Efeito da densidade de pontos LiDAR na
predição da altura em plantações de *Pinus taeda* L.Effect of LiDAR density points on the prediction
of height in *Pinus taeda* L. plantationsCarlos Alberto Silva¹, Carine Klauberg¹,
Bruno Araujo Furtado de Mendonça² e Samuel Padua Chaves e Carvalho³

Resumo

O objetivo deste estudo foi o de avaliar o efeito da densidade de pontos LiDAR na predição da altura média florestal (AMF) em plantações de *Pinus taeda* L., localizadas na região sul do Brasil. Em campo foram alocadas 55 unidades amostrais em que foram realizadas medições da altura total (ht) das árvores para a obtenção da AMF em nível de parcela. Os dados de sobrevoo LiDAR foram coletados com densidades de pontos média de 4 pontos m⁻², e posteriormente reduzidos de 100% para 80%, 60%, 40%, 20%, 10%, 5% e 1%. Após a redução da malha de pontos, métricas LiDAR do perfil de copa foram calculadas e utilizadas para a modelagem da AMF por meio de regressão linear múltipla. Os modelos preditivos da AMF apresentaram valores de Coeficiente de Determinação Ajustado (R² ajd.) variando de 0,93 a 0,95 indicando a boa qualidade preditiva do modelo. No critério de validação cruzada todos os modelos sugeridos apresentaram valores relativos de raiz quadrada do erro quadrático médio (RMSE) inferiores a 10%. Os resultados permitiram inferir que é possível fazer uso de dados LiDAR com densidade de pontos baixa para predição e consequentemente, o monitoramento da AMF em plantios de *P. taeda*, sem comprometer a precisão nas estimativas.

Palavras-chave: Perfil Vertical Florestal, Métricas LiDAR, Sensoriamento Remoto, Inventário Florestal.

Abstract

The aim of this study was to evaluate the effect of LiDAR density points for the prediction of forest mean height (AMF) in a *Pinus taeda* plantation in southern Brazil. 55 sample plots were allocated in the field for estimating tree heights and to compute AMF at plot level. Airborne LiDAR data were collected with a mean of density points of 4 points m⁻² and then reduced from 100% to 80%, 60%, 40%, 20%, 10%, 5% e 1%. After reduction of LiDAR density points, LiDAR-derived canopy profile metrics were computed for AMF modeling. The models predictive of AMF show an Adjusted Coefficient of Determination (R² ajd.) ranging from 0.93 to 0.95. In cross validation, all models show relative Root Mean Square Error (RMSE) lower than 10%. The result suggests that it is possible to use low LiDAR density point data for predicting and monitoring AMF in *P. taeda* plantations without compromising the precision of the estimates.

Keywords: Forest profile, LiDAR metrics, Remote sensing, Forest Inventory.

INTRODUÇÃO

Desde a década de 60, extensas áreas de plantações florestais têm sido estabelecidas como um marco à política de incentivos fiscais para o reflorestamento no Brasil. Na maioria das áreas foi plantado eucalipto (*Eucalyptus* spp.), mas no sul do país o pinus (*Pinus* spp.) se destacou pelo bom desenvolvimento e adaptabilidade. Passando 50 anos, as áreas com árvores plantadas para fins industriais vêm crescendo. Em 2014, foi contabilizada uma área total de 7,74 milhões de hectares, o que corresponde a aproximadamente 1,0 % do território nacional (IBÁ, 2015). Desse total, 1,59 milhões de hectares correspondem aos plantios de pinus. Apesar da área de plantio de pinus no país ser menor em relação ao de eucalipto, este apresenta alta produtividade tanto quanto o eucalipto,

¹Pesquisador Doutor. USDA – United States Department of Agriculture / Forest Service. Rocky Mountain Research Station, RMRS, 1221 South Main Street – 83843 – Moscow, USA. E-mail: carlos_engflorestal@outlook.com; carine_klauberg@hotmail.com.

²Professor Adjunto do Departamento de Silvicultura. UFRRJ – Universidade Federal Rural do Rio de Janeiro, Instituto de Florestas, Departamento de Silvicultura. Rua da Floresta – 23897005 – Seropédica, RJ, Brasil. E-mail: brunoafmendonca@gmail.com.

³Professor Adjunto do Departamento de Engenharia Florestal. UFMT – Universidade Federal de Mato Grosso. Av. Fernando Correa da Costa, 2367 – Boa Esperança – 78060900 – Cuiabá, MT, Brasil. E-mail: sam.padua@gmail.com

31 m³/ha.ano⁻¹, quando comparada a outros países. Por exemplo, a produtividade média do pinus na África do Sul, Chile e Estados Unidos é de 22, 18 e 14 m³/ha.ano⁻¹, respectivamente (IBÁ 2015).

A mensuração florestal é um importante elemento no Manejo Florestal. As duas principais variáveis mensuradas em atividades de inventários florestais são a altura e o diâmetro. Assim como o diâmetro, a altura é utilizada para quantificação da produtividade, e ainda na definição de índice de sítio e avaliação da homogeneidade florestal (MACHADO, 2003). Porém, em virtude do alto custo para mensuração, altura em inventários florestais é comumente mensurada em parte dos indivíduos, e as restantes são preditas por meio de equações, relações estas conhecidas como Hipsométricas (BATISTA et al., 2014).

O sensoriamento remoto por meio da tecnologia LiDAR, do inglês *Light Detection and Ranging*, tem se destacado nas últimas duas décadas devido a sua capacidade de mensurar simultaneamente a estrutura vertical e horizontal da floresta bem como a morfologia do terreno de maneira detalhada, precisa e rápida (JENSEN, 2009). No Brasil, alguns estudos tem mostrado o potencial da ferramenta nas estimativas de atributos florestais em plantios de *Eucalyptus* spp, como volume (CARVALHO et al. 2015, SILVA et al. 2016a), biomassa e carbono (SILVA et al. 2015a, SILVA et al. 2014), assim como em plantios de Pinus, a altura média, dominante e contagem de indivíduos (SILVA et al. 2016b).

Embora o LiDAR apresenta a capacidade de mensuração da altura florestal em larga escala e de forma precisa, a sua aquisição é ainda inviável devido ao seu custo elevado principalmente em médias e pequenas extensões de área. Este custo é resultado de alguns fatores, como: a) tamanho e localização da área do projeto; b) prazo e condições meteorológicas para voo; e c) densidade de pontos. Dentre estes fatores, a densidade de pontos é uma das mais importantes variáveis que influenciam o custo de aquisição de dados LiDAR (JAKUBOWSKI et al. 2013).

A densidade de pontos pode ser definida pelo número de retornos ou pontos, recebidos pelo sensor após a emissão de pulsos laser que se interagem com os alvos e retornaram ao sensor para serem armazenados (JENSEN, 2009). A densidade de pontos é expressa por unidade de área, sendo a mais utilizada por número de pontos em um metro quadrado (pontos m⁻²). Em sistemas LiDAR de retorno discreto, o sensor tem a capacidade de detectar e armazenar múltiplos retornos, sendo que um único pulso pode interagir com o alvo e voltar ao sensor na forma de um único ou múltiplos retornos (JENSEN, 2009). Desta forma, uma maior densidade de pontos vai depender do aumento da frequência da taxa de pulso enviado pelo sensor, da velocidade de perfilhamento da superfície, da taxa de sobreposição da trajetória de voo, e da diminuição da altitude de voo da aeronave, assim como de sua velocidade (JAKUBOWSKI et al. 2013).

Na perspectiva de que o custo de aquisição de dados LiDAR pode ser reduzido a medida que a densidade de pontos também é reduzida, e que a diminuição do custo pode favorecer a operacionalização do uso desta tecnologia para o inventário florestal em plantações florestais Brasileiras. O objetivo deste estudo foi i) simular a partir de dados LiDAR originais de alta densidade, dados com densidades de pontos reduzidas em até 1% ; ii) avaliar o efeito da densidade de pontos na distribuição do perfil florestal; iii) avaliar o efeito da densidade de pontos na predição da altura média florestal (AMF) em plantações de *Pinus taeda* L. localizados no sul do Brasil; e iv) indicar um número suficiente na densidade de pontos para estimar essas variáveis em levantamentos e monitoramentos da AMF.

MATERIAL E MÉTODOS

Área de estudo

O estudo foi realizado em plantações de *Pinus taeda* L. localizados no município de Telêmaco Borba, estado do Paraná (Figura 1) e pertencentes à empresa Klabin S/A. Para a formação das florestas foram utilizados espaçamentos médios iniciais de 3 x 2 m e 2,5 x 2,5 m, resultando em uma densidade média de árvores de 1.667 e 2.000 por hectare, respectivamente. O clima da região é descrito na classificação de Köppen Geiger como Cfa, temperado úmido com verão quente (Peel et al., 2007). A precipitação total anual é de aproximadamente 1.378 mm, e a temperatura média anual de 18,4 °C. O relevo regional da área de estudo varia de ondulado a montanhoso, com altitude variando de 618 m a 905 m. Os talhões florestais estão localizados em áreas com topografia relativamente plana.

Figura 1. Localização da área de estudo. Os pontos em destaque indicam a localização das 55 parcelas amostrais em talhões florestais de *P. taeda*.

Figure 1. Location of the study area. The highlighted black points indicate the location of the 55 field sample plots in the *P. taeda* forest stands.

Inventário florestal convencional

Em campo 55 parcelas retangulares com área variando de 500 a 620 m², foram alocadas em talhões de *P. taeda* com idades variando de 3 a 9 anos. Todas as parcelas foram georreferenciadas com GPS com capacidade de correção diferencial modelo *Trimble Pro-XR*, sendo que em cada parcela foram mensurados todos os diâmetros a altura do peito (DAP), medidos a 1,3 m do solo, e 15% das alturas totais (Ht). As alturas das árvores não mensuradas em campo foram previstas por relações hipsométricas. O modelo hipsométrico ajustados foi o de Curtis (1967), em que o inverso do DAP é a variável independente e o logaritmo neperiano da altura é a variável dependente conforme apresentado na equação 1.

$$\ln(Ht) = \beta_0 + \beta_1 * \left(\frac{1}{DAP}\right) + e \quad (1)$$

Onde: $\ln(Ht)$ é o logaritmo neperiano da altura (m); β_0 e β_1 correspondem ao intercepto e o coeficiente angular do modelo; DAP é o diâmetro a altura do peito e e é o erro aleatório do modelo.

Os coeficientes dos modelos hipsométricos são informações restritas da empresa Klabin e, portanto, não são disponibilizados. Entretanto, a precisão do modelo foi disponibilizada pela empresa em que o coeficiente de determinação ajustado ($R^2_{ajd.}$) e erro padrão da estimativa (Syx%) variaram de 0,42 a 0,76 e 3,6 a 11,7% respectivamente. A AMF utilizada neste estudo foi calculada como sendo a média das alturas medidas e previstas das árvores amostradas em cada unidade amostral. Informações que descrevem a variável objeto deste estudo (AMF) estão apresentadas na Tabela 1.

Tabela 1. Resumos da altura média florestal (AMF) nas 55 parcelas estudadas de *P. taeda*.

Table 1. Summary of the forest mean height (AMF) in the 55 sample plots of *P. taeda*.

Idade (anos)	AMF observada (m)				Nº Parcelas
	min	max	média	sd	
3 ≥ IF < 5	6,10	7,10	6,72	0,29	19
5 ≥ IF < 7	8,50	11,10	9,99	0,72	19
7 ≥ IF < 9	10,00	12,60	11,49	0,65	15
9 ≥ IF < 11	13,40	14,50	13,95	0,78	2

Coleta e processamento de dados LiDAR aerotransportado

Os dados LiDAR foram obtidos com o sensor Harrier 68i embarcado na aeronave CESSNA 206. As características e a precisão dos dados estão apresentadas na Tabela 3. O processamento dos dados LiDAR foi efetuado em duas distintas etapas. Uma primeira no software FUSION/LDV 3.42 (MCGAUGHEY, 2015) seguida por procedimentos implementados no ambiente R (R DEVELOPMENT CORE TEAM, 2016).

Tabela 2. Características de voo do LiDAR.

Table 2. LiDAR flight characteristics.

Parâmetros	Valores
Ângulo de visada (°)	60°
Largura da faixa imageada (m)	0,33m
Velocidade do voo (km/h)	234,00 km/h
Acurácia Horizontal	10cm
Acurácia Vertical	15cm
Altitude do voo	666,17 m
Frequência	300 kHz
Densidade de Pulsos	4 pulses/m ²

Em FUSION, o passo inicial, efetuado por meio da função *Catalog* foi o de gerar informações que descrevem a nuvem de pontos LiDAR. Na sequência aplicou-se a função de filtragem *Groundfilter*, tomando como referência o algoritmo de Kraus e Pfeifer (1998), de forma a diferenciar os pontos no solo e a vegetação. Classificado o solo, foi gerado o modelo digital de terreno (DTM), com resolução espacial de um metro, por meio da função *GridSurfaceCreate*. Como próximo passo, por meio da função *ClipData*, a nuvem de pontos foi normalizada e a função *PolyClipdata* fez o recorte desta nuvem de pontos LiDAR para as 55 parcelas dispostas em campo.

Em R foi realizada a redução da nuvem de pontos por meio do pacote rLiDAR (SILVA, et al., 2015b). Este passo teve por objetivo, simular um cenário onde futuras aquisições de sobrevoos LiDAR de baixa densidade de pontos poderiam ser efetivamente normalizadas pelo DTM gerado aquisições anteriores com alta densidade de pontos. Portanto, o passo inicial foi a importação da nuvem no R, efetuado pela função *readLAS*, e em sequência a redução da densidade de pontos de 100% para 80%, 60%, 40%, 20%, 10%, 5% e 1% por meio de seleção aleatória dos pontos utilizando a função *sample* em R.

Perfil de copa LiDAR

Para representar o perfil de copa florestal (CHP) em nível de parcela, foi utilizada a função densidade probabilidade (PDF) Weibull. Para as 55 parcelas em classes de densidade de pontos, foi ajustado uma PDF Weibull através da função *fitdistr* do pacote MASS, também no R. A PDF Weibull tem sido utilizada para caracterização da distribuição do perfil de copa em florestas de coníferas do Canadá (Coops et al., 2007). Recentemente, SILVA et al. (2015a) utilizou a PDF Weibull para a caracterização do perfil de copa e predição da biomassa do fuste Eucalyptus utilizando métricas derivadas da nuvem de pontos LiDAR e os parâmetros escala e forma da PDF Weibull. Em nosso estudo, para eliminar o efeito biomodal no perfil copa ocasionado pela vegetação rasteiras, a PDF foi ajustada utilizando todos os retornos LiDAR acima de 2 m.

Para avaliar o efeito da densidade de pontos LiDAR no CHP, foi feito a comparação das PDFs Weibull derivadas da nuvem de pontos reduzida com a PDF Weibull derivada da nuvem pontos original por meio do teste Kolgomoronov-smirnov em R. O teste Kolgomoronov-smirnov foi executado em R através da função *ks.t.functionn*, do pacote *stats*, com objetivo de avaliar a hipótese de que a CHPs derivada das nuvens de pontos reduzidas são iguais ao CHP derivado da nuvem de pontos original, não reduzida.

Modelagem da altura média florestal (AMF)

Para modelagem da AMF em nível de parcela foi utilizada função *lm* em ambiente *base* do R com o objetivo de ajustar modelos de regressão linear múltipla. Para tal foi empregada a AMF como variável dependente e os parâmetros de escala e forma derivados da PDF Weibull como variáveis

independentes. A precisão dos modelos foi avaliada pelo Coeficiente de Determinação Ajustado (R^2_{aj}) e também pela Raiz do erro quadrático médio (RMSE) absoluta e relativa (Eq. 2 e Eq.3).

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

$$RMSE (\%) = \frac{\sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}}}{\text{mean}(y)} * 100 \quad (3)$$

Sendo “n” o número de parcelas, y_i é o valor da AMF observado na parcela “i”, e $\hat{y}_i$ é o valor da AMF predito na parcela “i”. Os resíduos dos modelos foram analisados graficamente e testado quanto à normalidade e homogeneidade de variâncias pelos testes Shapiro-Wilk (SHAPIRO e WILK, 1965) e Breusch-Pagan test (BREUSCH; PAGAN, 1979). Para avaliar a robustez dos modelos, foi realizada a validação cruzada do tipo “deixa-um-de-fora”. Por fim, para verificar se os valores preditos da validação cruzada foram semelhantes aos valores observados, foi realizado o teste de equivalência (ROBINSON et al., 2015), como apresentados por SILVA et al. (2016a). Para este estudo, e com base nos erros de inventários convencionais, foram definidos valores de RMSE relativos abaixo de 10%, como valores satisfatórios. O resumo da metodologia empregada neste estudo está apresentado na Figura 2.

Figura 2. Etapas de processamento dos dados LiDAR e modelagem da altura média florestal em plantios de *P. taeda*.
Figure 2. Steps of the LiDAR processing and forest height modeling in *P. taeda* plantations.

RESULTADOS

Densidade de pontos LiDAR

A Tabela 3 apresenta os valores mínimos, máximos e médios da densidade de pontos utilizadas nos cenários de redução da malha de pontos LiDAR sugeridos no estudo. O número médio de pontos LiDAR nas 55 unidades amostrais variou de 10 a 87 e de 1034 a 8733 para as classes de densidade de pontos 1 e 100%, resultando, portanto, em uma densidade de pontos média de 0.05 (± 0.02) e 4.95 (± 2.38) pontos m^{-2} , respectivamente.

Tabela 3. Densidade de pontos LiDAR para os cenários estudados.

Table 3. LiDAR point density for the studied scenarios.

Classes de DP (%)	Número de pontos				Densidade de pontos (pontos m^{-2})			
	min	max	média	sd	min	max	média	sd
1	10	87	30.98	14.85	0.02	0.14	0.05	0.02
5	52	437	155.11	74.47	0.09	0.71	0.25	0.12
10	103	873	310.16	148.84	0.18	1.43	0.50	0.24
20	207	1747	620.36	297.71	0.37	2.85	0.99	0.48
40	414	3493	1240.86	595.40	0.74	5.71	1.98	0.95
60	620	5240	1861.11	893.12	1.11	8.56	2.97	1.43
80	827	6986	2481.60	1190.81	1.48	11.41	3.96	1.91
100	1034	8733	3101.96	1488.52	1.85	14.27	4.95	2.38

DP= densidade de pontos

CHP em classe de densidade de pontos

Os parâmetros forma e escala derivados da PDF Weibull nas classes de densidade de pontos estudadas estão apresentados na Tabela 4. Em termos médios, a forma foi o parâmetro mais afetado pela redução da densidade de pontos, resultando em valores médios de 2.57 (± 0.17) e 4.24 (± 1.89) para a densidade de pontos original e reduzida a 1%.

Tabela 4. Parâmetros de escala e forma da PDF Weibull para as 55 parcelas estudadas.

Table 4. Scale and shape parameters of the PDF Weibull for the 55 sample plots studied.

Classes de DP (%)	PDF Weibull							
	Forma				Escala			
	min	max	média	sd	min	max	média	sd
1	2.51	9.31	4.24	1.89	3.85	12.26	7.45	2.48
5	2.50	7.74	3.37	1.27	4.17	12.58	7.57	2.42
10	2.50	5.82	2.94	0.72	4.06	12.68	7.53	2.42
20	2.50	4.38	2.77	0.44	4.10	12.66	7.53	2.42
40	2.50	4.32	2.70	0.38	4.13	12.55	7.55	2.42
60	2.50	3.68	2.60	0.19	4.11	12.54	7.54	2.43
80	2.50	3.66	2.58	0.19	4.11	12.55	7.54	2.43
100	2.50	3.66	2.57	0.17	4.10	12.54	7.54	2.43

DP= densidade de pontos

Os resultados da Tabela 5 evidenciam que apesar de reduzida a nuvem de pontos a 1%, o teste de Kolmogorov-Smirnov (KS) aceitou a hipótese nula de que não existe diferença significativa quando comparado o perfil de copa (CHP) das classes reduzidas com a totalidade das informações, os 100% dos pulsos. Por exemplo, na classe de 1%, 54 das 55 parcelas (98%) apresentaram CHP igual ao CHP dos 100%. Isto implica que os pulsos laser enviados pelo sensor no ato do perfilhamento foram interceptados em sua maioria pelo dossel florestal, fazendo com que a maioria dos pontos retornados alcançasse o estrato florestal entre 15 – 25 m em altura. Exemplos de CHPs gerados nas classes de densidade de pontos estão apresentados na Figura 3.

Tabela 5. Comparação dos CHPs pelo teste de Kolmogorov-Smirnov.
Table 5. Comparison of the CHPs by the Kolmogorov-Smirnov test.

Classes de DP (%)	Kolmogorov–Smirnov (KS)				Estatisticamente não significativa (p-valor > 0.05)	
	Estatística KS		p-valor			
	média	sd	média	sd	N	%
01	0.174	0.058	0.518	0.240	54	98
05	0.077	0.029	0.555	0.316	53	96
10	0.050	0.015	0.648	0.249	55	100
20	0.032	0.011	0.786	0.204	55	100
40	0.023	0.009	0.803	0.249	55	100
60	0.015	0.006	0.948	0.104	55	100
80	0.009	0.004	0.994	0.036	55	100

DP= densidade de pontos; N= número de casos não estatisticamente significantes pelo teste de Kolmogorov-Smirnov.

A Figura 3 ilustra graficamente os resultados da Tabela 5 em que não há diferença significativa entre o perfil de Copa com 100% dos dados comparado à nuvem reduzida mesmo que a 1% das informações.

Figura 3. Exemplo dos CHP em classes de densidade de pontos. A linha preta horizontal representa o limiar de altura de 2m.

Figure 3. Examples of CHP across point density classes. The horizontal black line represent the height threshold of 2m.

Modelos de predição da AMF

A Tabela 6 apresenta os modelos ajustados para a predição da AMF através das métricas de forma e escala da PDF Weibull derivadas do LiDAR. Verifica-se que os modelos ajustaram bem aos dados observados, e a redução da densidade de pontos não afetou a qualidade preditiva dos modelos. Foi possível notar pequenas alterações nos valores dos parâmetros de intercepto bem como àqueles associados aos parâmetros de forma e escala respectivamente. Além disso, todos os modelos atenderam os pré-requisitos de normalidade e homogeneidade de variância, quando os resíduos foram analisados pelos testes Shapiro-Wilk e Breusch-Pagan.

Tabela 6. Modelos de predição da AMF por meio de variáveis da PDF Weibull derivada de dados LiDAR.

Table 6. Models for predicting AMF using PDF Weibull variables derived from LiDAR data.

Classes de PD (%)	Modelos de AMF	Adj. R ²	r	RMSE	
				m	%
1	$3.15 + 0.94 \cdot \text{forma} - 0.17 \cdot \text{escala}$	0.93	0.87	0.80	8.52
5	$2.89 + 0.91 \cdot \text{forma} - 0.11 \cdot \text{escala}$	0.94	0.89	0.72	7.72
10	$3.25 + 0.90 \cdot \text{forma} - 0.21 \cdot \text{escala}$	0.95	0.89	0.71	7.60
20	$2.86 + 0.86 \cdot \text{forma} - 0.01 \cdot \text{escala}$	0.94	0.89	0.74	7.88
40	$3.31 + 0.88 \cdot \text{forma} - 0.20 \cdot \text{escala}$	0.94	0.89	0.73	7.77
60	$3.02 + 0.86 \cdot \text{forma} - 0.06 \cdot \text{escala}$	0.94	0.89	0.73	7.77
80	$2.89 + 0.86 \cdot \text{forma} - 0.01 \cdot \text{escala}$	0.94	0.89	0.73	7.79
100	$3.22 + 0.86 \cdot \text{forma} - 0.14 \cdot \text{escala}$	0.94	0.89	0.73	7.80

Os valores de AMF observados em campo versus preditos pela validação cruzada foram semelhantes pelo teste de equivalência (Figura 4). A estabilidade dos modelos foi confirmada pelos altos valores de R² adj, correlação de Pearson e pelos baixos RMSE (absoluto e relativo) quando comparados os valores observados e preditos via validação cruzada.

Predição da AMF em nível de parcela

Os valores preditos da AMF pela validação cruzada nas classes de densidade de pontos estão apresentados na Tabela 7. Na média não houve diferença na predição da AMF observada em campo com os preditos pelos modelos ajustados por densidades reduzidas, o que assegura uma alta estabilidade nas predições derivadas de modelos ajustados com baixa densidades de pontos.

Tabela 7. Resumos dos valores observados e preditos da AMF (m) em classe de densidade de pontos.

Table 7. Summary of the observed and predicted AMF across point density.

Estatística	AMF Observada	AMF predita em classe de densidade de pontos							
		1%	5%	10%	20%	40%	60%	80%	100%
min	6.1	6.33	6.41	6.38	6.44	6.44	6.44	6.46	6.44
max	14.5	13.28	13.57	13.9	13.87	13.71	13.7	13.74	13.66
média	9.41	9.41	9.41	9.41	9.41	9.41	9.41	9.41	9.41
sd	2.22	2.06	2.09	2.1	2.09	2.09	2.09	2.09	2.09

Figura 4. Teste de equivalência entre valores observados e preditos pela validação cruzada “deixa-um de fora” (LOOCV) da AMF; ($n=55$). O polígono cinza sombreado representa a região de equivalência para o intercepto, e a barra vertical preta representa 95% de intervalo de confiança para a interceptação. A AMF observada em campo e predita pela validação cruzada - LOOCV são equivalentes pelo intercepto do modelo, se a barra vertical preta estiver completamente dentro do polígono cinza. Além disso, as linhas tracejadas cinzas representam a região de equivalência para o coeficiente angular, e se a barra vertical preta estiver contida completamente dentro das linhas tracejadas cinzas, a AMF observada e predita são consideradas equivalentes. Os pontos brancos representam as medidas pareadas das AMFs, e a linha sólida preta representa o melhor ajuste do modelo. Por fim, a linha cinza tracejada representada a relação de 1:1.

Figure 4. Equivalence plots of observed vs. predicted AGC by the leave one out cross validation (LOOCV); ($n=55$). The grey polygon represents the region of equivalence for the intercept, and the red vertical bar represents a 95% of confidence interval for the intercept. The observed and predicted AMF by LOOCV are equivalents if the black bar is completely within the grey polygon. Moreover, the grey dashed line represents the region of equivalence for the slope, and if the black vertical bar is contained completely within the grey dashed line, the pairwise measurements are equal. The white dots are the pairwise measurements, and the solid line is a best-fit linear model for the pairwise measurements. The light grey dashed line represented the relationship 1:1.

DISCUSSÃO

O uso da tecnologia LiDAR para a mensuração da altura florestal permite a obtenção de dados com altíssima precisão e em larga escala. Além do aumento da qualidade das informações em inventários florestais, muitas vezes com alturas médias estimadas a partir de equações hipsométricas, o uso desses dados durante o monitoramento da produtividade florestal, de modo mais otimizado, pode acarretar em grandes benefícios econômicos para empresas florestais. Esse trabalho estudou uma simulação na redução da densidade de pontos a partir de dados LiDAR originais de alta densidade, avaliou o efeito da densidade de pontos na distribuição do perfil florestal e o efeito da densidade de pontos na estimativa da altura florestal em plantações de *Pinus taeda* L. localizados no sul do Brasil.

As pequenas variações das métricas utilizadas na PDF Weibull (Tabela 4), forma e escala, para as diferentes densidades de pontos avaliadas revelam a correlação da nuvem de pontos reduzida para 1% com os dados originais (100%), corroborados pelo teste de Kolmogorov-Smirnov (KS) com diferenças não significativas. Segundo Coops et al. (2007), tais métricas da pdf Weibull apresentam correlação significativa com importantes atributos do perfil florestal e podem indicar, além da altura florestal, características da estrutura do dossel.

Diversos estudos vêm comprovando a eficiência da tecnologia LiDAR para predições precisas de parâmetros de florestas plantadas no Brasil (CARVALHO et al., 2015; RODRIGUEZ et al., 2010; SILVA et al., 2014; 2015a; 2016a; 2016b; ZONETE et al., 2010). Porém, embora estudos indiquem que o inventário florestal obtido a partir de dados LiDAR já possuem custos e precisões comparáveis aos inventários convencionais de campo (HUMMEL et al., 2016), ainda existe a limitação devido ao alto custo de aquisição desses dados, principalmente em inventários contínuos em grandes regiões, com aquisição de dados anuais.

Entretanto, nossos resultados demonstram que podemos reduzir o custo do inventário florestal contínuo por meio de LiDAR, através da aquisição de dados com densidade de pontos reduzida durante a realização do monitoramento. Para isso, seria possível adquirir uma única vez dados com alta densidade de pontos, para criação de um DTM preciso, e posteriormente a obtenção de dados LiDAR para o monitoramento da produtividade com baixa densidade de pontos. Para predição da altura média florestal em nível de parcela, com parcelas de tamanho variando de 500 a 600 m² e com densidade de pontos de 0,05 a 0,25 pontos por m² pode-se promover predições precisas de AMF em plantações de *P. taeda*.

Tesfamichael et al. (2010) também encontraram alta precisão para predição da altura florestal em parcelas e em grandes áreas utilizando densidade de pontos reduzida em plantios de *E. grandis*. As avaliações de Singh et al. (2015) também indicam a redução da densidade de pontos LiDAR como uma solução viável para levantamentos regionais da cobertura florestal, especialmente na obtenção da biomassa florestal, a qual teve a altura florestal como principal variável de predição.

Embora os custos de aquisição dos dados LiDAR possuam variações de mercado e de tecnologias, existem ainda as variações de dimensão da área e densidade de pontos. Nosso estudo não aborda custos propriamente, mas apresenta importantes resultados que podem promover o avanço da operação do inventário florestal em plantações de *P. taeda* no Brasil por meio de dados LiDAR, no sentido de otimizar os custos de aquisição e melhorar a qualidade das informações finais.

CONCLUSÕES

Esse estudo avaliou o efeito da densidade de pontos LiDAR na predição da altura média florestal em plantações de *P. taeda* por meio de métricas derivadas da nuvem de pontos LiDAR referentes ao perfil de copa florestal. A tecnologia LiDAR mostra ser uma ferramenta precisa para a predição da altura média florestal, mesmo em densidade de pontos baixas. Além dos perfis de copa derivados das densidades de pontos reduzidas não apresentarem diferenças entre si, todos os modelos ajustados obtiveram RMSE inferiores aos estabelecidos (abaixo de 10%). Desta forma, é possível reduzir o custo do inventário florestal contínuo por meio de LiDAR, através da aquisição de dados com densidade de pontos reduzida durante a realização do monitoramento, sem comprometer a precisão nas estimativas. Esperamos que os resultados promissores da modelagem da altura média florestal apresentados neste estudo estimule o uso e operação desta tecnologia no Brasil.

AGRADECIMENTOS

Os autores agradecem a empresa Klabin S/A, em especial ao Luiz Gastão Burnett, Clewerson Frederico Scheraiber e ao Emerson Roberto Schoeninger pelas contribuições durante as etapas de coleta de dados e revisão do manuscrito.

REFERÊNCIAS BIBLIOGRÁFICAS

BATISTA, J. L. E.; COUTO, H. T. Z.; SILVA FILHO, D. F. **Quantificação de Recursos Florestais - Árvores, Arvoredos e Florestas**. São Paulo: Oficina de Textos, 2014. 384 p.

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

CARVALHO, S. P. C.; RODRIGUEZ, L. C. E.; SILVA, L. D.; CARVALHO, L. M. T.; CALEGARIO, N.; LIMA, M. P.; SILVA, C. A.; MENDONÇA, A. R.; NICOLETTI, M. F. Predição do volume de árvores integrando Lidar e Geoestatística. **Scientia Forestalis**, v. 43, n. 107, p. 627-637, 2015.

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**, Danvers, v. 21, p. 295-310. 2007.

CURTIS, R. O. Height diameter and height diameter age equations for second growth Douglas-fir. **Forest Science**, Bethesda, v. 13, n. 4, p. 365-375, 1967.

HUMMEL, S.; HUDAK, A. T.; UEBLER, E. H.; FALKOWSKI, M. J.; MEGOWN, K. A. A comparison of accuracy and cost of LiDAR versus stand exam data for landscape management on the Malheur National Forest. **Journal of Forestry**, Bethesda, v. 109, n. 5, p. 267-273, 2011.

IBÁ - INDÚSTRIA BRASILEIRA DE ÁRVORES. **A Indústria Brasileira de Árvores**. Brasília: IBÁ, 2015. 80 p.

KRAUS, K.; PFEIFER, N. Determination of terrain models in wooded areas with airborne laser scanner data. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 53, p. 3193–203, 1998.

MACHADO, S. A. **Dendrometria**. Curitiba: UFPR, 2003. 309 p.

MCGAUGHEY, R. J. **FUSION/LDV: software for LiDAR Data Analysis and Visualization**. Washington: USDA, Forest Service, 2015. 150 p.

R DEVELOPMENT CORE TEAM. **R: A language and environment for statistical computing**. Vienna: R Foundation for Statistical Computing, 2016.

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, Edição Especial, p. 67-80, 2010.

JAKUBOWSKI, M. K.; GUO, Q.; KELLY, M. Tradeoffs between lidar pulse density and forest measurement accuracy. **Remote Sensing of Environment**, New York, v. 130, p. 245–253, 2013.

JENSEN, J. R. **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres**. São José dos Campos: Parêntese, 2009. 598 p.

PEEL, M. C.; FINLAYSON, B. L.; McMAHON, T. A. Updated world map of the Köppen-Geiger climate classification. **Hydrology Earth System Science**, Göttingen, v.11, n. 5, p.1633–1644, 2007.

ROBINSON, A. **Equivalence**: Provides Tests and Graphics for Assessing Tests of Equivalence, Version 0.7.0. 2006. Disponível em: < <https://cran.r-project.org/web/packages/equivalence/> >. Acesso em 20 Jun. 2016.

SHAPIRO, S. S.; WILK, M. B. An analysis of variance test for normality (complete samples). **Biometrika**, London, v. 3/4, n. 52, p. 591-611, 1965.

SILVA, C. A.; KLAUBERG, C.; HUDAK, A. T.; VIERLING, L. A.; LIESENBERG, V.; CARVALHO, S. P. C.; RODRIGUEZ, L. C. E. A principal component approach for predicting the stem volume in Eucalyptus plantations in Brazil using airborne LiDAR data. **Forestry**, Oxford, v. 89, p. 422-433, 2016a.

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

SILVA, C. A.; CROOKSTON, N. L.; HUDAK, A. T.; VIERLING, L. A. **rLiDAR: An R package for reading, processing and visualizing LiDAR (Light Detection and Ranging) data, version 0.1**. 2015b. Disponível em: < <http://cran.r-project.org/web/packages/rLiDAR/index.html> >. Acesso em 11 Abril, 2016.

SILVA, C. A.; KLAUBERG, C.; CARVALHO, S. P. C.; HUDAK, A. T.; RODRIGUEZ, L. C. E. Mapping aboveground carbon stocks using LiDAR data in Eucalyptus spp. Plantations in the state of São Paulo, Brazil. **Scientia Forestalis**, Piracicaba, v. 42, n. 104, 2014.

SINGH, K.K., CHEN, G., MCCARTER, J.B., MEENTEMEYER, R.K. Effects of LiDAR point density and landscape context on estimates of urban forest biomass. **ISPRS Journal Photogramm Remote Sensing**, v. 101, p. 310-322, 2015.

TESFAMICHAEL, S. G.; JAN VAN AARDT, F. A.; Estimating plot-level tree height and volume of Eucalyptus grandis plantations using smallfootprint, discrete return LiDAR data. **Progress in Physical Geography**, Londres, v. 34, n. 4, p. 515-540, 2010.

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

Recebido em 08/09/2016

Aceito para publicação em 07/04/2017