

UNIVERSIDADE FEDERAL DO PARANÁ

CLEBSON LIMA CERQUEIRA

MODELAGEM MISTA E REDES NEURAIAS ARTIFICIAIS PARA AFILAMENTO
DO FUSTE DE EUCALIPTO EM SISTEMA DE INTEGRAÇÃO LAVOURA-
PECUÁRIA-FLORESTA

CURITIBA
2018

CLEBSON LIMA CERQUEIRA

MODELAGEM MISTA E REDES NEURAIS ARTIFICIAIS PARA AFILAMENTO
DO FUSTE DE EUCALIPTO EM SISTEMA DE INTEGRAÇÃO LAVOURA-
PECUÁRIA-FLORESTA

Trabalho de conclusão de curso apresentado ao
Curso de Especialização em Manejo de Precisão, do
Programa de Educação Continuada em Ciências
Agrárias, da Universidade Federal do Paraná, como
pré-requisito para obtenção do título de especialista.

Orientador (a): Prof. Dr. Julio Eduardo Arce

CURITIBA
2018

MODELAGEM MISTA E REDES NEURAIS ARTIFICIAIS PARA FORMA DO FUSTE DE EUCALIPTO EM SISTEMA DE INTEGRAÇÃO LAVOURA-PECUÁRIA-FLORESTA

Clebson Lima Cerqueira¹

¹Engenheiro Florestal, Bacharel em Engenharia Florestal, Universidade Federal do Piauí (UFPI), mestre em Ciências Florestais e Ambientais, Universidade Federal de Mato Grosso (UFMT), doutorando em Engenharia Florestal, Universidade Federal do Paraná (UFPR), clebsonlima10@hotmail.com

RESUMO

Este trabalho teve como objetivo avaliar e comparar a modelagem de efeitos mistos e redes neurais artificiais para estimar o afilamento de eucalipto em sistemas de integração Lavoura-Pecuária-Floresta (iLPF). Os dados foram coletados em uma área experimental de iLPF, implantada pela Empresa Brasileira de Pesquisa Agropecuária – EMBRAPA Agrossilvipastoril, localizada no município de Sinop, Estado do Mato Grosso. Para alcançar o objetivo proposto, 165 árvores com 51 meses de idade foram rigorosamente cubadas para a modelagem do afilamento com modelos de efeitos mistos e redes neurais artificiais. O desempenho destas técnicas foi avaliada por meio de estatísticas de precisão e análise gráfica. A modelagem de efeitos mistos e redes neurais artificiais são eficientes e recomendadas para estimativa do afilamento de eucalipto em sistema de integração lavoura-pecuária-floresta, contudo, apesar de ambas técnicas avaliadas apresentarem resultados precisos para predição do afilamento das árvores amostradas, a rede neural artificial prediz valores com maior precisão que a modelagem de efeitos mistos.

Palavras-Chave: Biometria florestal, Inteligência artificial, Modelagem não linear mista.

ABSTRACT

Mixed modeling and artificial neural network for stem taper of eucalyptus in integrated crop-livestock-forestry systems. This work aimed to evaluate and compare the mixed effects modeling and artificial neural networks to estimate of taper of eucalyptus in integrated crop-livestock-forestry (iCLF) systems. Data were collected in an experiment area of iCLF, implanted by the Brazilian Company of Farming Research – EMBRAPA Agrossilvipastoril, located in the municipality of Sinop, Mato Grosso State. For reach the proposed aim, 165 trees with 51 months of age were rigorously scaled for the taper modeling with mixed effects models and artificial neural networks. The performance of these techniques was evaluated through precision measurements and graphical analysis. Mixed effects modeling and artificial neural networks are efficient and recommended for estimate of taper of eucalyptus in integrated crop-livestock-forestry system, however, despite both evaluated techniques present results accurate for predicting the taper of the sampled trees, the artificial neural network predicts values with greater precision than the modeling of mixed effects.

Key words: Forest biometry, Artificial intelligence, Nonlinear mixed modeling.

SUMÁRIO

1. INTRODUÇÃO	3
2. MATERIAL E MÉTODOS	5
2.1. Caracterização da área de estudo	5
2.2. Base de dados	6
2.3. Afilamento do fuste	7
2.3.1 Modelagem de efeitos mistos (MEM)	7
2.3.2 Redes Neurais Artificiais (RNAs)	8
2.3.3 Ajuste e acurácia dos modelos	9
3. RESULTADOS E DISCUSSÃO	10
4. CONCLUSÃO	16
5. REFERÊNCIAS BIBLIOGRÁFICAS	1

1. INTRODUÇÃO

Dada a crescente demanda pelos diversos produtos de origem agropecuário e florestal, diversas alternativas de produção têm sido estudadas e implementadas visando a maior produtividade. Dentre várias alternativas tem os sistemas de integração lavoura-pecuária-floresta (iLPF), que une diferentes sistemas produtivos na mesma área.

Nestes modelos de produção, culturas agrícolas, árvores, pastagens e animais são integrados visando potencializar interações ecológicas e econômicas (TORRES et al. 2016). Esse modelo de produção vem crescendo por meio de programas de fomento, tais como o Programa Agricultura de Baixo Carbono (ABC), implantado pelo governo federal instituído pela Lei nº 12.187 de 29 de dezembro de 2009, que institui a Política Nacional sobre Mudanças do Clima (PNMC).

Nesse contexto, surge a necessidade e interesse por parte dos produtores e gestores florestais em manejar o componente florestal, visando a quantificação da produção, uma vez que essas informações subsidiam o planejamento florestal. Para isso, utilizam-se técnicas de modelagem por meio de estatísticas e ferramentas computacionais para assim, obter estimativas acuradas da produção. Dentre várias técnicas utilizadas no Brasil e no mundo tem se as funções de afilamento, que podem ser utilizadas para fornecer informações sobre a produção volumétrica e os sortimentos de madeira.

A modelagem da forma do fuste em povoamentos estabelecidos em monocultivo e arranjos espaciais convencionais é um assunto bastante difundido no setor florestal brasileiro, com diversos estudos desenvolvidos e propostos para representar o perfil do fuste para espécies do gênero *Eucalyptus*, dentre outros pode-se citar Mendonça et al. 2007; Miguel et al. 2011; Môra et al. 2014; carvalho et al. 2014; Ribeiro e Andrade 2016; Souza et al. 2016). No entanto, pesquisas sobre a forma do fuste de *Eucalyptus* estabelecido em sistemas agroflorestais ainda são escassos, destacando-se os trabalhos de Müller et al. 2014 e Cerqueira et al. (2017) que utilizaram técnicas convencionais de regressão. Já em relação ao emprego de novas técnicas de modelagem do perfil do fuste, Silva et al. (2016) obtiveram resultados promissores com o uso de inteligência artificial em sistemas

agroflorestais. Dessa forma a adoção de novas técnicas de modelagem podem gerar estimativas com maior grau de precisão, como a modelagem de efeitos mistos e inteligência artificial.

A modelagem de efeitos mistos (MEM) é uma técnica caracterizada por utilizar parâmetros de efeitos fixos e aleatórios em dados com medidas repetidas, podendo ser em modelos lineares ou não lineares, dependendo do estudo de interesse (MÔRA, 2015). Segundo Schabenberger e Pierce (2002) essa técnica deve ser utilizada quando se dispõe de um conjunto de dados que está agrupado ou que necessita da inclusão de efeitos aleatórios. Apesar da eficiência da MEM, esta técnica para afilamento das árvores é relativamente recente na engenharia florestal. Atualmente, existem poucos trabalhos desenvolvidos com funções de afilamento, destacando-se os autores Garber e Maguire (2003); Sharma e Parton (2009); Yang *et al.* (2009); Özçelik *et al.* (2011), Cao e Wang (2011); Carvalho *et al.* (2014); Môra (2015); Guangyi *et al.* (2015); Rodil *et al.* (2015), Zheng *et al.* (2017); Nicoletti (2017).

As redes neurais artificiais (RNAs) são modelos computacionais inspirados no sistema nervoso de cérebros biológicos. Braga *et al.* (2000) definiu como sistemas paralelos constituídos por unidades de processamento simples, também denominadas neurônios artificiais ou nodos, conectados e que operam de forma unidirecional de maneira específica para desempenhar determinada função matemática. Os elementos fundamentais de uma RNA são os neurônios artificiais ou unidades de processamento, dispostos em uma ou mais camadas de forma paralela e interligados entre si por um grande número de conexões (rede), formando desta maneira o sistema de RNA (KOVÁCS, 1996; SILVA *et al.*, 2010).

O emprego da RNA na ciência florestal tem confirmado a eficiência dessa técnica em diversas situações, com destaque para a geração de estimativas dendrométricas. Sua utilização como ferramenta em estudos de diâmetro ao longo do fuste já é considerada eficiente por diversos autores Schikowski *et al.* (2015), Mendonça *et al.* (2015), Martins *et al.* (2016), Silva *et al.* (2016), Campos *et al.* (2017) e Martins *et al.* (2017).

Dada a importância dos estudos de modelagem do fuste em sistemas agroflorestais, objetivou-se avaliar e comparar a modelagem de efeitos mistos e

redes neurais artificiais para estimativa do afilamento de eucalipto em sistema de integração lavoura-pecuária-floresta.

2. MATERIAL E MÉTODOS

2.1. Caracterização da área de estudo

Os dados para realização do presente estudo foram obtidos em sistema de integração-lavoura-pecuária-floresta (iLPF), em duas áreas experimentais implantada pela Empresa Brasileira de Pesquisa Agropecuária (Embrapa Agrossilvipastoril), denominadas iLPF leite e iLPF corte, localizadas no município de Sinop, na região norte de Mato Grosso, nas coordenadas 11°50'53" S e 55°38'57" W (Figura 1). De acordo com a classificação de Köppen o clima da região é do tipo tropical de monção, com três meses de seca e precipitação anual de 2.500 a 2.800 mm, com temperatura média anual de 24-26 °C, com máximas em torno dos 40 °C e mínimas próximas de 20 °C, altitude de 380 m (ALVARES et al., 2013). Com relevo plano e predomínio do latossolo vermelho amarelo argiloso (SEMA, 2014).

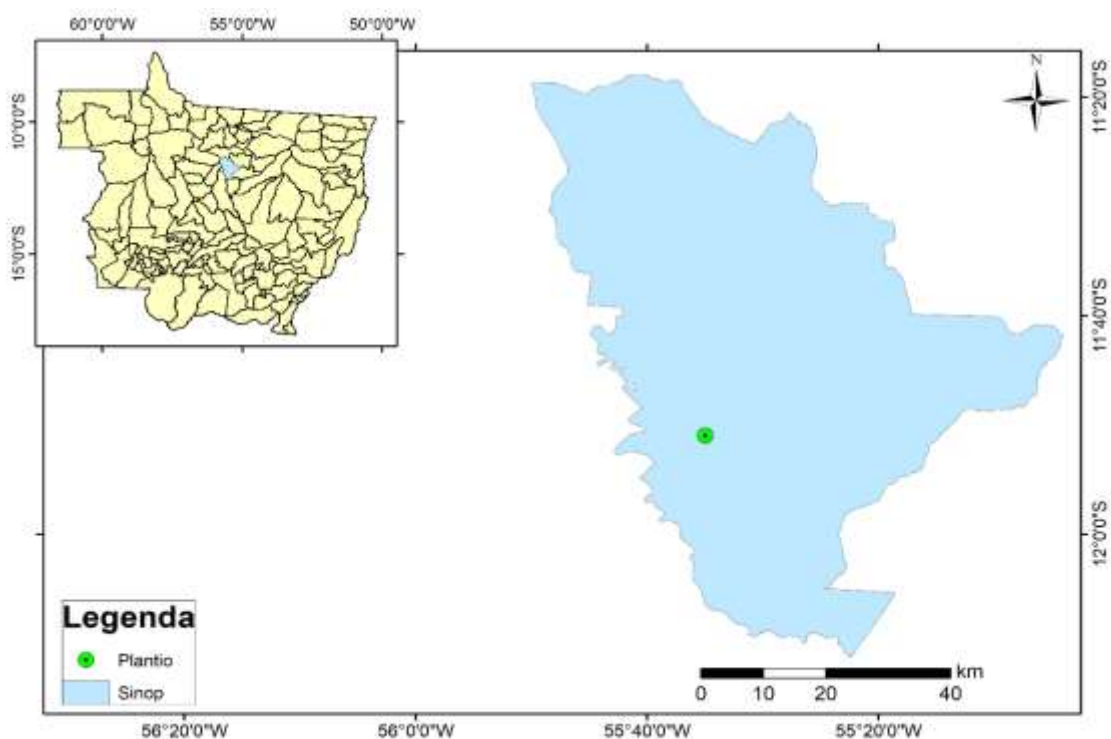


Figura 1 - Localização da área de estudo em Sinop, Mato Grosso.

Os experimentos foram implantados em fevereiro (iLPF leite) e dezembro de 2011 (iLPF corte), em delineamento em blocos casualizados (DBC) com três tratamentos: lavoura-pecuária-floresta (T1); Pecuária-floresta (T2) e plantio homogêneo (T3). No tratamento T1, adotou-se o arranjo de plantio das árvores em faixas triplas com o eucalipto consorciado com pastagem de capim-piatã (*Brachiaria brizantha* cv. Piatã) em integração com milho para silagem e criação de gado leiteiro girolanda. No tratamento T2 foi adotado o plantio das árvores em faixas, de três linhas consorciado com capim-piatã (*Brachiaria brizantha* cv. Piatã) e criação de boi para corte.

Os tratamentos foram estabelecidos em diferentes arranjos espaciais (Tabela 1). O componente florestal utilizado é o clone de híbrido *Eucalyptus grandis* x *Eucalyptus urophylla* e a orientação de plantio das árvores nas linhas foi no sentido leste oeste, ambos plantados em sulcos de 30 cm de profundidade.

2.2. Base de dados

Os dados para realização deste trabalho foram obtidos por meio da cubagem de 165 árvores aos 51 meses de idade distribuídas entre os tratamentos estudados (Tabela 1). As árvores cubadas foram selecionadas com base na distribuição diamétrica dos tratamentos provenientes dos dados do inventário florestal. Os indivíduos selecionados foram abatidos, seccionados e mensurados os diâmetros com casca com auxílio da Suta e trena nas seguintes alturas: 0,10 m; 0,70 m; 1,30 m e posterior em intervalos de 1,0 m até um diâmetro mínimo de aproximadamente 1,0 cm.

Para cada árvore, mensurou-se além dos diâmetros (d_i) nas várias alturas (h_i), o diâmetro a 1,30 m (d_{ap}) e altura total (h). A obtenção do volume individual das árvores, considerado como real foi obtido por meio da aplicação da fórmula de Smalian.

Tabela 1 - Distribuição de frequência das árvores cubadas nos diferentes tratamentos.

Tratamentos	Arranjo espacial (m)	N (ha^{-1})	N	L
T1	3x2x15	714	56	3
T2	3,5x3x30	270	54	3
T3	3,5x3	952	55	x
Total		1936	165	

N (ha⁻¹)=número de árvores por hectare; N=número de árvores cubadas; L=número de linhas de plantio das árvores nos tratamentos (T1 e T2).

2.3. Afilamento do fuste

Para estudar a forma do fuste, foram testadas e avaliadas duas técnicas, sendo a modelagem de efeitos mistos (MEM) e redes neurais artificiais (RNAs).

2.3.1 Modelagem de efeitos mistos (MEM)

O procedimento de modelagem de efeitos mistos foi empregado utilizando o modelo de afilamento polinomial proposto por Schöepfer (1966) (Equação. 1) com a finalidade de obter estimativas do diâmetro ao longo do fuste das árvores nos diferentes tratamentos.

Adotou-se o polinômio do quinto grau por ser um modelo não segmentado amplamente utilizado pelos profissionais das ciências florestais, sendo frequentemente utilizado em inventários florestais quando o objetivo é quantificar multiprodutos e também avaliar a forma do tronco em diferentes idades e espaçamentos. Isso se deve ao fato da facilidade de ajuste e da acurácia que em geral esse modelo proporciona (Figueiredo Filho et al. 2015).

$$\frac{d_{ij}}{dap_j} = \phi_0 + \phi_1 T_{ij} + \phi_2 T_{ij}^2 + \phi_3 T_{ij}^3 + \phi_4 T_{ij}^4 + \phi_5 T_{ij}^5 + \varepsilon_{ij} \quad (1)$$

Em que: d_i = diâmetro com casca (cm) da i -ésima árvore na j -ésima altura h_i (m); dap = diâmetro a 1,3 m do solo (cm) da i -ésima árvore; ϕ = coeficientes fixos e aleatórios; T_{ij} = altura relativa $\left(\frac{h_i}{h}\right)$ da i -ésima árvore na j -ésima posição do fuste; ε = erro aleatório.

A estrutura do modelo misto de afilamento utilizado é representada na equação 2.

$$\phi = \begin{bmatrix} \phi_0 \\ \phi_1 \\ \phi_2 \\ \phi_3 \\ \phi_4 \\ \phi_5 \end{bmatrix} = \begin{bmatrix} \beta_0 \\ \beta_1 \\ \beta_2 \\ \beta_3 \\ \beta_4 \\ \beta_5 \end{bmatrix} + \begin{bmatrix} b_0 \\ b_1 \\ b_2 \\ b_3 \\ b_4 \\ b_5 \end{bmatrix} = \boldsymbol{\beta} + \boldsymbol{b} \quad (2)$$

Sendo que: $b \sim N(0, \sigma^2)$ $\varepsilon \sim N(0, \sigma^2 I)$. O vetor $\boldsymbol{\beta}$ representa os efeitos fixos e o vetor \boldsymbol{b} os efeitos aleatórios.

A modelagem não linear mista (*nlme*) foi aplicada adotando como efeito aleatório o espaçamento e arranjos espaciais dos experimentos com a finalidade de aumentar a precisão das predições de diâmetro, visto que nem sempre as equações ajustadas pela técnica de modelagem tradicional estimam com precisão

os diâmetros em todas as partes do fuste (base, meio e ápice), podendo se avaliar com a técnica possíveis melhorias. Além de que, a técnica foi aplicada com o objetivo de agrupar os dados obtidos nos diferentes espaçamentos e arranjos espaciais estudados.

2.3.2 Redes Neurais Artificiais (RNAs)

O treinamento das RNAs foi realizado visando estimar os diâmetros (d_i) ao longo do fuste (variável de saída), utilizando como variáveis de entrada quantitativas o dap , h e h_i e como entrada categóricas o espaçamento e arranjos espaciais. As RNAs utilizadas foram do tipo de multicamada (camada de entrada, intermediária e de saída) que possui capacidade universal de aproximação de funções (Hornik et al., 1989). O algoritmo de treinamento foi o de retropropagação do erro, que tem como vantagem o método do gradiente descendente estocástico para atualização dos pesos sinápticos (CANDEL et al., 2018).

As redes foram treinadas com apenas uma camada intermediária e o número de neurônios variando de 1 a 15. A função de ativação utilizada na camada intermediária foi a *maxout* (Equação 3), enquanto na camada de saída empregou-se a função linear (Equação 4).

$$f(\alpha_1, \alpha_2) = \max(\alpha_1, \alpha_2) \quad (3)$$

$$f(\alpha) = \sum_i x_i w_i + b \quad (4)$$

Em que: $f(\alpha)$ = função de ativação; x_i =vetor de entradas; w_i =vetor de pesos sinápticos; b =bias.

Para obtenção dos pesos que minimizam o erro das predições utilizou-se o método de busca em grade. Este método requer a definição de um conjunto ou sequência de valores para cada parâmetro, para que a busca seja realizada por meio de ajustes sucessivos, utilizando todas as combinações de parâmetros possíveis (BERGSTRA e BENGIO, 2012).

O treinamento das RNAs consistiu na aplicação do método de validação cruzada *n-fold*, combinado ao método de busca em grade conforme demonstrado por Candel et al. (2018). Segundo Shalev-Shwartz e Ben-David (2014), o método *n-fold* consiste em dividir a base de dados aleatoriamente em n subconjuntos de dimensões similares e, para cada configuração do algoritmo, realizar n treinamentos, separando um subconjunto por vez para validação. Desse modo,

todas as instâncias são utilizadas $n-1$ vezes para treinamento e uma vez para validação. A medida de acurácia de cada configuração é obtida pela média do erro quadrático médio das n validações. Após a etapa de validação cruzada, o algoritmo efetua o treinamento de um modelo final para a configuração testada, utilizando todo o conjunto de dados de treinamento.

A melhor configuração foi a que conferiu ao modelo o menor erro quadrático médio obtido por validação cruzada, com um número máximo de 3000 ciclos. O treinamento foi automaticamente interrompido pelo algoritmo quando a precisão do modelo não foi incrementada por 20 ciclos. O treinamento das redes foi realizado em linguagem R de programação (R CORE TEAM, 2016), utilizado o pacote (*h2o*) (THE H2O. AI TEAM, 2017) que realiza a validação cruzada *n-fold* automaticamente a partir da determinação do número de subconjuntos (*folds*) pelo usuário, que neste estudo definiu-se *5-fold*. Com isso, a base de dados foi dividida em 5 partes, sendo 4 para treinamento e 1 para validação e assim sucessivamente até que todas as partes sejam treinadas e validadas entre elas. Finalmente a melhor rede validada foi treinada para toda a base dados.

2.3.3 Ajuste e acurácia dos modelos

O ajuste do modelo, treinamento da rede neural e procedimentos estatísticos foram realizados no *Software R*, versão 3.3 (R DEVELOPMENT CORE TEAM, 2016). A precisão e acurácia das técnicas de modelagem foram analisadas com base nos seguintes critérios estatísticos: maior coeficiente de correlação ao quadrado ($r_{y\hat{y}}^2$), menor valor da raiz quadrada do erro médio em porcentagem (RQEM %) e análise gráfica dos resíduos, calculados pelas Equações 5, 6 e 7 respectivamente:

$$r_{y\hat{y}}^2 = \frac{\left[\sum_{i=1}^n y_i \hat{y}_i - \frac{(\sum_{i=1}^n \hat{y}_i)(\sum_{i=1}^n y_i)}{n} \right]^2}{\left[\sum_{i=1}^n y_i^2 - \frac{(\sum_{i=1}^n y_i)^2}{n} \right] \left[\sum_{i=1}^n \hat{y}_i^2 - \frac{(\sum_{i=1}^n \hat{y}_i)^2}{n} \right]} 100 \quad (5)$$

$$RMSE\% = \frac{100}{\bar{Y}} \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad (6)$$

$$(7)$$

$$E_{\%} = \left(\frac{y - \hat{y}}{y} \right) * 100$$

Em que: \hat{y} é a variável regressora estimada pelo modelo; y é a variável observada; \bar{y} é a média das variáveis observadas.

3. RESULTADOS E DISCUSSÃO

Na figura 2, observa-se a distribuição diamétrica das árvores amostradas com amplitude de classes de dap de 2 cm definida com base no critério de Sturges. Nota-se que os dados apresentam uma distribuição de diâmetros de forma simétrica, e segundo Soares et al. (2011) esse comportamento é esperado em florestas plantadas, visto que a maior frequência de indivíduos está próxima à média do povoamento.




Figura 2 – Distribuição diamétrica das árvores cubadas.

Para caracterização da variação da forma do fuste das árvores amostras, plotou-se gráfico por meio da altura (h_i) e diâmetro (d_i) ao longo do fuste, bem como com as variáveis d_i e h_i relativizados (Figura 3).




Figura 3 - Variação do perfil do fuste das árvores cubadas. a=variação do perfil do fuste em função do diâmetro versus altura; b=diâmetro versus altura relativizados.

Alguns atributos do povoamento como (espaçamento, idade, sítio, classe diamétrica, material genético), dentre outros, exercem influência sobre a forma do fuste das árvores no povoamento (LARSON, 1963; FINGER, 1992; SCHNEIDER, 1993; SCOLFORO e THIERSCH, 2004). Assim, ao realizar o ajuste de modelos de afilamento e estes serem avaliados como efeito aleatório ou variáveis categóricas, espera-se obter estimativas mais acuradas.

Com a utilização do procedimento de modelagem de efeitos mistos definiu-se como efeito aleatório o espaçamento de plantio e foram estimados os coeficientes fixos e aleatórios (Tabela 2). Durante o procedimento de ajuste do modelo de Schöpfer que considerou todos os parâmetros aleatórios, não houve convergência. Assim, para o seu ajuste considerou-se como coeficientes aleatórios \emptyset_0 até \emptyset_4 .

Tabela 2 - Coeficientes fixos para todo o conjunto de dados e aleatórios por tratamento.

Modelo	Trat.	\emptyset_0	\emptyset_1	\emptyset_2	\emptyset_3	\emptyset_4	\emptyset_5
Coeficientes aleatórios							
	T1	1,2120	-3,4416	13,0674	-27,8758	26,9320	-9,9008
	T2	1,1990	-3,5508	13,0676	-28,0515	27,2022	-9,9008
Schöpfer	T3	1,1738	-3,3033	13,0674	-28,4421	27,3921	-9,9008
Coeficientes fixos							
	T	1,1949*	-3,4319*	13,0674*	-28,1231*	27,1754*	-9,9008*

Trat=tratamentos estudados; T=dados agrupados.

Observa-se que todos os coeficientes fixos foram significativos. Percebe-se que apenas o coeficiente \emptyset_5 manteve-se constante, os demais variaram de acordo com o efeito aleatório do tratamento. Verificou-se que a medida que aumenta o número de coeficientes aleatórios no modelo misto, aumenta a precisão das estimativas, como também observado por Môra (2015). No entanto, quando o modelo possui o número elevado de parâmetros dificulta o procedimento matricial pelo software e em muitos casos não há convergência. Nestes casos o ideal é diminuir o número de parâmetros aleatórios do modelo.

A função de ativação utilizada para a RNA (*Maxout*) apresentou resultados satisfatórios para estimativa dos diâmetros ao longo do fuste. A arquitetura da melhor RNA treinada apresentou 6 neurônios de entrada, 14 na camada oculta e 1 na saída.

Na Tabela 3, são apresentadas as estatísticas da rede neural artificial (RNA) e do modelo de afilamento com efeitos mistos para estimativa dos diâmetros ao longo do fuste das árvores de eucalipto.

Tabela 3 - Estatísticas de avaliação da modelagem mista e redes neurais artificiais.

Ajuste/treino	r_{yy}^2 (%)	RMSE (%)
MEM	98,483	6,65
RNA	98,797	6,14

Com base nas estatísticas de avaliação da MEM e RNA, nota-se que ambas as técnicas apresentaram estimativas acuradas com resultados semelhantes. No entanto, observa-se por meio desses critérios que a RNA apresentou um maior r_{yy}^2 (%) e uma redução de 0,51% de erro médio *RMSE*.

Também foi avaliado a MEM e RNA por meio da análise gráfica dos resíduos (Figura 4).

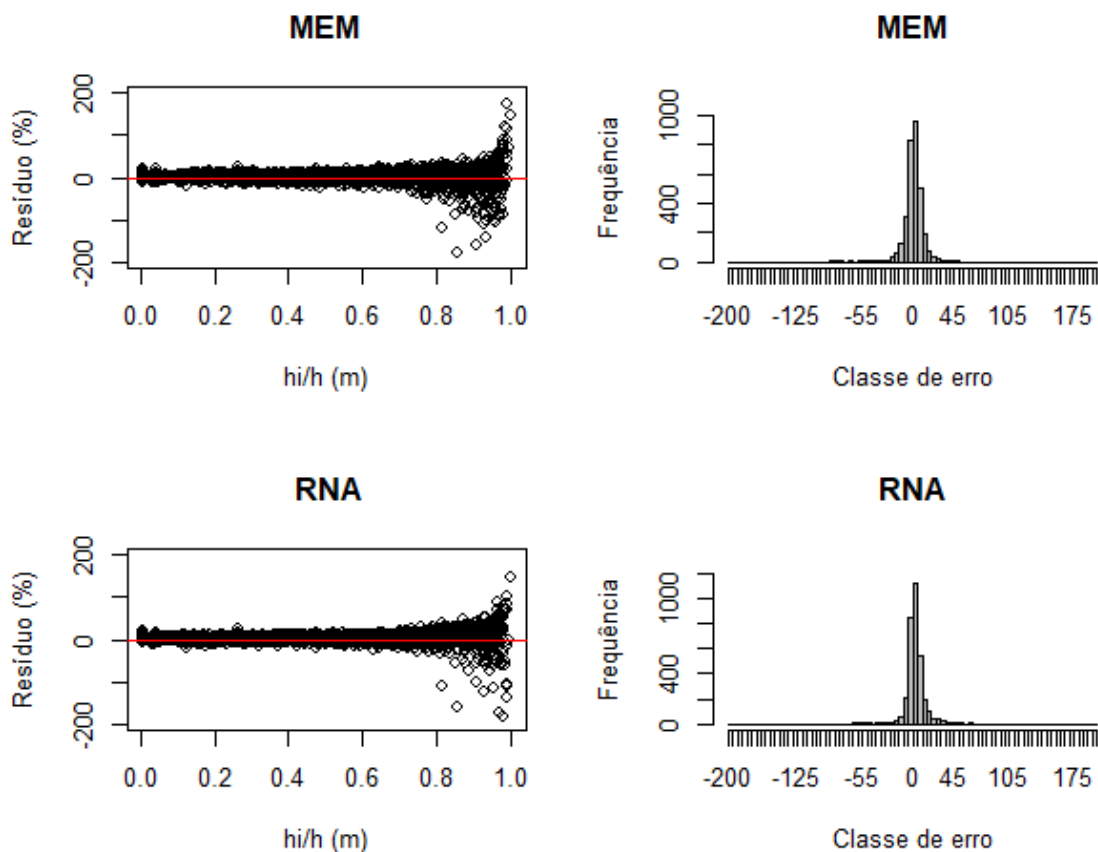


Figura 4 - Distribuição dos resíduos e histograma dos erros para a modelagem de efeitos mistos e redes neurais artificiais.

Analisando os gráficos de resíduos, o qual permite avaliar o comportamento dos erros ao longo dos fustes, observa-se uma similaridade entre MEM e RNA, com distribuição adequada ao longo da linha de regressão, o que indica boa precisão entre os valores observados e estimados. Entretanto, nota-se uma maior dispersão com superestimativa e subestimativa da variável d_i na parte apical das árvores. Os histogramas dos resíduos apresentaram distribuição simétrica e média em torno de 0, confirmando a acurácia das técnicas avaliadas.

A dificuldade em estimar os menores diâmetros na porção final do fuste é comum em estudos de afilamento, como também relatado por Téo et al. (2013); Mendonça et al. (2015); Schikowski et al. (2015). Em alguns casos os maiores erros são acentuados nos maiores diâmetros na base dos fustes, como destacado por Môra et al. (2014) e Souza et al. (2016).

A precisão das estimativas pela MEM e RNA também pode ser visualizada pelo gráfico dos dados de di observado em função do estimado pelas duas técnicas (Figura 5).

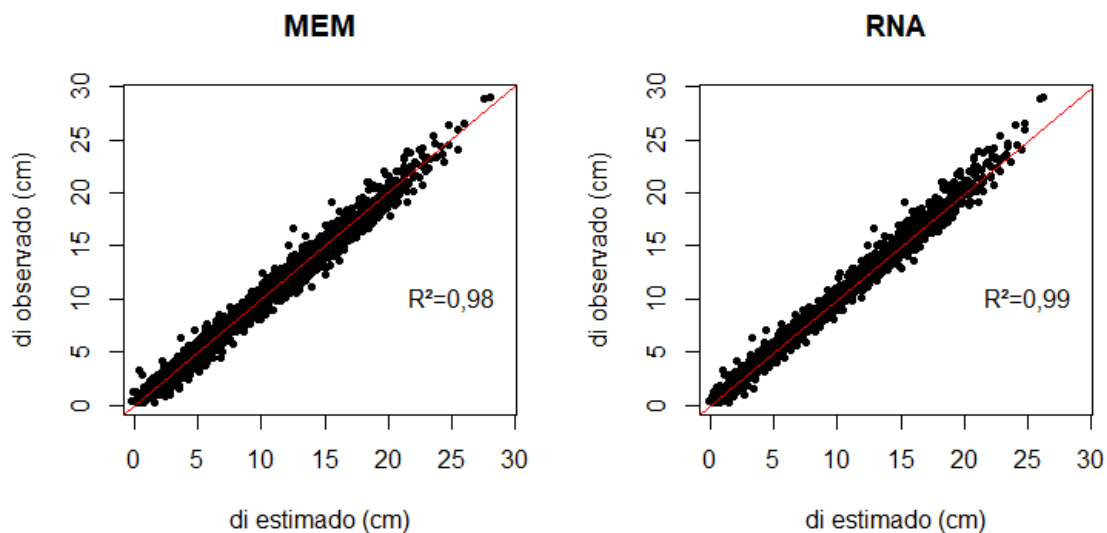


Figura 5 - Diâmetro observado versus estimado pela MEM e RNA.

Observa-se na Figura 5 que os valores observados versus estimados ao longo da linha, partindo da origem formando um ângulo de 45 graus, apresentaram-se semelhantes entre as duas técnicas, porém a RNA apresentou maior correlação 0,99 entre os diâmetros observados e estimados.

A Figura 6 ilustra o afilamento da árvore média com diâmetros ao longo fuste observados, e estimados pela MEM e RNA. Nota-se que a MEM e RNA estimaram com precisão o perfil da árvore média confirmando-se pela sobreposição das curvas. No entanto, houve uma pequena discrepância na parte basal do fuste pela MEM.




Figura 6 - Perfil médio observado e estimado pela MEM e RNA.

Com base nos indicadores estatísticos, distribuição residual, dados observados versus estimados e curvas estimada do perfil da árvore média, confirma-se que as duas técnicas apresentam resultados acurados para estimativa do afilamento das árvores mensuradas, com um pequeno ganho em precisão pelas RNA. No entanto, as RNAs têm como vantagem a flexibilidade de inserção de mais variáveis explicativas simultaneamente fornecendo ao processo de ajuste maior agilidade e acurácia das estimativas, uma vez que elimina o processo de estratificação dos dados, como também destacado por Binoti (2012) e Martins et al. (2015).

Outros autores também estudaram a aplicação das redes neurais artificiais para o afilamento de eucalipto e encontraram resultados satisfatórios, recomendando seu uso utilizando diferentes configurações de redes, número de neurônios, funções de ativação e parâmetros de treinamento, dentre outros cita-se Souza et al. (2013); Schikowski et al. (2015) e Martins et al. (2016);

A acurácia da MEM observada neste estudo para predição da forma do tronco, já foi comprovado e relatada por outros autores estudando a forma do fuste com a aplicação de efeitos aleatórios, dentre outros ressalta-se os trabalhos de Cao e Wang, 2011; Carvalho et al. 2014; Môra, 2015; Macfarlane e Weiskittel, 2016; Nicoletti, 2017.

Cabe salientar, que além das estimativas acuradas, outro fator importante da MEM e RNA é a possibilidade de agrupar dados de condições florestais diferentes (espaçamentos, material genético, sítio, classe diamétrica e idade) e realizar o procedimento de ajuste com uma única base de dados reduzindo o número de equações com ganhos de tempo e acurácia, conseqüentemente isso reflete nos custos do inventário florestal. Além disso, permitem trabalhar com os dados sem precisar atender alguns pressupostos da regressão, tais como independência entre as observações, distribuição aleatória, normal e idêntica dos resíduos, com média zero e variância constante (LAPPI, 1991; SANQUETTA et al. 2015; NICOLETTI, 2017).

Cerqueira et al. (2017) avaliou a influência do espaçamento e arranjo de plantio na forma do fuste de eucalipto e concluiu que os mesmos influência de forma significativa na forma do fuste das árvores, e uma única equação não deve ser

ajustada para prever o afilamento para dados globais que contemplem diferentes densidades em sistema iLPF.

Com isso, nota-se a importância de estudos com aplicação dos modelos mistos e redes neurais para predição da forma das árvores visando otimizar os sortimentos de madeira em iLPF. Outro fator de grande relevância é a possibilidade de redução do número de árvores amostra para os ajustes, como também mencionado por, Mendonça et al. (2015) e Dorado et al. (2006), que o emprego da teoria dos modelos mistos possibilita a diminuição da intensidade amostral necessária para calibração do modelo com precisão adequada. Binoti et al. (2013) avaliou a redução dos custos com na atividade do inventário florestal de povoamentos de eucalipto e concluiu que é possível reduzir o número de medições de altura sem perda de precisão nas estimativas com o emprego da RNA.

A redução da intensidade amostral é de suma importância para a mensuração florestal dos sistemas integrados de produção, tendo em vista que nesses sistemas tem-se um número reduzido de árvores se comparado aos sistemas convencionais de produção.

Desta forma, a modelagem de efeitos mistos e redes neurais artificiais são ferramentas importantes para estimativa do afilamento e conseqüentemente do sortimento de madeira das árvores, podendo ser utilizadas para dar suporte ao manejo florestal de eucalipto em sistema iLPF.

4. CONCLUSÃO

A modelagem de efeitos mistos e redes neurais artificiais são eficientes e recomendadas para estimativa do afilamento de eucalipto em sistema de integração lavoura-pecuária-floresta.

As duas técnicas avaliadas apresentam resultados acurados e similares para estimativa dos diâmetros ao longo do fuste das árvores de eucalipto

5. REFERÊNCIAS BIBLIOGRÁFICAS

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

BERGSTRA, J.; BENGIO, Y. Random search for hyper-parameter optimization. **The Journal of Machine Learning Research**, Montréal, Qc, Canada, v. 13, n. 1, p.281-305, 2012.

BINOTI, M. L. M. S. **Emprego de Redes Neurais Artificiais em mensuração e manejo florestal**. 130f. (Doutorado em Mensuração Florestal) – Departamento de Ciências Florestais. Universidade Federal de Viçosa, Minas Gerais, 2012.

BINOTI, M. L. M. S.; BINOTI, D. H. B. ; LEITE, H. G. ; SILVA, A. ; PONTES, C. R. . Aplicação de redes neurais artificiais para estimação da altura de povoamentos equiâneos de eucalipto. **Revista Árvore** (Impresso), v. 37, p. 639-645, 2013.

BRAGA, A. P.; CARVALHO A. P. L. F.; LUDEMIR, T. B. **Redes Neurais Artificiais: Teoria e Aplicações**. LTC - Livros Técnicos e Científicos Editora S.A., 2000. 262p.

CAMPOS, B. P. F.; SILVA, G. F.; BINOTI, D. H. B.; MENDONÇA, A. R. LEITE, H. G. Descrição do perfil do tronco de árvores em plantios de diferentes espécies por meio de redes neurais artificiais. **Pesquisa Florestal Brasileira**. v.37, n.90, p.99-107, 2017.

CANDEL, A., PARMAR, V., LEDELL, E., ARORA, A. (Mar. 2018). Deep Learning with H2O. <http://h2o.ai/resources>.

CAO, Q. V.; WANG, J. Calibrating fixed- and mixed-effects taper equations. **Forest Ecology and Management**, Amsterdã, v.262, n.4, p.671-673, 2011.

CARVALHO, S. P. C.; RODRIGUES, L. C. E.; CALEGARIO, N.; SAVIAN, T. V.; LIMA, M. P.; SILVA, C. A.; MENDONÇA, A. R.; NICOLETTI, M. F. Modelagem não linear mista para descrever o afilamento de árvores clonais de *Eucalyptus sp.* **Scientia Forestalis**. 42 (104): 605-614. 2014.

CERQUEIRA, L. C.; MÔRA, R.; TONINI, H. Forma do fuste de eucalipto em diferentes arranjos de plantio e espaçamento. **Advances in Forestry Science**, v. 4, n.3, p.137-141, 2017.

DORADO, F. C.; DIÉGUEZ-ARANDA, U.; ANTA, M. B.; RODRIGUEZ, M. S.; VON GADOW, K. A generalized height–diameter model including random components

for radiata pine plantations in northwestern Spain. **Forest Ecology and Management**, Amsterdam, v. 229, p. 202- 213. 2006.

FIGUEIREDO FILHO, A.; RETSLAFF, F. A. Z.; KOHLER, S. V.; BECKER, M.; BRANDES, D. Efeito da idade no afilamento e sortimento em povoamentos de *Araucaria angustifolia*. **Revista Floresta e Ambiente**, v.22 (1): 50-59, 2015.

FINGER, C. A. G. **Fundamentos de biometria florestal**. Santa Maria: UFSM, CEPEF - FATEC, p. 269, 1992.

GARBER, S. M.; MAGUIRE, D. A. Modeling stem taper of three central Oregon species using nonlinear mixed effects models and autoregressive error structures. **Forest Ecology and Management**, Amsterdã, v.179, n.1–3, p.507–522, 2003.

GUANGYI, M.; YUJUN, S.; MIGUEL, S. A mixed-effects model with diferente strategies for modeling volume in *Cunningghamia laceolata* plantations. **PLoS ONE**, v.10, n.10. 2015.

HORNIK, K.; STINCHCOMBE, M.; WHITE, H. Multilayer feed forward network are universal approximators. *Neural Networks, Bandera*, v. 2, n. 5, p. 359-366, 1989.

KOVÁCS, Z. L. **Redes neurais artificiais: fundamentos e aplicações**. 2.ed. São Paulo: Colledium Cognition, 1996. 174 p.

LARSON, P. R. Stem form development of forest trees. **Forest Science** (Monograph), Washington, p.1-41, 1963.

LAPPI, J. Mixed linear models for analyzing and predicting stem form variation of Scots pine. **Communicationes Instituti Forestalis Fenniae**, v.134, p.1-69, 1986.

MACFARLANE, D. W.; WEISKITTEL, A. R. A new method for capturing stem taper variation for trees of diverse morphological types. **Canadian Journal Forest**. V.46, p.804-815. 2016.

MARTINS, A. P. M.; DEBASTIANI, A. B.; PELISSARI, A. L.; MACHADO, S. A.; SANQUETTA, C. R. Estimativa do afilamento do fuste de Araucária utilizando técnicas de inteligência artificial. **Floresta e Ambiente**, v.24, 2017.

MARTINS, E. R.; BINOTI, M. L. M. S. LEITE, H. G.; BINOTI, D. H. B.; DUTRA, G. C. Configuração de redes neurais artificiais para estimação do afilamento do fuste de árvores de eucalipto. **Agrária**, v.11, n.1, p.33-38, 2016.

MENDONÇA, A. R.; SILVA, G. F.; OLIVEIRA, J. T. S.; NOGUEIRA, G. S.; ASSIS, A. L. Avaliação de funções de afilamento visando a otimização de fustes de

Eucalyptus sp. Para multiprodutos. **Cerne**, Lavras, v. 13, n. 1, p. 71-82, jan./mar. 2007.

MENDONÇA, N. P.; CARVALHO, M. C.; GOMIDE, L.; FERRAZ FILHO, A. C. F.; FERREIRA, M. A. Previsão de diâmetros ao longo do fuste de eucalipto via redes neurais artificiais. **Enciclopédia Biosfera**, v. 11, n. 22, p. 2419-2429, 2015.

MIGUEL, E. P.; MACHADO, S. A.; FILHO, A. F.; ARCE, J. E. Modelos polinomiais para representar o perfil e o volume do fuste de *Eucalyptus urophylla* na região norte do estado de Goiás. **Floresta**. v.41, n.2, p.355-368, 2011.

MÔRA, R. **Funções de afilamento de forma variável e modelagem de efeitos mistos em fustes de *Pinus taeda* e *Eucalyptus saligna***. 2015. 277 p. Tese (Doutorado em Engenharia Florestal)-Universidade Federal do Paraná, Curitiba, 2015.

MÔRA, R.; SILVA, G. F.; GONÇALVES, F. G.; SOARES, C. P. B.; CHICHORRO, J. F.; CURTO, R. A. Análise de diferentes formas de ajuste de funções de afilamento. **Scientia Forestalis**, Piracicaba, v.42, n.102, p.237-249, 2014.

MÜLLER, M. D.; SALLES, T. T.; PACIULLO, D. S. C.; BRIGHENTII, A. M.; CASTRO, C. R. T. Equações de altura, volume e afilamento para eucalipto e acácia estabelecidos em sistema silvipastoril. **Floresta**. Curitiba, PR, v. 44, n. 3, p. 473-484. 2014.

NICOLETII, M. F. **Modelagem não linear mista e método bivariado para sortimento da produção de *Pinus taeda* L.** 2017. 132 p. Tese (Doutorado em Engenharia florestal)-Universidade Federal do Paraná, Curitiba, 2017.

ÖZÇELIK, R.; BROOKS, J. R.; JIANG, L. Modeling stem profile of Lebanon cedar, Brutian pine, and Cilicica fir in Southern Turkey using nonlinear mixed-effects models. **European Journal of Forest Research**, Dordrecht, v.130, n.4, p.613–621, 2011.

R Core Team (2016). R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. URL <https://www.R-project.org/>.

RIBEIRO, J. R.; ANDRADE, V. C. L. Equações de perfil do tronco para *Eucalyptus camadulensis* Dehnh no Centro-Sul Tocantinense. **Floresta e ambiente**, 2015.

RODIL, M. A.; ARANDA, U. D.; PUERTA, F. R.; SÁNCHEZ, C. A. L.; LÍBANO, E. C.; OBREGÓN, A. C.; DORADO, F. C. Modeling and localizing a stem taper function for *Pinus radiata* in Spain. **Canadian Journal Forest**, v.45. 2015.

SCHABENBERGER, O.; PIERCE, F. J. **Contemporary statistical models: for the plant and soil sciences**. 730p., 2002.

SANQUETTA, C. R.; WOJCIECHOWSKI, J.; CORTE, A. P. D.; BEHLING, A.; PÉLLICO, S. N.; RODRIGUES, A. L.; SANQUETTA, M. N. I. Comparison of data mining and allometric model in estimation of tree biomass. **BMC Bioinformatics**, v.16, n.1, p.247, 2015.

SCHIKOWSKI, A. B.; CORTE, A. P. D.; SANQUETTA, C. R. Estudo da forma do fuste utilizando redes neurais artificiais e funções de afilamento. **Pesquisa Florestal Brasileira**, Colombo, V.35, n.82, p.119-127, 2015.

SCHNEIDER, P. R.; FINGER, C. A. G.; KLEIN, J. E. M.; TOTTI, J. A.; BAZZO, J. L. Forma do tronco e sortimentos de madeira de *Eucalyptus grandis* Maiden para o estado do Rio Grande do Sul. **Ciência Florestal**, v.6, n.1, p.79-88, 1996.

SCHÖEPFER, W. **Automatisierung des massen, sorten and wertberechnung stenender waaldbestande schriftenreihe bad**. [S.l.]: Wurttt-Forstl., 1966.

SCOLFORO, J. R. S. THIERSCH, C. R. **Biometria florestal: medição, volumetria e gravimetria**. Lavras: UFLA/FAEPE, 2004. 285 p.

SHALEV-SHWARTZ, S.; BEM-DAVID, S. **Understanding Machine Learning: From Theory to Algorithms**. New York: Cambridge University Press, 1. ed., 2014.

SHARMA, M.; PARTON, J. Modeling stand density effects on taper for Jack Pine and Black Spruce plantations using dimensional analysis. **Forest Science**, Washington, v.55, n.3, p.268–282, 2009.

SILVA, I. N. da; SPATTI, D. H.; FLAUZINO, R. A. **Redes Neurais Artificiais para engenharia e ciências aplicadas**. Artliber, 2010. 397p.

SOARES, C. P. B.; NETO, F. de P.; SOUZA, A. L. de. **Dendrometria e Inventário Florestal**. 2.ed. Viçosa: Ed. UFV, 2011. 272p.

SILVA, S. NETO, S. N. O. LEITE, H. G.; OBOLARI, A. M. M.; SCHETTINI, B. L. S. Avaliação do uso de regressão e rede neural artificial para modelagem do afilamento do fuste de eucalipto em sistema silvipastoril. **Enciclopedia Biosfera**, v. 13, n.23, p. 189-199, 2016.

SOUZA, R. R.; NOGUEIRA, G. S.; JÚNIOR, L. S. M.; OLIVEIRA, M. L. R.; ABRAHÃO, C. P.; LEITE, H. G. Forma de fuste de árvores de eucalipto em plantios adensados. **Scientia Forestalis**, v.44, n.109, p-33-40, 2016.

TÉO, S. J.; MARCON, A.; EHLERS, T.; BIANCHI, J. C.; PELOSO, A. NAVA, P. R.; COSTA, R. H. (2013) Modelos de afilamento para *Pinus elliottii* em diferentes idades, na região de Caçador, SC. **Floresta**, Curitiba, v.43, n.3, p.439-452.

TORRES, C. M. M. E.; OLIVEIRA, A. C.; PEREIRA, BÁRBARA, L. C.; JACOVINE, L. A. G.; OLIVEIRA NETO, S. N.; CARNEIRO, A. C. O.; TORRES, C. M. M. E. Estimativas da produção e propriedades da madeira de eucalipto em Sistemas Agroflorestais. **Scientia Forestalis**, v. 44, p. 137-148, 2016.

The H2O.ai team (2017). h2o: R Interface for H2O. R package version 3.14.0.3. <https://CRAN.R-project.org/package=h2o>

YANG, Y.; HUANG, S.; TRINCADO, G.; MENG, S. X. Nonlinear mixed-effects modelling of variable-exponent taper equations for lodgepole pine in Alberta, Canada. **European Journal of Forest Research**, Dordrecht, v.128, n.4, p.415–429, 2009.

ZHENG, C.; WANG, Y.; JIA, L.; MASON, E. G.; WE, S.; SUN, C.; DUAN, J. Compatible taper-volume models of *Quercus variabilis* Blue forests in north China. **iForest**, v.10, p.567-575. 2017.