas P_{30} e b_{CHP} parece ter sofrido leve influência das diferentes densidades provocadas pelas áreas de sobreposição das faixas de voo (ver Figura 8).

---

⁷ CHAVES, R.; MARRICHI, A. H. C. Duratex S.A.

Figura 39 – Mapa de predição de biomassa do lenho em função da variável parâmetro de escala da distribuição Weibull (a_{CHP}) (modelo 10).

O mapa de predição da biomassa do lenho (B) em função do parâmetro de escala da distribuição Weibull (a_{CHP}) apresentou maior uniformidade visual do que o mapa da Figura 38.

As estatísticas de biomassa do lenho média e incremento médio anual foram parecidas entre os modelos 13 e 10, com ligeira superioridade em precisão ao último modelo. No mapa da Figura 39 a biomassa do lenho média foi de $153.85 \text{ Mg.ha}^{-1}$ ($\sigma = 22.01 \text{ Mg.ha}^{-1}$) e o IMA 6.7 anos de $52.5 \text{ m}^3.\text{ha}^{-1}.\text{ano}^{-1}$. O volume total sem casca predito foi de 68136 m^3 . Esse volume é maior em 13.3 % em relação ao volume de madeira colhido (sem casca) (CHAVES; MARRICHI⁸, comunicação pessoal).

⁸ CHAVES, R.; MARRICHI, A. H. C. Duratex S.A..

4.7.2 Krigagem ordinária

A Figura 40 contém o mapa de predição de área basal resultante da interpolação dos dados de campo por krigagem ordinária.

Figura 40 – Mapa de predição de área basal resultante da interpolação dos dados das parcelas experimentais de campo pelo método da krigagem ordinária. As cruzes em branco representam o ponto centroide de cada parcela experimental.

Embora a krigagem ordinária de área basal tenha resultado em um mapa diferente do mapa de predição resultante dos modelos lineares (Figura 36, Figura 37 e Figura 40), os valores de área basal (G) e desvio padrão de área basal (σ de G) foram parecidos: $29.85 \text{ m}^2.\text{ha}^{-1}$ e $2 \text{ m}^2.\text{ha}^{-1}$, respectivamente.

Figura 41 – Mapa de predição de biomassa de lenho resultante da interpolação dos dados das parcelas experimentais de campo pelo método da krigagem ordinária. As cruzes em branco representam o ponto centroide de cada parcela experimental.

A Figura 41 apresentou resultados para biomassa do lenho (média e dispersão) semelhantes aos encontrados nos mapas de predição obtidos por extrapolação dos modelos de regressão. A biomassa do lenho média foi igual a $153.53 \text{ Mg.ha}^{-1}$ ($\sigma = 17.76 \text{ Mg.ha}^{-1}$).

O volume médio sem casca foi igual a $349.7 \text{ m}^3.\text{ha}^{-1}$ enquanto que o IMA aos 6.7 anos foi equivalente a $52.4 \text{ m}^3.\text{ha}^{-1}.\text{ano}^{-1}$. O volume total sem casca interpolado no site de estudo foi de 67993 m^3 .

A Tabela 21 resume as estatísticas de área basal, biomassa do lenho e volume obtidos nas parcelas experimentais e nos mapas de predição gerados por regressão e krigagem ordinária. Ela também expressa o volume de madeira sem casca posto fábrica informado pela empresa Duratex S.A.

Tabela 21 – Estatísticas de área basal, biomassa do lenho e volume obtidos nas parcelas experimentais da área de estudo, e dos mapas de predição gerados pelos modelos lineares de regressão e por krigagem ordinária.

	G média m ² .ha ⁻¹	σ de G m ² .ha ⁻¹	B média Mg.ha ⁻¹	σ de B Mg.ha ⁻¹	V médio m ³ .ha ⁻¹	IMA 6.7 anos m ³ .ha ⁻¹ .ano ⁻¹	V total m ³
Parcelas experimentais	29.8	3.5	155.1	26.56	353.3	53.0	68689
Modelos lineares*	29.8	2.5	153.8	22.02	350.3	52.5	68136
Krigagem ordinária	29.9	2.0	153.5	17.76	349.7	52.4	67993
Volume posto fábrica	-	-	-	-	-	47.8	60139

G = área basal, B = biomassa do lenho, V = volume de madeira, IMA= incremento médio anual. *Modelos lineares de área basal e biomassa do lenho predito pela variável a_CHP.

Com relação ao volume total de madeira do site experimental, houve superestimação em ambos os mapas de predição: regressão e krigagem ordinária. Entretanto, é difícil realizar uma comparação mais precisa entre os valores preditos pelos mapas e o real colhido, pois não foi possível quantificar o valor exato de volume de madeira residual deixado no campo.

4.7.3 Comparação visual

A Figura 42 compara os mapas de predição de área basal em uma parte da área experimental Eucflux. O painel a esquerda é o modelo linear de área basal predito em função do parâmetro de escala da distribuição Weibull (a_CHP) ajustada para o perfil vertical da floresta, o painel do meio é o resultado da área basal calculada com os dados provenientes do censo de DAPs e o painel à direita representa a variável de área basal interpolada por krigagem ordinária com dados das parcelas experimentais de campo.

Figura 42 – Mapas de predição de área basal. À esquerda mapa de predição com base no parâmetro de escala da distribuição Weibull ajustada para o perfil vertical da floresta aos 6.5 anos de idade. No meio, a área basal obtida a partir de censo dos DAPs para floresta aos 5.5 anos de idade. À direita, mapa de predição resultante da krigagem ordinária com dados das parcelas experimentais de campo.

O mapa de predição de área basal resultante do modelo de regressão com base em estatísticas da nuvem ALS preservou melhor os detalhes obtidos nas cotas de elevação intermediárias do terreno, do que o mapa de predição gerado por interpolação dos dados de campo.

5 DISCUSSÃO

Neste tópico discutem-se os principais resultados encontrados na pesquisa. A sequência da discussão segue uma ordem parecida com as apresentadas nas seções: Material e Métodos e Resultados.

5.1 Homogeneização da nuvem de pontos

No caso da área de estudo Eucflux, a sobreposição real entre as faixas de sobrevoo foi maior do que os 30% inicialmente planejados (aproximadamente 50%), o que contribuiu para o aumento da diversidade espacial do número de retornos obtidos.

De acordo com McGaughey, (2013) o desbaste ou raleamento da densidade de pontos de uma nuvem ALS, pode ser útil quando se deseja comparar bases de dados obtidas com diferentes densidades, ou quando uma nuvem singular de pontos é muito heterogênea.

Desse modo, a homogeneização da nuvem foi conduzida a fim de garantir maior robustez na comparação e reprodução dos resultados obtidos, tanto para a modelagem digital do terreno, como para a extração e utilização das métricas em modelos de regressão.

Como um comparativo, Bater et al. (2011) estudaram o efeito de múltiplos sobrevoos ALS identicamente parametrizados, coletados em mesma data e local, sobre uma área florestal na Ilha de Vancouver, Canadá. Eles observaram que as múltiplas campanhas de escaneamento a laser resultaram em nuvens de pontos com densidades desiguais. As métricas de altura (posição e dispersão) envolvendo últimos retornos, bem como métricas de proporção de dossel e métricas de intensidade, apresentaram resultados estatisticamente diferentes entre os sobrevoos.

No presente estudo, o processamento do desbaste manteve a proporção de primeiros retornos em relação aos demais (intermediários e últimos). Esse resultado é desejável, pois estatísticas de altura de primeiros retornos tendem a ser mais estáveis quando extraídas em diferentes densidades de pontos (BATER et al., 2011).

5.2 Modelo digital de elevação (DEM)

Com relação aos filtros para classificação de retornos de solo, embora os dois algoritmos utilizados tenham gerado Modelos Digitais de Elevação (DEMs) similares, o método do *Multiscale Curvature Classification* (MCC) foi preferido por ser mais versátil a diferentes tipos de vegetação, declividade e rugosidade do relevo (EVANS; HUDAK, 2007; MENG; CURRIT; ZHAO, 2010).

O uso do algoritmo de Kraus e Pfeifer (1998) também foi adequado para o povoamento estudado, em função do espaçamento regular do plantio de *Eucalyptus grandis* (6m² por indivíduo), e devido a situação do relevo ser plano a suave ondulado.

Este resultado está de acordo com a revisão realizada por Meng; Currit e Zhao (2010). Eles compararam as estatísticas de desempenho entre nove algoritmos de classificação, para diferentes condições de terreno e vegetação. O algoritmo de Kraus e Pfeifer apresentou acurácia acima de 85% quando utilizado em terrenos com relevo plano e com vegetação não adensada.

Silva et al. (2012) já haviam observado a ausência de erros de rotulação (pontos de vegetação classificados como solo) na área estudada, para uma janela de busca igual à 4 m². O mesmo não aconteceu para a floresta estacional semidecidual, circundante ao site experimental, em que para eliminar os erros de rotulação foi necessário o aumento da janela de busca para 64 m². Quanto maior o aumento da janela de filtro do algoritmo, menor a resolução obtida no DEM.

5.3 Perfis de alturas de dossel (CHPs)

Mesmo em se tratando de plantios florestais equiânios, os perfis aparentes de altura de dossel (CHPs) modelados pela distribuição Weibull apresentaram variabilidade entre as parcelas experimentais amostradas, de acordo com o inicialmente esperado.

Entretanto, os ajustes das funções probabilísticas foram mais coerentes para o estrato superior da floresta onde a grande maioria dos *hits* (retornos) foi interceptada (85% dos pontos > 20 metros, Apêndice D, Tabela 24). Esse resultado foi coerente com trabalho de Dean et al. (2009). Os autores ajustaram distribuições probabilísticas Weibull truncadas na região de copa para um povoamento equiânio de *Pinus taeda* L. localizado no Estado de Louisiana, Estados Unidos da América.

Em plantios florestais equiânicos e de rápido crescimento (*Eucalyptus* e *Pinus*, no caso do Brasil) a maior parte do dossel florestal está concentrada em apenas um único estrato, o que explica parcialmente a drástica redução de retornos laser observados no estrato inferior da floresta (região dos fustes). Adicionalmente, o escaneamento a laser aerotransportado é enviesado para a amostragem de retornos de copa, uma vez que é o primeiro lugar em que os feixes de luz atingem a floresta.

Coops et al. (2007) também observaram superestimação da fdp Weibull em relação aos dados ALS observados, tanto nos estratos mais altos como nos estratos inferiores para 5 estandes em 6 estudados. O grau de superestimação diferiu entre os tipos de florestas estudadas. O melhor ajuste foi encontrado para o estande considerado como o mais homogêneo entre as amostras. O talhão homogêneo, com aproximadamente 80 anos de idade, era constituído de 80% da área basal pertencente à espécie Douglas-fir (*Pseudotsuga menziesii* [Mirb.] Franco), com 19 metros de altura média (desvio padrão (σ) = 4 metros), DAP médio de 20.6 cm, área basal igual a 50 m².ha⁻¹, e densidade de árvores igual 1325 por hectare.

Magnussen; Eggermont e LaRiccia (1999) desenvolveram métodos de recuperação de alturas de árvores também em povoamentos de Douglas-fir, com o uso da tecnologia ALS e assumiram a distribuição dos retornos da nuvem como sendo desenhadas de uma fdp Weibull com três parâmetros. Testes de aderência de Kolmogorov-Smirnov indicaram bom ajuste entre as distribuições cumulativas empíricas e teóricas para a maioria das parcelas estudadas (estatística do teste KS $0.03 < \hat{D}_{max} < 0.22$ com D médio igual a 0.08, e p_valor médio na ordem de 0.18).

Mesmo com o ajuste coerente das distribuições, foi possível observar graficamente desvios para mais entre a fdp de altura Weibull e os pontos observados na nuvem, nos estratos inferiores da floresta, e desvios para menos nas regiões de maior frequência (MAGNUSSEN; EGGERMONT; LaRICCIA, 1999, figura 3). Com relação ao último caso, padrão semelhante foi observado em algumas das parcelas experimentais do site Eucflux (1, 2, 3, 4, 7 e 17, Figura 19).

Ainda em Magnussen; Eggermont e LaRiccia (1999), as distribuições probabilísticas Weibull ajustadas para os dados ALS, e as fdps Weibull derivadas para recuperação de altura de árvores apresentaram formas semelhantes, diferenciando-se apenas na sua localização (parâmetro de escala).

Lovell et al. (2003) não obtiveram bons ajustes entre o perfil real de dossel mensurado no campo e o perfil vertical aparente modelado por dados ALS de primeiros e últimos

retornos. Os autores atribuem esse resultado a ausência de retornos intermediários na nuvem de pontos, região do dossel que não pode ser bem modelada. Mesmo que os perfis de alturas de dossel aparente e real tenham diferido entre si, o ajuste de funções de densidade probabilidade Weibull aos pontos observados da nuvem ALS foi coerente, corroborando os resultados obtidos no presente estudo. Eles trabalharam com estandes florestais de *Pinus ponderosa*, *Pinus delegatensis*, *Eucalyptus pauciflora* e *Eucalyptus globulus*, no Estado de New South Wales, Austrália.

Como recomendação de ideias para futuros estudos, os perfis aparentes de altura de dossel gerados com a tecnologia de escaneamento a laser aerotransportado (ALS) podem ser explorados em diferentes aplicações.

Uma delas é o uso dos CHPs para realização de estudos de amostragem (NELSON et al., 2003). Por exemplo, em modelagem de atributos florestais, testar a hipótese de que a amostragem estratificada por CHP poderia demandar menor intensidade de parcelas de campo do que o método aleatório simples. Outra opção consiste no monitoramento da dinâmica florestal, comparando-se o perfil vertical de uma mesma área em idades diferentes (BATER et al., 2011).

5.4 Modelos biométricos com variáveis ALS

O alto grau de multicolinearidade observado na análise exploratória de dados entre as métricas provenientes da nuvem tridimensional de pontos está coerente com estudos publicados em literatura.

Stephens et al. (2012) aplicaram a técnica de análise de componentes principais sobre diversas métricas originadas de escaneamento a laser aerotransportado sobre a cobertura florestal nativa da Nova Zelândia. Eles concluíram que 84% do total de variabilidade poderia ser explicada utilizando-se apenas 3 variáveis enquanto que 92% do total da variação dos dados foi explicada por um conjunto de apenas 5 grupos de métricas (variáveis de altura e dispersão, variáveis de cobertura/proporção, variáveis de intensidade, variável de altura mínima e variável de curtose).

Silva (2013) modelou o estoque de carbono em plantios florestais de eucalipto e verificou elevada presença de colinearidade entre as métricas ALS estudadas.

Na presente pesquisa, a escolha inicial das métricas ALS baseou-se principalmente em resultados publicados de pesquisas anteriores, como aquela de Zonete; Rodriguez e Packalén (2010).

Ademais, optou-se pela utilização de estatísticas ainda não exploradas para povoamentos de *Eucalyptus spp*, como o caso dos parâmetros de escala (a_CHP) e de forma (b_CHP) das distribuições probabilísticas Weibull para os perfis verticais de alturas e também a proporção de pontos do subdossel em relação aos pontos de solo (*p_understory*).

O resultado de Stephens et al. (2012) corrobora com a premissa adotada na presente pesquisa, da não inclusão massiva de métricas ALS na análise exploratória de dados. Procurou-se embasar a escolha das métricas com hipóteses de causa e efeito em relação às variáveis respostas, a fim de se evitar a obtenção de modelos com correlação espúria (KOZAK; AZEVEDO, 2011; WHITTINGHAM et al., 2006).

Na análise de correlação entre as métricas ALS e os atributos de área basal e biomassa do lenho, as que mais se destacaram foram o percentil 30 de altura dos primeiros retornos (P30), o parâmetro de escala da fdp Weibull (a_CHP), a altura média de primeiros retornos (Média) e percentil 70 de altura também proveniente de primeiros retornos (P70). Não houve diferença entre área basal e biomassa do lenho quanto ao grupo de métricas que mostraram maior grau de correlação. Isto porque estas duas variáveis de interesse são altamente correlacionadas (CAMPOS; LEITE, 2013).

A métrica de P30 foi a que mais se destacou entre todas as variáveis ALS estudadas. Resultado semelhante foi obtido nos trabalhos de Stephens et al. (2012) e Zonete; Rodriguez e Packalén (2010). As outras métricas de altura, na presente pesquisa, mostraram alto grau de colinearidade com P30.

Outra evidência do potencial de estatísticas provenientes dos percentis mais baixos de altura é o trabalho de D'Oliveira et al. (2012). Eles encontraram boa correlação entre o percentil 25 de altura (todos os retornos) e o atributo de biomassa acima do solo em floresta tropical no Estado do Acre, Brasil.

De acordo com Stephens et al. (2012) os percentis de altura de primeiros retornos nos estratos mais inferiores de copa combinam informações de altura de árvores com densidade de copa, em que estandes florestais mais densos possuem maior valor de P30 do que talhões com árvores de mesma altura, porém em menor densidade populacional.

Mori e Hagihara (1991) correlacionaram positivamente o parâmetro de escala da distribuição Weibull ajustada para distribuição de folhagem de copa com a variável de DAP em uma população de cipreste japonês (*Chamaecyparis obtusa* [Sieb. et Zucc.] Endl.) com 29

anos de idade, na região central do Japão (5826 árvores.ha⁻¹, 9.8 metros de altura média, 9.3 cm de DAP médio e biomassa de lenho de 98.3 Mg.ha⁻¹). Embora o ajuste da fdp Weibull tenha se dado com base no perfil vertical de copa por meio de coleta de dados em campo, o resultado foi coerente com o obtido na presente pesquisa.

A variável do parâmetro de forma da fdp Weibull (b_CHP) foi a única que apresentou correlação negativa com as variáveis de área basal e biomassa do lenho. Esse resultado também foi observado em Coops et al. (2007) para a variável de diâmetro médio a altura do peito em 6 estandes maduros e com diferentes estruturas, na Ilha de Vancouver, Canadá.

O parâmetro de forma da distribuição Weibull está relacionado com o grau de dispersão dos dados da distribuição. Se mantido o valor do parâmetro de escala, quanto maior o valor do parâmetro de forma, menor a largura da curva na região da moda (Figura 13).

Em modelos de regressão em que o b_CHP foi utilizado em conjunto com a variável P30, houve um efeito de mediação da variável nos modelos, em que o parâmetro de forma (b_CHP) passou a possuir correlação positiva com área basal e biomassa do lenho. Em povoamentos de *Eucalyptus spp*, esse resultado pode ser explicado pela hipótese de que em estratos de altura semelhantes, uma menor dispersão vertical dos dados, pode ser um indicativo de maior homogeneidade do dossel da floresta, o que levaria ao aumento da produtividade (STAPE et al., 2010).

A variável de *p_understory* apresentou apenas correlação moderada com as variáveis de interesse área basal e biomassa do lenho, contrariando as expectativas iniciais. As parcelas mais produtivas também possuíram maior quantidade de retornos interceptados na copa e provavelmente diminuíram a amostragem de retornos presentes no subdossel. Como a amostragem de pontos nesta região é baixa, ocorreu subestimação do número de fustes das parcelas. A métrica de *p_understory* ainda foi afetada pela heterogeneidade da densidade de pontos na nuvem, em partes provocadas pelo efeito de sobreposição das faixas do sobrevoo (BATER et al., 2011). Para futuras investigações, sugere-se o estudo do efeito de ângulo de visada do escaneamento, nos percentis de altura dos pontos de subdossel. A hipótese é que as alturas de retornos filtrados fora do nadir poderiam apresentar melhor correlação com área basal.

A variável de densidade de fustes, quando utilizada em conjunto com o parâmetro de escala da distribuição Weibull (a_CHP) aumentou a explicação da variância de área basal em 15 pontos percentuais (adj. R² = 0.77 para adj. R² = 0.92) e biomassa do lenho em 3 pontos percentuais (adj. R² = 0.89 para adj. R² = 0.92). Esse resultado é interessante, pois existe o potencial de uso da tecnologia ALS para identificação de árvores individuais, e

consequentemente estimação do número de indivíduos por unidade de área (OLIVEIRA, 2011; POPESCU; WYNNE; NELSON, 2003; ZANDONÁ; LINGNAU; NAKAJIMA, 2007).

Em parcelas compostas por árvores semelhantes em altura e estrutura de copa, formula-se a hipótese de que o perfil vertical de dossel não captará muito bem as diferenças em % de falhas, se existirem. Dependendo do ângulo de escaneamento do sobrevoo, a árvore ausente fará com que a maioria dos retornos seja interceptada apenas no solo, e consequentemente estes não são incluídos no cálculo das probabilidades de alturas observadas no dossel.

Os modelos de regressão escolhidos para predição de área basal e biomassa do lenho foram função de apenas uma ou duas variáveis explicativas ALS e conseguiram explicar de forma não enviesada de 77% a 93% da variação dos atributos área basal e biomassa do lenho.

Stephens et al. (2012) conseguiram explicar 70% do estoque de carbono total em florestas naturais na Nova Zelândia, com o uso de apenas uma métrica proveniente da nuvem ALS (altura média de primeiros retornos ou percentil 30 de primeiros retornos). A adição de uma métrica de cobertura (proporção) em conjunto com P30 melhorou em 2% o desempenho do modelo de predição de carbono. Não houve melhoria dos modelos adicionando-se uma terceira métrica (não colinear) com as já existentes.

5.5 Mapas de predição

Os resultados dos semi-variogramas ajustados para área basal e biomassa do lenho a partir das informações das parcelas de campo estiveram parcialmente de acordo com o trabalho de Alvares et al. (2013b). Os autores estudaram a correlação espacial da métrica ALS denominada percentil 90 de altura (todos os retornos) amostrada em uma grade de 20 por 20 metros sobre a área de estudo Eucflux. Eles encontraram correlação espacial com alcance de até 900 metros para semi-variograma esférico isotrópico e de 600 a 900 metros em semi-variogramas esféricos anisotrópicos.

A descontinuidade (efeito pepita) observada nos semi-variogramas teóricos do presente estudo pode ser parcialmente explicada pela característica seminal (e não clonal) do povoamento estudado. Não houve efeito pepita no estudo de Alvares et al. (2013b), principalmente pelo fato da estatística P90 possuir alta amostragem espacial.

As parcelas de inventário em plantios florestais no Brasil são amostradas aleatoriamente no campo para capturar a maior parte da variação do atributo de interesse e com a menor intensidade amostral possível (redução de custos). Outro ponto importante é que a intensidade

amostral utilizada contribui para a diminuição da dependência espacial entre amostras, e que possibilita o uso de técnicas de modelagem por regressão linear (pressuposição de amostras independentes). O método convencional de inventário de campo é um dos fatores que limitam a obtenção de bons resultados utilizando-se a técnica de interpolação geoestatística por krigagem ordinária.

Os mapas de predição de área basal e biomassa do lenho, construídos tanto pelo método de regressão linear com as variáveis ALS quanto pelo método da interpolação por krigagem ordinária foram coerentes com o gradiente de produtividade do site experimental Eucflux, mostrado e estudado por Campoe (2012) e Campoe et al. (2012). Entretanto, foi possível observar que os mapas gerados com as informações da nuvem de pontos apresentaram maior coerência com a realidade de campo.

De acordo com Naesset (2009), o principal obstáculo ao uso da tecnologia de escaneamento a laser aerotransportado (ALS) em inventários florestais de forma operacional parece se dever aos altos custos relativos associados com: i) aquisição dos dados ALS e ii) aquisição de dados no campo.

A viabilidade econômica em se utilizar a tecnologia ALS para construção de mapas de predição de variáveis de interesse florestal como área basal e biomassa do lenho dependerá em como a informação espacial poderá ser aproveitada pelo gestor florestal no âmbito da silvicultura de precisão e no manejo da paisagem, dos custos de aquisição das informações ALS, de equipe capacitada para o seu processamento, e de outros produtos marginais que poderão ser aproveitados de uma mesma base de dados, como por exemplo, o modelo digital de elevação (DEM).

6 CONCLUSÕES

Os resultados apresentados nesta dissertação permitem algumas relevantes conclusões com relação às seguintes questões: (i) definição de funções que expressem adequadamente o perfil aparente de alturas do dossel em plantios homogêneos de eucalipto; (ii e iii) busca de métodos eficientes para estimação das variáveis de área basal e biomassa do lenho, e iv) representação espacial de parâmetros florestais com o auxílio de dados ALS em extensas áreas ocupadas por plantios de eucalipto.

Para a primeira questão, referida também na primeira hipótese deste trabalho, os resultados demonstram que a função Weibull de dois coeficientes ajustou com suficiente precisão o perfil aparente de alturas do povoamento estudado, principalmente no estrato superior do dossel. Do ponto de vista prático, esse resultado fortalece as estratégias de uso dos parâmetros de escala (α) e de forma (β) da função Weibull como métricas que caracterizam adequadamente a estrutura vertical de povoamentos florestais. Assim, é possível concluir que a utilização desses parâmetros, como variáveis explicativas em modelos biométricos, pode melhorar a qualidade das estimativas em extensos plantios florestais.

Para a segunda questão, que trata da busca de métodos eficientes de estimação da área basal de extensos plantios de eucaliptos por meio de métricas de subdossel de dados ALS, e que está contemplada na segunda hipótese deste trabalho, os resultados apresentados revelaram correlação moderada (intervalo de confiança do coeficiente de correlação linear de Pearson (ρ) entre $p\_understory$ e área basal apresentou limite inferior igual a 0.18). É inconclusiva a relação entre a proporção de pontos no subdossel e o atributo de área basal, sendo necessários mais estudos que explorem outras formas de relação entre os dados ALS presentes nesse estrato.

A terceira questão, melhoria das estimativas de biomassa do lenho e área basal em extensos plantios de eucaliptos, se beneficia dos resultados encontrados para a primeira hipótese levantada. Os resultados do ajuste que usa como variáveis explicativas de biomassa o parâmetro de escala (α) da fdp Weibull, como proxy para escala de alturas, revelam boa capacidade preditiva (R^2 ajustado de 0.89 para biomassa do lenho e 0.77 para área basal). É possível, portanto, concluir que a contribuição dessa abordagem para a geração de boas estimativas em extensos plantios é evidente.

A quarta e última questão, que trata da extrapolação espacial dos resultados devido aos dados ALS (quarta hipótese), também parece razoavelmente apoiada pelos resultados deste trabalho. A análise visual dos mapas de predição de área basal gerados por modelos de regressão com variáveis ALS apresentaram resolução mais próxima do censo, do que os mapas de predição originados a partir de interpolações dos dados de campo por krigagem ordinária. Os valores de RMSE relativo (rRMSE) resultantes da validação cruzada corroboram com a hipótese levantada (para área basal rRMSE igual a 5.2% em modelos de regressão *versus* 8.9% na krigagem ordinária e para biomassa do lenho, rRMSE = 5.5% nos modelos lineares com dados ALS *versus* 12.7% para krigagem ordinária). O uso de dados ALS para calibração e representação espacial de atributos florestais melhorou o resultado do mapeamento.

REFERÊNCIAS

ASSOCIAÇÃO BRASILEIRA DE PRODUTORES DE FLORESTAS PLANTADAS.

Anuário estatístico ABRAF 2011 ano base 2010. Brasília, 2011, 130 p. Disponível em: <<http://www.abraflor.org.br/estatisticas/ABRAF11/ABRAF11-BR.pdf>>. Acesso em: 15 jun. 2011.

_____. **Anuário estatístico ABRAF 2013 ano base 2012.** Brasília, 2013, 148 p. Disponível em: <http://www.abraflor.org.br/estatisticas/ABRAF13/ABRAF13_BR.pdf>. Acesso em: 04 jan. 2014.

ABREU, E.C.R.; SCOLFORO, J.R.S.; OLIVEIRA, A.D. de.; MELLO, J.M. de.; KANEGAE JÚNIOR, H. Modelagem para prognose precoce do volume por classe diamétrica para *Eucalyptus grandis*. **Scientia Florestalis**, Piracicaba, v. 61, p. 86–102, Jun. 2002.

ALFONS, A. **Cross-validation tools for regression models v. 0.3.2.** Vienna, 2012. Disponível em: <<http://cran.r-project.org/web/packages/cvTools/index.html>>. Acesso em: 02 nov. 2013.

ALVARES, C.A.; STAPE, J.L.; SENTELHAS, P.C.; GONÇALVES, J.L.M.; SPAROVEK, G. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, Stuttgart, v. 22, n. 6, p. 711–728, Dez. 2013a.

ALVARES, C.A.; GORGENS, E.B.; SILVA, A.G.P.; CAMPOE, O.C.; RODRIGUEZ, L.C.E.; STAPE, J.L. Integrando Geoestatística e LiDAR para identificar padrões isotrópicos e anisotrópicos da altura de plantações de *Eucalyptus grandis*. In: SIMPÓSIO DE GEOESTATÍSTICA APLICADA EM CIÊNCIAS AGRÁRIAS, 3., 2013, Botucatu. **Anais...Botucatu:SGeA**, 2013b. p. 1-6.

BALTSAVIAS, E.P. Airborne laser scanning: basic relations and formulas. **ISPRS Journal of Photogrammetry and Remote Sensing**, Amsterdam, v. 54, n. 2/3, p. 199–214, Jul. 1999.

BATER, C.W.; WULDER, M.A.; COOPS, N.; NELSON, R.F.; HILKER, T.; NAESSET, E. Stability of Sample-Based Scanning-LiDAR-Derived Vegetation Metrics for Forest Monitoring. **IEEE Transactions on Geoscience and Remote Sensing**, New York, v. 49, n. 6, p. 2385–2392, Jun. 2011.

BEHRENDT, R. Introduction to LiDAR and forestry, part 1: a powerful new 3D tool for resource managers. **The Forestry Source**, Bethesda, MD, p. 14–15, Set. 2012. Disponível em: <http://www.nxtbook.com/nxtbooks/saf/forestrysource_201209/index.php?startid=12#/14>. Acesso em: 23 jun. 2013.

BERNARDI, D. **Utilização de ortofotos e dados LiDAR para o planejamento florestal na Fibria Celulose S.A.** In: SEMINÁRIO DE ATUALIZAÇÃO EM SENSORIAMENTO REMOTO E SISTEMAS DE INFORMAÇÕES GEOGRÁFICAS APLICADOS À ENGENHARIA FLORESTAL, 10., 2012, Curitiba. **Palestra...** Curitiba: IEP, 2012.

BRANDELERO, C.; ANTUNES, M.U.; GIOTTO, E. Silvicultura de precisão: nova tecnologia para o desenvolvimento florestal. **Ambiência**, Guarapuava, v. 3, n. 2, p. 269–281, Mai/Ago. 2007.

BREUSCH, T.S.; PAGAN, A.R. A simple test for heteroscedasticity and random coefficient variation. **Econometrica**, Chicago v. 47, n. 5, p. 1287–1294, Sept. 1979.

CAMPOE, O. **Ecologia da produção e da competição intra-específica do *Eucalyptus grandis* ao longo de um gradiente de produtividade no Estado de São Paulo**. 2012. 123p. Tese (Doutorado em Silvicultura e Manejo Florestal) - Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo, Piracicaba, 2012.

CAMPOE, O.C.; STAPE, J.L.; LACLAU, J.P.; MARSDEN, C.; NOUVELLON, Y. Stand-level patterns of carbon fluxes and partitioning in a *Eucalyptus grandis* plantation across a gradient of productivity, in Sao Paulo State, Brazil. **Tree Physiology**, Oxford, UK, p. 1–11, Apr. 2012.

CAMPOS, J.C.C.; LEITE, H.G. **Mensuração Florestal: perguntas e respostas**. 4th. ed. Viçosa, MG: Editora UFV, 2013. 605p.

CHILÈS, J.P.; DELFINER, P. **Modeling Spatial Uncertainty**. New York: John Wiley, 1999. 720p.

COHEN, A.C. Maximum Likelihood Estimation in the Weibull Distribution Based On Complete and On Censored Samples. **Technometrics**, Richmond, v. 7, n. 4, p. 579–588, Nov. 1965.

COOPS, N.C.; HILKER, T. WULDER, M.A.; ST-ONGE, B.; NEWNHAM, G.; SIGGINS, A.; TROFYMOW, J.A.T. Estimating canopy structure of Douglas-fir forest stands from discrete-return LiDAR. **Trees**, Berlin, v. 21, n. 3, p. 295–310, Jan. 2007.

DEAN, T.J.; QUANG, V.C.; ROBERTS, S.D.; EVANS, D.L. Measuring heights to crown base and crown median with LiDAR in a mature, even-aged loblolly pine stand. **Forest Ecology and Management**, Amsterdam, v. 257, n. 1, p. 126–133, Jan. 2009.

DEMÉTRIO, C.G.B.; ZOCCHI, S.S. **Modelos de Regressão**. Piracicaba: Departamento de Ciências Exatas, Esalq, USP, 2011. 198p.

DIAZ, J.C.F. Lifting the Canopy Veil: Airborne LiDAR for Archeology of Forested Areas. **Imaging Notes**, v. 26, n. 2, 2011. Disponível em: <http://www.imagingnotes.com/go/article_freeJ.php?mp_id=264#2>. Acesso em: 03 feb. 2014.

DIXON, W.J. Analysis of extreme values. In: *The Annals of Mathematical Statistics*, [s.l.], 1950. **Proceedings...**[s.l.]: Institute of Mathematical Statistics, 1950. p. 488-506. Disponível em: <<http://www.jstor.org/stable/2236602>>. Acesso em: 12 set. 2013.

D'OLIVEIRA, M. V. N.; REUTEBUCH, S. E.; McGAUGHEY, R. J.; ANDERSEN, H. E. Estimating forest biomass and identifying low-intensity logging areas using airborne scanning lidar in Antimary State Forest, Acre State, Western Brazilian Amazon. **Remote Sensing of Environment**, Amsterdam, v. 124, p. 479–491, Sept. 2012.

DOORNIK, J.A.; HANSEN, H. An Omnibus Test for Univariate and Multivariate Normality. **Oxford Bulletin of Economics and Statistics**, Oxford, UK, v. 70, p. 927–939, Dec. 2008.

DURBIN, J.; WATSON, G.S. Testing for serial correlation in least squares regression III. **Biometrika**, London, v. 58, n. 1, p. 1–19, Apr. 1971.

ESTEIO ENGENHARIA E AEROLEVANTAMENTOS S.A. **Relatório de voo laser:** Instituto de Pesquisas Florestais. Curitiba, ESTEIO, 2009.. Relatório técnico de sobrevoo LiDAR. 48p.

EVANS, J.S.; HUDAK, A.T. A Multiscale Curvature Algorithm for Classifying Discrete Return LiDAR in Forested Environments. **IEEE Transactions on Geoscience and Remote Sensing**, New York, v. 45, n. 4, p. 1029–1038, Apr. 2007.

FREESE, F. **Elementary Forest Sampling**. 2nd ed. Washington D.C.: U.S. Department of Agriculture, Forest Service, 1976. 91p.

GONÇALVES, J.L.M. Principais solos usados para plantações florestais. In: GONÇALVES, J. L.M.; STAPE, J.L. (Ed.). **Conservação e cultivo de solos para plantações florestais**. Piracicaba: IPEF, 2002. cap. 1. p. 1-45.

GONÇALVES, J.L.M.; STAPE, J.L.; LACLAU, J.P.; SMETHURST, P.; GAVA, J.L. Silvicultural effects on the productivity and wood quality of eucalypt plantations. **Forest Ecology and Management**, Amsterdam, v. 193, n. 1/2, p. 45–61, May 2004.

GONÇALVES, J.L.D.M.; ALVARES, C.A.; HIGA, A.R.; SILVA, L.D.; ALFENAS, A.C.; STAHL, J.; FERRAZ, S.F.B.; LIMA, W.P.; BRANCALION, P.H.S.; HUBNER, A.; BOUILLET, J.P.D.; LACLAU, J.P.; NOUVELLON, Y.; EPRON, D. Integrating genetic and silvicultural strategies to minimize abiotic and biotic constraints in Brazilian eucalypt plantations. **Forest Ecology and Management**, Amsterdam, v. 301, p. 6–27, Aug. 2013.

GUJARATI, D.N. **Basic Econometrics**. 4th. ed. New York: The McGraw-Hill companies, 2004. 1002p.

HARDING, D.J.; LEFSKY, M.A.; PARKER, G.G.; BLAIR, J.B. Laser altimeter canopy height profiles: methods and validation for closed-canopy, broadleaf forests. **Remote Sensing of Environment**, Amsterdam, v. 76, n. 3, p. 283–297, Jun. 2001.

HIEMSTRA, P.; SLUITER, R. **Interpolation of Makkink evaporation in the Netherlands**. Amsterdam: Royal Netherlands Meteorological Institute; Ministry of Infrastructure and the Environment, 2011. 78p. (Technical Report.)

HIEMSTRA, P.H.; PEBESMA, E.J.; TWENHOFEL, C.J.W.; HEUVELINK, G.B.M. Real-time automatic interpolation of ambient gamma dose rates from the Dutch radioactivity monitoring network. **Computers & Geosciences**, New York, v. 35, n. 8, p. 1711–1721, Aug. 2009.

INTERNATIONAL TROPICAL TIMBER ORGANIZATION. **ITTO**: Manual for project formulation. 3rd. ed. Yokohama, 2009. 91p.

KELLEY, C.T. **Iterative Methods for Optimization**. Philadelphia: SIAM, 1999. 180p.

KOZAK, M.; AZEVEDO, R.A. Does using stepwise variable selection to build sequential path analysis models make sense? **Physiologia Plantarum**, Copenhagen, v. 141, n. 3, p. 197–200, Mar. 2011.

KRAUS, K.; PFEIFER, N. Determination of terrain models in wooded areas with airborne laser scanner data. **ISPRS Journal of Photogrammetry and Remote Sensing**, Amsterdam, v. 53, n. 4, p. 193–203, Aug. 1998.

LE MAIRE, G.; MARSDEN, C.; VERHOEF, W.; PONZONI, F.J.; SEEN, A.B.; STAPE, J.L.; NOUVELLON, Y. Leaf area index estimation with MODIS reflectance time series and model inversion during full rotations of *Eucalyptus* plantations. **Remote Sensing of Environment**, Amsterdam, v. 115, n. 2, p. 586–599, Feb. 2011.

LIRA, S.A. **Análise de correlação**: abordagem teórica e de construção dos coeficientes com aplicações. 2004. 196p. Dissertação (Mestrado em Métodos Numéricos em Engenharia) - Setores de Ciências Exatas e de Tecnologia, Universidade Federal do Paraná, Curitiba, 2004.

LOVELL, J.L.; JUPP, D.L.B.; CULVENOR, D.S.; COOPS, N.C. Using airborne and ground-based ranging lidar to measure canopy structure in Australian forests. **Canadian Journal of Remote Sensing**, Ottawa, v. 29, n. 5, p. 607–622, 2003.

MACEDO, R.C. **Estimativa volumétrica de povoamento clonal de *Eucalyptus* sp. através de laserscanner aerotransportado**. 2009. 143p. Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2009.

MAGNUSSEN, S.; BOUDEWYN, P. Derivations of stand heights from airborne laser scanner data with canopy-based quantile estimators. **Canadian Journal of Forest Research**, Ottawa, v. 1031, p. 1016–1031, 1998.

MAGNUSSEN, S.; EGGERMONT, P.; LaRICCIA, V. N. Recovering Tree Heights from Airborne Laser Scanner Data. **Forest Science**, Lawrence, v. 45, n. 3, p. 407–422, 1999.

MALTAMO, M.; SUVANTO, A.; PACKALÉN, P. Comparison of basal area and stem frequency diameter distribution modelling using airborne laser scanner data and calibration estimation. **Forest Ecology and Management**, Amsterdam, v. 247, n. 1/3, p. 26–34, Aug. 2007.

McCOOL, J.I. **Using the Weibull Distribution**: Reliability, Modeling and Inference. Hoboken: John Wiley., 2012. 368p.

McGAUGHEY, R.J. **FUSION / LDV** : Software for LIDAR Data Analysis and Visualization v. 3.3, Seattle, WA, 2013. Disponível em: http://forsys.cfr.washington.edu/fusion/FUSION_manual.pdf. Acesso em: 04 mai 2013.

MENG, X.; CURRIT, N.; ZHAO, K. Ground Filtering Algorithms for Airborne LiDAR Data: A Review of Critical Issues. **Remote Sensing**, Basel, v. 2, n. 3, p. 833–860, Mar. 2010. Disponível em: <<http://www.mdpi.com/2072-4292/2/3/833>>. Acesso em: 07 jan. 2013.

MOOD, A.M.; GRAYBILL, F.A.; BOES, D.C. **Introduction to theory of statistics**. 3rd ed. Auckland: McGraw-Hill, 1974. 564p.

MORI, S.; HAGIHARA, A. Crown profile of foliage area characterized with the Weibull distribution in a hinoki (*Chamaecyparis obtusa*) stand. **Trees**, Berlin, v. 5, p. 149–152, 1991.

NÆSSET, E. Determination of mean tree height of forest stands using airborne laser scanner data. **ISPRS Journal of Photogrammetry & Remote Sensing**, Amsterdam, v. 52, p. 49–56, 1997a.

_____. Estimating Timber Volume of Forest Stands Using Airborne Laser Scanner Data. **Remote Sensing of Environment**, Amsterdam, v. 61, p. 246–253, 1997b.

_____. Predicting forest stand characteristics with airborne scanning laser using a practical two-stage procedure and field data. **Remote Sensing of Environment**, Amsterdam, v. 80, n. 1, p. 88–99, Apr. 2002.

_____. Effects of different sensors, flying altitudes, and pulse repetition frequencies on forest canopy metrics and biophysical stand properties derived from small-footprint airborne laser data. **Remote Sensing of Environment**, Amsterdam, v. 113, n. 1, p. 148–159, Jan. 2009.

NELSON, R.; VALENTI, M. A.; SHORT, A.; KELLER, C. A Multiple Resource Inventory of Delaware Using Airborne Laser Data. **BioScience**, Washington D.C., v. 53, n. 10, p. 981–992, Oct. 2003.

OLIVEIRA, L.T. **Aplicação do LiDAR no inventário de florestas plantadas**. 2011. 117p. Tese (Doutorado em Florestas de Produção) – Departamento de Ciências Florestais, Universidade Federal de Lavras, Lavras-MG, 2011.

PACKALÉN, P.; MEHTÄTALO, L.; MALTAMO, M. ALS-based estimation of plot volume and site index in a eucalyptus plantation with a nonlinear mixed-effect model that accounts for the clone effect. **Annals of Forest Science**, Paris, v. 68, n. 6, p. 1085–1092, Aug. 2011.

PEDUZZI, A; WYNNE, R.H.; FOX, T.R.; NELSON, R.F.; THOMAS, V.A. Estimating leaf area index in intensively managed pine plantations using airborne laser scanner data. Amsterdam, **Forest Ecology and Management**, Amsterdam, v. 270, p. 54–65, Apr. 2012.

PELISSARI, A.L. **Silvicultura de precisão aplicada ao desenvolvimento de *Tectona grandis* L.f. na região sul do Estado de Mato Grosso**. 2012. 78p. Dissertação (Mestre em Ciências Florestais e Ambientais) – Faculdade de Engenharia Florestal, Universidade Federal de Mato Grosso, Cuiabá, 2012.

POPESCU, S.C.; WYNNE, R.H.; NELSON, R.F. Measuring individual tree crown diameter with lidar and assessing its influence on estimating forest volume and biomass. **Canadian Journal of Remote Sensing**, Ottawa, v. 29, n. 5, p. 564–577, Oct. 2003.

R CORE TEAM. **R: A Language and Environment for Statistical Computing v. 3.1**. Vienna, 2013. Disponível em: <<http://www.r-project.org/>>. Acesso em: 09 jul. 2013.

REUTEBUCH, S.E.; ANDERSEN, H.E.; MCGAUGHEY, R. Light detection and ranging (LIDAR): an emerging tool for multiple resource inventory. **Journal of Forestry**, Washington D.C., v. 103, n. 6, p. 286–292, Sept. 2005.

RHOADS, A.G.; HAMBURG, S.P.; FAHEY, T.J.; SICCAM, T.G.; KOBE, R. Comparing direct and indirect methods of assessing canopy structure in a northern hardwood forest. **Canadian Journal of Forest Research**, Ottawa, v. 34, n. 3, p. 584–591, Mar. 2004.

RIBEIRO, C.A.A.S. Floresta de Precisão. In: MACHADO, C. C. (Ed.). **Colheita Florestal**. 2. ed. Viçosa, MG: Editora UFV, 2008. cap. 11, p. 328–351.

RIEGL LASER MEASUREMENT SYSTEMS. Disponível em: <<http://www.riegl.com/nc/products/airborne-scanning/produktdetail/product/scanner/38/>>. Acesso em: 27 abr. 2014

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

SCHUMACHER, F.X.; HALL, F.S. Logarithmic expression of timber-tree volume. **Journal of Agriculture Research**, Washington D.C., v. 47, n. 9, p. 719–734, Nov. 1933.

SHAPIRO, S.S.; WILK, M.B. An Analysis of Variance Test for Normality (Complete Samples). **Biometrika**, London, v. 52, n. 3/4, p. 591–611, Dec. 1965.

SILVA, A.G.P.; GORGENS, E.B.; RODRIGUEZ, L.C.E.; SILVA, C.A.; ALVARES, C.A.; CAMPOE, C.A.; STAPE, J.L. Influência da janela do filtro de terreno em dados LiDAR sob duas coberturas florestais. In: SEMINÁRIO DE ATUALIZAÇÃO EM SENSORIAMENTO REMOTO E SISTEMAS DE INFORMAÇÕES GEOGRÁFICAS APLICADOS À ENGENHARIA FLORESTAL, 10., 2012, Curitiba. **Anais...** Curitiba: IEP, 2012. p. 65-72. 1 CD-ROM

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. 152 p. Dissertação (Mestrado em Silvicultura e Manejo Florestal) – Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo, Piracicaba, 2013.

SOARES, A. **Geoestatística para as ciências da terra e do ambiente.** 2. ed. Lisboa: IST Press, 2006. 214p.

SOARES, C.P.B.; LEITE, H.G.; GORGENS, E.B. Equações para estimar o estoque de carbono no fuste de árvores individuais e em plantios comerciais de eucalipto. **Revista Árvore**, Viçosa, MG, v. 29, n. 5, p. 711–718, 2005.

STAPE, J.L.; NOUVELLON, Y.; LACLAU, J. **Eucflux.** Relatório Anual 2006 IPEF, Piracicaba, Instituto de Pesquisas e Estudos Florestais 2006. p. 38-40,

STAPE, J.L.; NOUVELLON, Y.; LACLAU, J.; CAMPOE, O. **Eucflux.** Relatório Anual 2008 IPEF, Piracicaba, Instituto de Pesquisas e Estudos Florestais, , 2008. p. 73-79.

STAPE, J.L.; BINKLEY, D.; RYAN, M.G.; FONSECA, S.; LOOS, R.A.; TAKAHASHI, E.N.; SILVA, C.R.; SILVA, S.R.; HAKAMADA, R.E.; FERREIRA, J.M.A.; LIMA, A.M.N.; GAVA, J.L.; LEITE, F.P.; ANDRADE, H.B.; ALVES, J.M.; SILVA, G.G.C; AZEVEDO, M.R. The Brazil Eucalyptus Potential Productivity Project: Influence of water, nutrients and stand uniformity on wood production. **Forest Ecology and Management**, Amsterdam, v. 259, n. 9, p. 1684–1694, Apr. 2010.

STEPHENS, P.R.; KIMBERLEY, M.O.; BEETS, P.N.; PAUL, T.S.H.; SEARLES, N.; BELL, A.; BRACK, C.; BROADLEY, J. Airborne scanning LiDAR in a double sampling forest carbon inventory. **Remote Sensing of Environment**, Amsterdam, v. 117, p. 348–357, Feb. 2012.

SUN, Y.; KANG, S.; LI, F.; ZHANG, L. Comparison of interpolation methods for depth to groundwater and its temporal and spatial variations in the Minqin oasis of northwest China. **Environmental Modelling & Software**, Oxford, UK, v. 24, n. 10, p. 1163–1170, Oct. 2009.

THE PENNSYLVANIA STATE UNIVERSITY. **Detecting multicollinearity using variance inflation factors.** Philadelphia: Department of Statistics, Eberly College of Science, 2014. Disponível em: <<https://onlinecourses.science.psu.edu/stat501/node/83>>. Acesso em: 2 dez. 2014.

VASTARANTA, M. **Forest mapping and monitoring using active 3D remote sensing.** 2012. 45 p. Thesis (Doctorate in Forest Science) – Faculty of Agriculture and Forestry, University of Helsinki, Helsinki, 2012. Disponível em: <<http://www.metla.fi/dissertationes/df144.pdf>>. Acesso em: 29 out. 2013.

VENABLES, W. N.; RIPLEY, B. D. **Modern Applied Statistics with S.** 4th. ed. Berlin: Springer. 2002. 495p.

VENTURI, N.L. **Atualização cartográfica e cadastral com dados LIDAR na Klabin S.A.** In: SEMINÁRIO DE ATUALIZAÇÃO EM SENSORIAMENTO REMOTO E SISTEMAS DE INFORMAÇÕES GEOGRÁFICAS APLICADOS À ENGENHARIA FLORESTAL, 10., 2012, Curitiba. **Palestra...** Curitiba: IEP, 2012.

VETTORAZZI, C.A.; FERRAZ, S.F.B. Silvicultura de precisão: uma nova perspectiva para o gerenciamento de atividades florestais. In: BORÉM, A.; GIÚDICE, M. P.; QUEIROZ, D. M. (Ed.). **Agricultura de precisão**. Viçosa, MG: Editora UFV, 2000. p. 65–75.

VIANA, H.; ARANHA, J; LOPES, D.; COHEN, W.B. Estimation of crown biomass of *Pinus pinaster* stands and shrubland above-ground biomass using forest inventory data, remotely sensed imagery and spatial prediction models. **Ecological Modelling**, Amsterdam, v. 226, p. 22–35, Feb. 2012.

WASSER, L.; DAY, R.; CHASMER, L.; TAYLOR, A. Influence of Vegetation Structure on Lidar-derived Canopy Height and Fractional Cover in Forested Riparian Buffers During Leaf-Off and Leaf-On Conditions. **Plos One**, San Francisco, v. 8, n. 1, p. 1-14, Jan. 2013.

Disponível em:

<<http://www.plosone.org/article/info%3Adoi%2F10.1371%2Fjournal.pone.0054776>>.

Acesso em: 23 feb. 2014.

WHITTINGHAM, M.J.; STEPHENS, P.A.; BRADBURY, R.B.; FRECKLETON, R.P. Why do we still use stepwise modelling in ecology and behaviour? **The Journal of Animal Ecology**, Oxford, UK, v. 75, n. 5, p. 1182–1189, Sept. 2006.

WICKHAM, P. **Normality and White Noise Testing v. 1.0**. Vienna, 2012. Disponível em: <<http://cran.r-project.org/package=normwn.test>>. Acesso em: 14 out. 2013.

ZANDONÁ, D.F.; LINGNAU, C.; NAKAJIMA, N.Y. Utilização da tecnologia LIDAR para obtenção de altura individual e delimitação automática de copas em povoamento de *Pinus sp.* In: XIII Simpósio Brasileiro de Sensoriamento Remoto, 2007, Florianópolis. **Anais...** Florianópolis: INPE, 2007. p. 3693-3700.

ZONETE, M.F.; RODRIGUEZ, L.C.E.; PACKALÉN, P. Estimação de parâmetros biométricos de plantios clonais de eucalipto no sul da Bahia : uma aplicação da tecnologia laser aerotransportada. **Scientia Florestalis**, Piracicaba, v. 38, n. 86, p. 225–235, 2010.

APÊNDICES

APÊNDICE A

Tabela 22 – Atributos de interesse para as 23 parcelas experimentais da área de estudo.

Parcela	Área de j	Sobr.	Dens.	DAP	G	H	B
j	m ²	%	fustes.ha ⁻¹	cm	m ²	m	Mg.ha ⁻¹
1	574	90.5	1342	16.6	31.7	27.5	182
2	522	94.0	1551	15.8	34.2	26.2	194
3	501	94.0	1558	15.0	33.4	23.7	180
4	509	82.1	1376	16.3	32.7	26.2	184
5	458	88.1	1614	14.1	28.7	23.6	142
6	488	92.9	1579	13.8	27.2	23.4	133
7	529	92.9	1455	14.1	25.9	23.8	129
8	481	89.3	1539	14.3	28.0	23.7	136
9	526	92.9	1483	15.8	31.4	26.5	169
10	508	95.2	1574	13.6	25.4	23.1	119
11	457	92.9	1686	14.9	33.0	24.7	169
12	519	85.7	1310	13.7	25.2	22.6	126
13	823	91.0	1593	15.6	32.6	24.3	168
14	853	91.0	1513	15.5	32.9	25.5	180
15	872	91.7	1537	16.0	34.4	27.0	195
16	814	88.2	1559	15.1	31.8	23.7	158
17	881	92.4	1544	15.6	32.5	25.1	173
18	834	86.1	1475	14.7	27.4	25.0	138
19	811	96.5	1715	13.1	26.0	21.5	115
20	826	84.7	1441	14.0	26.3	22.8	129
21	839	88.9	1537	15.0	30.6	24.8	161
22	1106	83.3	1103	15.4	22.5	25.0	113
23	847	86.8	1475	15.7	32.2	25.5	175

Sobr. = sobrevivência; Dens. = densidade de fustes; DAP = diâmetro médio à altura do peito; G = área basal; H = altura total média; B = biomassa seca do lenho.

Figura 43 – Distribuição de DAPs e alturas totais (H) nas parcelas experimentais da área de estudo. No *boxplot* de DAPs, o eixo x foi ordenado em ordem decrescente pelo critério da mediana.

APÊNDICE B

Figura 44 – Modelo hipsométrico entre logaritmo natural da altura total (H) e inverso do DAP utilizado para predição das alturas totais nas parcelas de validação.

Tabela 23 – Resultados de inventário florestal para as 21 parcelas de validação.

Parcela	Sobr.	DAP	G	H	B
j	%	cm	m ²	m	Mg.ha ⁻¹
10	72.1	15.0	25.4	23.2	123
11	89.1	12.7	24.3	20.9	109
12	75.7	16.4	26.3	24.9	130
13	95.2	15.1	33.0	23.2	159
14	82.9	14.4	24.6	23.1	114
15	87.2	13.9	24.5	22.0	116
16	87.8	14.0	24.5	22.6	112
17	85.4	13.6	23.1	22.4	104
18	78.0	15.1	26.4	23.7	126
26	90.2	14.0	28.2	22.1	133
27	89.7	13.0	22.7	20.7	106
28	92.5	13.5	25.3	21.7	116
29	94.9	13.2	23.6	21.4	107
30	96.7	14.4	29.8	22.8	140
31	90.2	14.6	29.0	22.6	139
32	83.7	15.1	28.9	23.6	138
33	97.7	15.0	34.8	23.4	167
34	88.1	14.8	30.3	22.9	146
35	81.0	14.4	24.7	23.2	114
36	90.2	12.7	21.6	21.5	94
37	92.9	14.1	28.5	22.2	135

Sobr. = sobrevivência; DAP = diâmetro médio à altura do peito; G = área basal; H = altura total média; B = biomassa seca do lenho.

Figura 45 – Distribuição de DAPs observadas e alturas totais (H) preditas nas parcelas de validação no site experimental. No *boxplot* de DAPs, o eixo x foi ordenado em ordem decrescente pelo critério da mediana.

APÊNDICE C

Figura 46 – Mapa de declividade da área de estudo com resolução espacial de 50 metros.

APÊNDICE D

Tabela 24 – Número de retornos ALS por classe de altura.

Parcela #	Número de retornos por classe de altura						
	5-10*	10-15	15-20	20-25	25-30	30-35	% >20
1	93	163	135	163	1219	884	85.3
2	101	109	120	94	864	757	83.9
3	80	92	148	258	1000	728	86.1
4	99	69	194	125	1000	726	83.6
5	18	67	101	650	667	0	87.6
6	62	69	60	1207	553	0	90.2
7	42	94	119	824	947	0	87.4
8	40	63	102	906	877	0	89.7
9	35	39	101	352	1236	313	91.6
10	15	48	117	1030	409	0	88.9
11	51	42	128	345	1242	69	88.2
12	12	41	125	619	822	34	89.2
13	127	108	287	559	2055	431	85.4
14	86	80	126	537	2564	158	91.8
15	79	135	114	363	2691	664	91.9
16	39	59	183	614	1689	83	89.5
17	95	131	149	233	2002	499	87.9
18	34	70	144	1841	1276	0	92.6
19	16	60	284	2055	258	0	86.5
20	68	99	161	1457	1038	0	88.4
21	123	141	181	489	2427	358	88.0
22	54	128	323	943	2944	148	88.9
23	77	117	134	435	2100	443	90.1
desv. pad.	35	36	65	528	769	305	2
min.	12	39	60	94	258	0	84
média	63	88	154	700	1386	274	88
max.	127	163	323	2055	2944	884	92.6

* limites das classes de altura em metros.