MODELAGEM DA DISTRIBUIÇÃO DIAMÉTRICA DE FLORESTAS TROPICAIS

Mônica Canaan Carvalho^{1*}; Lucas Rezende Gomide²; Antônio Carlos Ferraz Filho³; Wilian Soares Lacerda⁴; Carolina Souza Jarochinski e Silva⁵

^{1*} Doutoranda do Programa de Pós-graduação em Engenharia Florestal, Departamento de Ciências Florestais, Universidade Federal de Lavras, Lavras, MG, Brasil – monicacanaan@gmail.com

² Doutor, Professor adjunto do Departamento de Ciências Florestais, Universidade Federal de Lavras, Lavras, MG, Brasil

³ Doutor, Professor adjunto do Departamento de Ciências Florestais, Universidade Federal de Lavras, Lavras, MG, Brasil

⁴ Doutor, Professor adjunto do Departamento de Ciência da Computação, Universidade Federal de Lavras, Lavras, MG, Brasil

⁵ Doutoranda do Programa de Pós-graduação em Engenharia Florestal, Departamento de Ciências Florestais, Universidade Federal de Lavras, Lavras, MG, Brasil

Recebido em: 03/10/2016 – Aprovado em: 21/11/2016 – Publicado em: 05/12/2016

DOI: 10.18677/EnciBio_2016B_069

RESUMO

O presente estudo teve como principal objetivo aplicar a técnica de Redes Neurais Artificiais na modelagem da estrutura diamétrica de florestas tropicais. Foram utilizados dados de 27 remanescentes florestais nativos inseridos na bacia do Rio Grande em Minas Gerais, totalizando 979 parcelas. Três Redes Neurais Artificiais foram testadas na modelagem diamétrica, sendo as redes 1 e 2 para predição das probabilidades por classe diamétrica e a rede 3 para predição dos parâmetros b e c da função Weibull. A estrutura diamétrica estimada pelas redes foi comparada com a função densidade de probabilidade Weibull com 3 parâmetros, ajustada pelo método dos Momentos e com a distribuição real obtida com informação coletada em campo. A avaliação e comparação dos métodos se deram a partir de análises residuais calculadas por classe diamétrica e pelo teste de aderência Kolmogorov-Smirnov. As Redes Neurais 1 e 2 apresentaram maior precisão nas estimativas de probabilidade nas primeiras três classes diamétricas, quando comparadas às estimativas produzidas por Weibull, obtendo menor erro total e mais de 95% de aderência à distribuição real. Esta técnica também pode ser aplicada na predição dos parâmetros da função Weibull, com aderência superior a 90%. De acordo com os resultados, as Redes Neurais Artificiais podem ser empregadas com sucesso na modelagem da distribuição diamétrica de florestas inequiduais.

PALAVRAS-CHAVE: Florestas inequiduais, Rede Neural Artificial, Weibull.

MODELING THE DIAMETER DISTRIBUTION OF TROPICAL FORESTS

ABSTRACT

This study aimed to apply the artificial neural network technique to model the diametric structure of tropical forests. We used data of 27 areas of native forests

situated in the Rio Grande watershed in Minas Gerais state, totaling 979 plots. Three Artificial Neural Networks were tested for diametric modeling, networks 1 and 2 for prediction of probabilities by diameter class and the network 3 for prediction of parameters b and c of the Weibull function. The diameter structure estimated by the networks was compared with the probability density function Weibull with three parameters fitted by the method of moments and with the actual distribution obtained from information collected in the field. The evaluation and comparison of the methods are given from residual analysis calculated by diameter class and the Kolmogorov-Smirnov adherence test. Neural Networks 1 and 2 had greater accuracy in estimates of probability in the first three diameter classes, compared to estimates produced by Weibull, obtaining smaller total error and over 95% adherence to the actual distribution. This technique can also be applied to the prediction of Weibull function parameters with adhesion higher than 90%. According to the results, the Artificial Neural Networks can be successfully employed in shaping the diameter distribution of uneven-aged forests.

KEYWORDS: Uneven-aged forests; Artificial Neural Network; Weibull

INTRODUÇÃO

Conhecer a distribuição diamétrica das árvores permite descrever a estrutura horizontal dos povoamentos florestais. Em plantios comerciais este conhecimento é empregado para o planejamento de diversas atividades, como a colheita e sortimento de produtos florestais, bem como na modelagem de crescimento e produção (BURKHART & TOME, 2012). Considerando as florestas nativas, a distribuição horizontal dos indivíduos auxilia na distinção de tipos fisionômicos e contribui na elaboração de tabelas de produção que consideram o crescimento e a dinâmica populacional (NASCIMENTO et al., 2012; LIMA & LEÃO, 2013). Quando avaliada ao nível de espécie, pode ser utilizada para fornecer informações sobre estratégias específicas de regeneração, taxas demográficas e tendências populacionais (WRIGHT et al., 2003; LIMA et al., 2015).

Usualmente, a modelagem da distribuição dos indivíduos por classe de diâmetro é realizada com o emprego de função densidade de probabilidade (RENNOLLS et al., 1985; MIGUEL et al., 2010). Dentre as funções disponíveis, destaca-se Weibull que possui características matemáticas desejáveis e adaptáveis a uma série de padrões fisionômicos e de povoamentos equiâneos (LEI, 2008; BINOTI et al., 2012a). A aplicabilidade é preferida nas ciências florestais devido à grande flexibilidade, precisão e correlação existente entre os coeficientes e os atributos populacionais da floresta (BAILEY & DELL, 1973; LEITE et al., 2010).

Em contrapartida, as desvantagens em utilizar Weibull estão associadas aos diferentes métodos de ajuste da função, bem como variações nos parâmetros, podendo ser utilizada uma função com 2 parâmetros, iniciando da origem, ou com 3 parâmetros com emprego do parâmetro de locação (ABBASI & RABELO, 2008; LEI, 2008). Normalmente, o ajuste da função é realizado por parcela e, quando empregada em uma grande base de dados, tal tarefa se torna trabalhosa, já que é aconselhável o teste de diferentes métodos e parâmetros de locação.

Rede Neural Artificial (RNA) é um método da área de Inteligência Artificial, conhecido pela grande capacidade em aproximar funções não lineares. Na área florestal, este método tem demonstrado desempenho superior quando comparado aos métodos tradicionais da estatística clássica (DIAMANTOPOULOU, 2005; RODRIGUES et al., 2010; BINOTI et al., 2014; BINOTI et al., 2015). A vantagem deste método em relação aos demais é que trabalha com dados não paramétricos,

com ruídos, incompletos e multicolineares. Além disso, permite a introdução de variáveis categóricas, bem como a predição de várias saídas em uma única rede treinada (DIAMANTOPOULOU et al., 2015). As RNA's vêm sendo empregadas com sucesso na modelagem da distribuição diamétrica via predição dos parâmetros da função Weibull (DIAMANTOPOULOU et al., 2015), simulação de desbastes (BINOTI et al., 2012b) e predição da frequência relativa por classe de diâmetro (HUANG et al., 2009; GUO et al., 2011).

Objetivando verificar o desempenho da utilização das RNA's na modelagem da distribuição diamétrica, o atual trabalho aplicou a técnica em 979 parcelas de fragmentos nativos localizados na bacia do Rio Grande, Minas Gerais. A técnica foi empregada na predição das probabilidades por classe de diâmetro bem como na predição dos parâmetros da função Weibull. Para avaliação destas aplicações, a estrutura diamétrica estimada pelas redes foi comparada com a função densidade de probabilidade Weibull com 3 parâmetros e com a distribuição real obtida em campo.

MATERIAL E MÉTODOS

Área de estudo

Os dados modelados são provenientes do inventário florestal realizado na bacia do Rio Grande no território de Minas Gerais (Figura 1). De acordo com a classificação do índice de umidade de Thornthwaite, a área compreende os climas Úmidos B2, B3 e B4 e Superúmido. A bacia encontra-se inserida em uma faixa de transição entre os biomas Mata Atlântica e Cerrado, com altitude variando entre 300 e 2.600m. A vegetação é bem representativa dos dois ambientes, variando entre espécies gramíneo-lenhosas do Cerrado e espécies lenhosas de grande porte das Florestas Estacionais e Florestas Ombrófilas. O tipo de solo predominante na Bacia do Rio Grande é latossolo, com manchas expressivas de neossolo litólico, argissolo e cambissolo (CARVALHO et al., 2008).

FIGURA 1. Distribuição espacial dos fragmentos florestais utilizados na modelagem da estrutura diamétrica na bacia do Rio Grande.

Foram inventariados 27 fragmentos, totalizando 979 parcelas de 250m², sendo mensurados todos os indivíduos com circunferência a 1,30m do solo acima de 15,7cm. Cada parcela representa uma amostra dos dados, na qual foram calculados o diâmetro médio (Dmedio), variância (Dvar), desvio (Ddesv), diâmetro mínimo e máximo (Dmin e Dmax), diâmetro nos percentis 10%, 20%, 80% e 90% (P10%, P20%, P80% e P90%) e o diâmetro quadrático (Dg).

Os indivíduos de cada parcela foram agrupados em classes diamétricas com amplitude de 5cm, sendo a menor classe 5-10cm e a maior representando diâmetros maiores que 90cm, totalizando 18 classes. Calculou-se a probabilidade de ocorrência por classe de diâmetro através da razão entre a frequência da classe e o número total de indivíduos da parcela. Esses valores representam a distribuição de probabilidade real por classe de diâmetro.

A base total de dados (979 parcelas) foi dividida aleatoriamente em conjunto de treinamento e validação. O primeiro representando 70% dos dados, totalizando 588 parcelas; e o segundo 30% dos dados, com um total de 391 parcelas. O conjunto de treinamento foi utilizado para o ajuste dos pesos das Redes Neurais, e o conjunto de validação aplicado na avaliação das redes já treinadas. As mesmas parcelas utilizadas para avaliar as Redes Neurais (391) foram utilizadas no ajuste da distribuição Weibull.

Função de distribuição de probabilidade - Weibull

A função de distribuição de probabilidade Weibull com 3 parâmetros foi ajustada, ao qual o parâmetro de locação (a) foi considerado 5cm (diâmetro mínimo para medição e inclusão da árvore na parcela). No ajuste foi empregado o método dos momentos, no qual se estipula que os parâmetros de escala e forma da distribuição de Weibull são relacionados, respectivamente, aos momentos amostrais de primeira e segunda ordem, centrados na origem (MERGANIĆ & STERBA, 2006). No caso de distribuições diamétricas, o primeiro momento amostral corresponde ao diâmetro médio do povoamento e o segundo ao diâmetro quadrático (LEI, 2008).

No método de ajuste foram utilizados os dados de diâmetro médio e desvio de cada parcela. Na estimativa dos parâmetros de forma (b) e escala (c) empregou-se um método iterativo, a fim de diminuir a diferença entre o coeficiente de variação (CV) real e o estimado através dos momentos amostrais. Os parâmetros de forma e escala, bem como a função de probabilidade, foram estimados através das equações (1), (2) e (3), respectivamente.

$$b = \frac{\overline{D - a}}{\Gamma(1 + \frac{1}{c})}$$

(1)

$$CV = \frac{Sd}{\overline{D}} = \frac{\left[\Gamma(1 + (\frac{2}{c})) - \Gamma^2(1 + (\frac{1}{c})) \right]^{\frac{1}{2}}}{\Gamma(1 + (\frac{1}{c}))} \quad (2)$$

$$F(x) = 1 - \left\{ \exp \left[- \left(\frac{x - a}{b} \right)^c \right] \right\} \quad (3)$$

Definição e treinamento das Redes Neurais Artificiais

A técnica de Rede Neural Artificial (RNA) foi aplicada para a estimativa da probabilidade por classe de diâmetro e para a predição dos parâmetros de forma e escala da função Weibull (b e c). Dois conjuntos de variáveis independentes foram utilizados para estimar a probabilidade em cada classe diamétrica. O primeiro (RNA 1), contendo as variáveis de entrada D_{medio} e D_{desv} , as mesmas utilizadas no ajuste pelo método momentos da função Weibull. O segundo (RNA 2) contendo todas as 10 variáveis derivadas dos diâmetros da parcela descritas anteriormente. A RNA 3, para predição dos parâmetros, recebeu como entradas D_{medio} e D_{desv} e como saída esperada os parâmetros b e c proveniente do ajuste pelo método dos momentos ao conjunto de treinamento.

As Redes Neurais utilizadas foram do tipo Perceptron de múltiplas camadas. O treinamento das redes ocorreu por meio do algoritmo backpropagation, que ajusta os pesos de todas as camadas da rede a partir da retropropagação do erro, obtido na camada de saída (RUMELHART et al., 1986). A atualização dos pesos foi realizada em função do erro, taxa de aprendizagem e termo Momentum (regra Delta). A função de ativação empregada em todos os neurônios foi a sigmoideal. O conjunto de entradas foi normalizado pela razão de valor máximo, a fim de garantir mesmo intervalo de variação dos dados.

A arquitetura e os parâmetros das redes foram fixados em: 2 camadas ocultas, nas quais a primeira é constituída de 18 neurônios e a segunda por 10 neurônios; taxa de aprendizado 0,07 e Momentum 0,9. O critério de parada da rede foi definido em 1000 iterações (épocas de treinamento). As redes RNA 1 e RNA 2 possuem 18 saídas enquanto a RNA 3 apenas 2, referentes às probabilidades por classe diamétrica e aos parâmetros da função Weibull b e c . A arquitetura das redes é descrita no Quadro 1. O treinamento e aplicação das redes ao conjunto de validação foram realizados com 10 repetições, onde no início de cada treinamento eram utilizados pesos iniciais aleatórios nas conexões dos neurônios da rede.

TABELA 1. Arquitetura das Redes Neurais Artificiais.

Rede Neural Artificial	Nº de entradas	Nº de neurônios		Nº de saídas	Valores preditos
		1ª camada	2ª camada		
RNA1	2	18	10	18	Probabilidade por classe diamétrica
RNA2	10	18	10	18	Probabilidade por classe diamétrica
RNA3	2	18	10	2	Parâmetros da função Weibull

Avaliação dos métodos

Os resultados gerados pelos métodos foram avaliados em relação ao desvio da distribuição real. As métricas de cálculo do erro foram calculadas por classe de diâmetro e apenas para o conjunto de validação. Os valores apresentados para as Redes Neurais foram valores médios provenientes das 10 repetições. Calculou-se erro médio absoluto (EMA) (4), o erro percentual médio absoluto (EPMA) (5) e o erro total (ET) (6), sendo: n = Número total de amostras (parcelas); y_i = Probabilidade real da amostra i ; e $\hat{y}_i$ = Probabilidade estimada da amostra i .

$$EMA = \frac{1}{n} \sum_{i=1}^n \left| \left(y_i - \hat{y}_i \right) \right| \quad (4)$$

$$EPMA = \frac{1}{n} \sum_{i=1}^n \left| \frac{\left(y_i - \bar{y}_i \right)}{y_i} \right| * 100 \quad (5)$$

$$ET = \sum_{i=1}^n \left| \left(y_i - \bar{y}_i \right) \right| \quad (6)$$

Ao final foi aplicado o teste de aderência não paramétrico Kolmogorov-Smirnov (KS) a 1% de significância. Esse teste é baseado no módulo da maior diferença entre a frequência acumulada estimada e a frequência acumulada observada. Além da avaliação dos erros nas estimativas de probabilidade, foi calculado o número de indivíduos e área basal por hectare e por classe diamétrica e comparado com os valores reais obtidos em campo. Para o cálculo da área basal utilizou-se o valor central de cada classe diamétrica de acordo com a equação (7), sendo V_c o valor central da classe de diâmetro e n o número de indivíduos na respectiva classe.

$$G = \frac{\pi * V_c^2}{40000} * n \quad (7)$$

RESULTADOS E DISCUSSÃO

A distribuição média da probabilidade observada por classe de diâmetro apresentou forma exponencial negativa (J invertido), sendo as classes de menores diâmetros com maior probabilidade de ocorrência dos indivíduos, típica de florestas inequidâneas (NEELO et al., 2015; JIMENEZ et al., 2016). Conforme esperado, as classes diamétricas inferiores apresentaram maior amplitude de valores de probabilidade em relação às classes superiores, no entanto, quando é feita a razão pela média da classe, nota-se maior variação nestas últimas (Figura 2).

FIGURA 2. Distribuição das probabilidades reais observadas nas classes diamétricas.

A função Weibull com 3 parâmetros atingiu uma taxa de 98,2% de aderência para o conjunto de validação (391 parcelas). A não aderência de 7 parcelas esteve relacionada com as 6 primeiras classes de diâmetro. Em geral, os maiores desvios

foram associados às classes com maiores probabilidades (menores diâmetros), afetando principalmente as 3 primeiras classes, entre 7,5 e 17,5 cm. Para as classes 12,5 e 17,5 cm a estimativa desviou mais de 85% em relação ao valor real da classe, conforme disposto na Tabela 1.

A Rede Neural que utilizou apenas a média e desvio dos diâmetros como entradas (RNA 1), apresentou aderência em 97,4% das parcelas segundo o teste KS a 1%. Em média, apenas 10 parcelas não apresentaram uma distribuição estimada pela rede condizente com a real. A classe responsável pela não aderência da distribuição ajustada é a que possui maior probabilidade de ocorrência, com diâmetros entre 5 e 10cm. Apesar dos resultados do teste KS, a RNA 1 demonstrou maior precisão que a função Weibull nas classes diamétricas inferiores. Nas classes 12,5 e 17,5, onde Weibull apresentou um erro percentual (EPMA) superior a 85%, a rede apontou um erro inferior a 50% (Tabela 2). No entanto, de acordo com o erro total por classe diamétrica, a partir da classe de diâmetro médio de 32,5cm o desempenho deste método foi superado pela função de distribuição de probabilidade.

A Rede Neural com 11 entradas (RNA 2) aderiu à distribuição real em 96,9% das parcelas a 1% de significância pelo teste KS. O desempenho desta rede foi bastante semelhante ao da RNA 1, sendo que esta última apresentou ligeira superioridade na precisão das estimativas para as primeiras duas classes, enquanto que a RNA 2 apresentou menores desvios nas classes restantes.

TABELA 2. Métricas de avaliação para os métodos Weibull, RNA 1* e RNA 2*.
*Média proveniente das 10 repetições

Valor central das classes (cm)	Método											
	Weibull			RNA 1			RNA 2			RNA 3		
	EMA	EPMA	ET	EMA	EPMA	ET	EMA	EPMA	ET	EMA	EPMA	ET
7,5	0,1468	28,6481	57,3819	0,0783	16,0646	30,6115	0,0802	16,47	31,3622	0,1392	28,3988	56,9356
12,5	0,1603	97,8559	62,6615	0,0642	38,467	25,1088	0,0667	40,3667	26,0759	0,1398	97,3742	61,9357
17,5	0,0719	87,8518	28,106	0,0497	50,6248	19,4242	0,05	50,3314	19,5614	0,0673	87,6095	27,9888
22,5	0,04	50,3787	15,6367	0,0396	42,3592	15,4735	0,0393	42,5978	15,362	0,0396	50,0161	15,497
27,5	0,0294	41,0228	11,5106	0,029	25,9768	11,3524	0,0292	27,3187	11,3959	0,0294	40,8676	11,5145
32,5	0,017	28,9051	6,6362	0,0218	19,8522	8,5394	0,0212	20,892	8,2867	0,018	28,8948	6,6465
37,5	0,0123	24,0032	4,8201	0,0159	16,809	6,2182	0,0154	16,8426	6,0311	0,013	23,8489	4,8265
42,5	0,0073	14,5141	2,8534	0,0112	11,0749	4,3941	0,0106	12,2004	4,1323	0,0081	14,542	2,849
47,5	0,0044	10,0009	1,721	0,0077	9,0056	2,9933	0,0071	9,1059	2,7886	0,005	10,2321	1,7262
52,5	0,0034	6,5825	1,3469	0,006	6,0936	2,3354	0,0059	5,9862	2,2863	0,0039	6,5785	1,3436
57,5	0,0024	5,2083	0,9452	0,004	4,9405	1,57	0,0038	4,9493	1,4996	0,0027	5,2043	0,9455
62,5	0,0013	2,4308	0,5052	0,0028	2,4126	1,091	0,0024	2,4476	0,9245	0,0016	2,6917	0,5297
67,5	0,0007	0,922	0,2793	0,0019	0,9764	0,7261	0,0014	1,0002	0,5432	0,0009	0,9119	0,2813
72,5	0,0004	0,5039	0,1429	0,0013	0,4898	0,5239	0,001	0,4959	0,3837	0,0005	0,5055	0,1472
77,5	0,0006	1,2602	0,2495	0,0017	1,2266	0,6587	0,0012	1,245	0,4727	0,0008	1,2637	0,2546
82,5	0,0003	0,2472	0,1046	0,0014	0,2507	0,5463	0,0009	0,2524	0,3557	0,0005	0,245	0,107
87,5	0,0002	0,2483	0,0798	0,0013	0,249	0,5112	0,0009	0,2519	0,3308	0,0004	0,2473	0,0828
92,5	0,0003	0,5808	0,1119	0,0017	1,4571	0,6628	0,0013	1,5012	0,5001	0,0006	0,8439	0,1486

As estatísticas referentes à predição dos parâmetros pela RNA 3 encontram-se na Tabela 3. Observa-se que o método apresentou maior dificuldade na

estimação do parâmetro de forma b . A distribuição estimada pelos parâmetros preditos obteve uma aderência de 91,05%. Em média 35 parcelas não aderiram a distribuição real. Como esperado, o desempenho foi similar ao da função Weibull ajustada pelo método dos momentos, com pequenas diferenças ao longo das classes diamétricas.

TABELA 3. Erros para a predição dos parâmetros b e c estimados pela RNA 3

Parâmetros	EMA	EPMA	ET
b	0,10329	1,29542	40,38795
c	0,00416	0,29125	1,62728

Através dos gráficos do erro total (Figura 3), constatou-se que magnitude dos erros segue a mesma variação da probabilidade observada, sendo decrescente à medida que o diâmetro aumenta. A maior discrepância entre a inexistência dos métodos é notada nas primeiras três classes diamétricas, na qual a função Weibull, bem como a RNA 3, demonstraram desempenho inferior. Nas classes de 7,5 e 12,5cm o erro destes métodos chega próximo ao dobro dos erros obtidos pelas RNA's 1 e 2.

FIGURA 3. Erro total (ET) e erro médio percentual (EPMA) dos métodos utilizados.

O erro médio percentual (EPMA), como pode ser notado na Figura 3, não apresentou o mesmo comportamento do erro total. É necessário considerar que, por ser relativo à probabilidade observada da classe, em muitas parcelas é realizada a divisão do erro absoluto por zero nas classes de maiores diâmetros. Estes valores não são contabilizados na média, fazendo com que o erro percentual médio seja inferior ao erro real. O baixo erro percentual obtido nas classes de diâmetro superiores está diretamente ligado à probabilidade baixa ou nula nestas classes. A diferença no comportamento da função Weibull e RNA 3 frente às Redes Neurais 1 e 2 a partir da classe 32,5 cm também pode ser explicada por essa razão, indicando que a maior concentração dos erros obtidos pelas redes esteja na superestimação em parcelas com probabilidade nula. Apesar da inconsistência na utilização do erro médio percentual, pode-se afirmar que a maior dificuldade em precisar os valores em ambos os métodos encontra-se na classe 12,5 e 17,5cm.

Ao realizar o somatório do erro absoluto para todas as classes diamétricas (18) e parcelas (391) por método de modelagem, obtêm-se um valor de 195,09 para Weibull e 132,74 e 132,29 para RNA 1 e RNA 2, respectivamente e 193,76 para a RNA 3. Resultado que demonstra, de maneira geral, maior compatibilidade das Redes Neurais nas estimativas das probabilidades por classe de diâmetro, bem como a utilização da técnica para predição dos parâmetros da função Weibull.

Apesar do notável desempenho das Redes Neurais em estimar a probabilidade por classe de diâmetro, esta técnica nem sempre atende ao princípio matemático de que o somatório das probabilidades de cada parcela deve ser igual a 1. De acordo com as 391 parcelas analisadas, o somatório das probabilidades estimadas pela rede neural em média foram 1,009 (RNA 1) e 1,005 (RNA 2), com uma variação de 1,09% e 0,74% respectivamente. Ao aplicar as probabilidades estimadas ao número de indivíduos total de cada parcela, verificou-se que as redes RNA 1 e RNA 2 superestimaram indivíduos em relação ao total real, sendo 221 e 48 indivíduos respectivamente, no total de 391 parcelas e 13.293 indivíduos. Em média, de acordo com os dados levantados em campo existem 1.360 indivíduos por hectare, sendo que as RNA's 1 e 2 estimaram 1.383 indivíduos/ha e 1.355 indivíduos/ha, respectivamente. Já a função Weibull e a RNA 3 forneceram o número de indivíduos total exato. Porém na classe de valor central 7,5cm a função Weibull ajustada pelo método dos momentos subestimou 173 indivíduos/ha e na classe de 12,5cm superestimou 205 indivíduos/ha, diferenças com grandes magnitudes presentes também nas estimativas da RNA 3 e não encontradas nas Redes Neurais 1 e 2.

Na Figura 4 pode-se verificar a tendência das Redes Neurais em superestimar o número de indivíduos de maiores diâmetros, demonstrando a maior dificuldade em identificar casos onde estes ocorrem. Diante desta limitação é indicado que a técnica de Redes Neurais seja adotada mediante a análise do comportamento de outras variáveis por classe de diâmetro, como volume, área basal, etc.

FIGURA 4. Número de indivíduos/ha e área basal/ha real e estimados pelos métodos Weibull, RNA 1, RNA 2 e RNA 3, sendo Grupo 1 constituído pelas classes de menores diâmetros e o Grupo 2 pelas classes de maiores diâmetros.

A tendência de superestimação das Redes Neurais é confirmada pela área basal, na qual a RNA1 superestimou em relação ao total obtido nas 391 parcelas 88,85m² e a RNA2 19,74m². Em média, de acordo com os dados obtidos em campo a área basal é de 23,48m²/ha sendo que as RNA's 1 e 2 estimaram 32,37m²/ha e 25,5m²/ha, respectivamente (Figura 4). Estes resultados evidenciam o melhor ajuste da RNA 2 nas classes de maiores diâmetros, decorrendo em uma melhor aproximação do número de indivíduos e área basal. Já a função Weibull obteve subestimativa da área basal em 40,92m² e a RNA 3 de 43,18m² em relação às 391 parcelas, estimando em média 19,29m²/ha e 19,06m²/ha respectivamente.

Pode-se considerar que o emprego da função Weibull com três parâmetros ajustada pelo método dos momentos é viável para modelar a estrutura diamétrica das florestas avaliadas, diante da alta aderência entre as parcelas (98,2%). Diversos trabalhos também utilizaram com sucesso a função Weibull, com dois e três parâmetros, para caracterização da distribuição diamétrica. RIBEIRO et al. (2014) obtiveram aderência em 75% dos tratamentos utilizando a função Weibull com 3 parâmetros para plantios de *Eremanthus erythropappus* com diferentes idades, espaçamentos e tratos silviculturais. ABREU et al. (2011) testaram 4 funções de densidade de probabilidade para modelar a estrutura diamétrica de uma floresta de várzea na Amazônia e identificaram, através de estatística KS e coeficiente de determinação, que a função Weibull com 3 parâmetros foi a que melhor se ajustou a distribuição observada.

Apesar, de maneira geral, as RNA's 1 e 2 terem obtido menores erros nas estimativas de probabilidade, estas demonstraram maior dificuldade em aprender os

valores das classes de maiores diâmetros, que representam baixas probabilidades, bem como modelar parcelas *outliers*. Em contrapartida, foram mais assertivas nas classes inferiores. A RNA 1 apresenta como vantagem a estimativa de todas as probabilidades por classe de diâmetro em uma única rede, com as mesmas entradas utilizadas no ajuste por parcela da função Weibull pelo método dos momentos. Contudo ela superestimou o número de indivíduos e a área basal, esta última em maior magnitude que a subestimação de Weibull. A RNA 2 foi o método que mais se aproximou nas estimativas de probabilidade e área basal. No entanto, a utilização em modelos de crescimento e produção torna-se trabalhosa devido à dificuldade para a obtenção de todos os parâmetros de entrada em um tempo futuro.

GUO et al. (2011) estimaram a frequência relativa com a técnica de Redes Neurais utilizando o diâmetro médio, coeficiente de variação e o diâmetro relativo da classe como variáveis de entrada. A arquitetura utilizada foi 3 entradas, 1 camada oculta com 11 neurônios e 1 saída, relativa à probabilidade na classe indicada. Obtiveram uma acurácia de 98,18% das estimativas. CAI et al. (2012) também utilizaram redes do tipo múltiplas camadas treinadas com algoritmo *backpropagation* para modelar a distribuição de três espécies arbóreas latifoliadas (*Populus davidiana*, *Betula platyphylla* e *Betula costata*). Estimaram o número de indivíduos, frequência e frequência cumulativa, obtendo em média uma precisão de ajuste de 0,99.

As redes também demonstraram potencial para serem empregadas na predição dos parâmetros da função Weibull. De 391 parcelas, apenas 35 distribuições estimadas, em média, não aderiram a distribuição real, conferindo uma aderência de 91% das parcelas modeladas. DIAMANTOPOULOU et al. (2015) utilizaram a técnica de Redes Neurais Artificiais e mínimos quadrados para predição dos parâmetros de forma e escala da função Weibull com 2 parâmetros, ajustada pelo método dos momentos. Em comparação com o método dos mínimos quadrados ordinários, as redes conseguiram estimar os parâmetros sem viés e com muito mais precisão que o método de regressão. LEDUC et al. (2001) verificaram que as redes utilizando o algoritmo de aprendizado *backpropagation* forneceram melhores predições do que a função Weibull estimada por regressões ou recuperação de parâmetros.

A grande vantagem em se modelar a distribuição diamétrica utilizando Redes Neurais artificiais é que uma vez treinada, a técnica pode ser aplicada a outras florestas com características fisionômicas similares sem a necessidade de um novo ajuste. O emprego deste método pode auxiliar na caracterização do estágio de regeneração da área (RIBEIRO & FERRAZ-FILHO, 2013), na indicação do rendimento da colheita (MALINOVSKI et al., 2006; MARTINS et al., 2009) e no manejo sustentável seguindo os princípios de florestas balanceadas (KERR, 2013). A praticidade em termos de implementação e tempo computacional fazem com que a Rede Neural Artificial, mesmo com dificuldades em prever indivíduos nas maiores classes, seja uma ótima opção para quem deseja modelar a estrutura diamétrica de florestas inequiduais.

CONCLUSÕES

Diante da alta aderência dos métodos (Weibull, RNA 1 e RNA 2), superior a 95%, pode-se afirmar que ambos podem ser utilizados para modelar a distribuição diamétrica de florestas tropicais. O desempenho da técnica de Rede Neural Artificial é mais acurado quando são fornecidas mais variáveis de entrada relacionada ao

posicionamento dos diâmetros na parcela. O método também pode ser empregado com sucesso na predição dos parâmetros de forma e locação da função Weibull.

REFERÊNCIAS

ABBASI, B.; RABELO, L.; HOSSEINKOUCHACK, M. Estimating parameters of the three-parameter Weibull distribution using a neural network. **European Journal of Industrial Engineering**, v.2, n.2, p. 428-445, 2008. Disponível em: < <http://dx.doi.org/10.1504/EJIE.2008.018438> >. doi: 10.1504/EJIE.2008.018438.

ABREU, J. C.; SILVA, J. A. A.; APARICO, P. S.; MARANGON, G. P.; SANTOS, M. S.; BARRETO, T. N. A. Modelagem da estrutura diamétrica de uma floresta de várzea no município de Macapá-AP. In: **Simpósio Latino-americano sobre Manejo Florestal**, 5., 2011, Santa Maria. Proceedings. Simpósio latino-americano sobre manejo florestal Tema: Sustentabilidade Florestal, v. 5, p.336-343, 2011.

BAILEY, R. L.; DELL, J. R. Quantifying diameter distributions with the Weibull function. **Forest Science**, Bethesda, v. 19, n. 2, p. 97-104, 1973.

BINOTI, D. H. B.; BINOTI, M. L. M. S.; LEITE, H. G.; MELIDO, R. C. N.; SANTOS, F. L. Descrição da distribuição diamétrica de sistemas agrossilvipastoris utilizando as funções Weibull e Hiperbólica. **Árvore**, v.36, n.2, p.349-356, 2012a. Disponível em: < <http://dx.doi.org/10.1590/S0100-67622012000200016> >. doi: 10.1590/S0100-67622012000200016.

BINOTI, D. H. B.; BINOTI, M. L. M. S.; LEITE, H. G.; SILVA, A.; SANTOS, A. C. A. Modelagem da distribuição diamétrica em povoamentos de eucalipto submetidos a desbaste utilizando autômatos celulares. **Árvore**, v.36, n.5, p.931-939, 2012b. Disponível em: < <http://dx.doi.org/10.1590/S0100-67622012000500015> >. doi: 10.1590/S0100-67622012000500015

BINOTI, M. L. M. S.; BINOTI, D. H. B.; LEITE, H. G.; GARCIA, S. L. R.; FERREIRA, M. Z.; RODE, R. SILVA, A. A. L. Redes neurais artificiais para estimação do volume de árvores. **Árvore**, v.38, n.2, p.283-288, 2014. Disponível em: < <http://dx.doi.org/10.1590/S0100-67622014000200008> >. doi: 10.1590/S0100-67622014000200008

BINOTI, M.L.M.S.; LEITE, H.G.; BINOTI, D.H.B.; GLERIANI, J.M. Prognose em nível de povoamento de clones de eucalipto empregando redes neurais artificiais. **Cerne**, v.21,n.1,p.97-105,2015. Disponível em: <<http://dx.doi.org/10.1590/01047760201521011153>>. doi: 10.1590/01047760201521011153

BURKHART, H. E.; TOMÉ, M. **Modeling forests trees and stands**. Springer, New York, 459 p., 2012.

CAI, S.; KANG, X.; ZHANG, L. Simulation of Trunk Diameter Distribution for Three Broadleaved Trees Based on Artificial Neural Networks. **International Journal of Advancements in Computing Technology**, v. 4, n.15, p.520-527, 2012. Disponível em: <<http://dx.doi.org/10.4156/ijact.vol4.issue15.61>>. doi: 10.4156/ijact.vol4.issue15.61

CARVALHO, L. G.; MELLO, C. R.; ALVES, M. C.; CURI, N.; MARQUES, A. F. S. M.; CARVALHO, L. M. T.; MARQUES, J. J. G. Clima. In: SCOLFORO, J. R. S.; CARVALHO, L. M. T.; OLIVEIRA, A. D. (Ed.). **Zonamento ecológico-econômico do estado de Minas Gerais: Componentes geofísico e biótico**. Lavras - Editora UFLA, 161 p., 2008.

DIAMANTOPOULOU, M.J.; OZÇELIK, R.; CRECENTE-CAMPO, F.; ELER, U. Estimation of Weibull function parameters for modelling tree diameter distribution using least squares and artificial neural networks methods. **Biosystems Engineering**, v. 133, p. 33-45, may, 2015. Disponível em: < <http://dx.doi.org/10.1016/j.biosystemseng.2015.02.013>>. doi: 10.1016/j.biosystemseng.2015.02.013

GUO, F.; GAO, G.; HUANG, J.; WANG, L. Diameter Distribution Prediction of Populus Shelterbelts Based on Artificial Neural Network. In: **Seventh International Conference on Natural Computation**, p.762-765, 2011.

HUANG, J.; ZHAO, J.; GAO, G.; MENG, X.; GUAN, Y. Prediction of Stand Diameter Distribution with Artificial Neural Network. In: **Fifth International Conference on Natural Computation**, p. 79-82, 2009.

JIMÉNEZ, J. U.; FÁBREGA, J.; MORA, D.; TEJEDOR, N.; SÁNCHEZ, M. Composition, Diversity, and Tree Structure of a Tropical Moist Forest in Gamboa, Colon, Panama. **Air, Soil and Water Research**, v.9, p.29–34, 2016. Disponível em: <<http://dx.doi.org/10.4137/ASWR.S33960>>. doi: 10.4137/ASWR.S33960

KERR, G. The management of silver fir forests: de Liocourt (1898) revisited. **Forestry**, v.87, n.1, p.29-38, 2013. Disponível em: < <http://dx.doi.org/10.1093/forestry/cpt036> >. doi: 10.1093/forestry/cpt036

LEDUC, D. J.; MATNEY, T. G.; BELLI, K. L.; BALDWIN, V. C. Predicting diameter distributions of longleaf pine plantations: a comparison between artificial neural networks and other accepted methodologies. **USDA Forest Service**, Southern Research Station, Research Paper. SRS-25, 18 p., 2001.

LEI, Y. Evaluation of three methods for estimating the Weibull distribution parameters of Chinese pine (*Pinus tabulaeformis*). **Journal of Forest Science**, v.54, n.12, p.566-571, 2008.

LEITE, H. G.; BINOTI, D. H. B.; GUIMARÃES, D. P.; SILVA, M. L. M.; GARCIA, S. L. R. Avaliação do ajuste das funções Weibull e hiperbólica a dados de povoamentos de eucalipto submetidos a desbaste. **Árvore**, v.34, n.2, p.305-311, 2010. Disponível em: < <http://dx.doi.org/10.1590/S0100-67622010000200013> >. doi: 10.1590/S0100-67622010000200013

LIMA, J. P. C.; LEÃO, J. R. A. Dinâmica de crescimento e distribuição diamétrica de fragmentos de florestas nativa e plantada na Amazônia Sul Ocidental. **Floresta e Ambiente**, v. 20, n. 1, p. 70-79, 2013. Disponível em: < <http://dx.doi.org/10.4322/floram.2012.065>>. doi: 10.4322/floram.2012.065

LIMA, R.; BATISTA, J.L.F.; PRADO, P.I. Modeling Tree Diameter Distributions in Natural Forests: An Evaluation of 10 Statistical Models. **Forest Science**, v.60, p. 1-8, 2015. Disponível em: < <http://dx.doi.org/10.5849/forsci.14-070>>. doi: 10.5849/forsci.14-070.

MALINOVSKI, R.A.; MALINOVSKI, R.A.; MALINOVSKI, J.R.; YAMAJI, F.M. análise das variáveis de influência na produtividade Das máquinas de colheita de madeira em função das Características físicas do terreno, do povoamento e Do planejamento operacional florestal. **Floresta**, , v. 36, n. 2, p. 169-182, 2006. Disponível em: <<http://dx.doi.org/10.5380/rf.v36i2.6459>>. doi: 10.5380/rf.v36i2.6459

MARTINS, R.J.; SEIXAS,F.; STAPE,J.L. Avaliação técnica e econômica de um harvester trabalhando em diferentes condições de espaçamento e arranjo de plantio em povoamento de eucalipto. **Scientia Forestalis**, v.37, n.83, p. 253-263, 2009.

MERGANIČ, J.; STERBA,H. Characterisation of diameter distribution using the Weibull function: method of moments. **European Journal of Forest Research**, v.125,n.4,p.427-439,2006. Disponível em: < <http://dx.doi.org/10.1007/s10342-006-0138-2> >. doi: 10.1007/s10342-006-0138-2

MIGUEL, E. P.; MACHADO, S. A.; FIGUEIREDO FILHO, A.; ARCE, J. E. Using the Weibull function prognosis of yield by diameter class in Eucalyptus urophylla stands. **Cerne**, v. 16, n. 1, p. 94-104, 2010.

NASCIMENTO, R. G. M.; MACHADO, S. A.; FIGUEIREDO-FILHO, A.; HIGUCHI, N. Modelo de projeção por classe diamétrica para florestas nativas: enfoque na função probabilística de Weibull. **Pesquisa Florestal Brasileira**, v. 32, n. 70, p. 209-219, abr./jun. 2012. Disponível em: <<http://dx.doi.org/10.4336/2012.pfb.32.70.93>>. doi: 10.4336/2012.pfb.32.70.93.

NEELO, J.; TEKETAY, D.; KASHE, K.; MASAMBA, W. Stand Structure, Diversity and Regeneration Status of Woody Species in Open and Exclosed Dry Woodland Sites around Molapo Farming Areas of the Okavango Delta, Northeastern Botswana. **Open Journal of Forestry**, v. 5, p.313-328, 2015. Disponível em: <<http://dx.doi.org/10.4236/ojf.2015.54027>>. doi: 10.4236/ojf.2015.54027.

RENNOLS, K.; GEARY, D. N.; ROLLINSON, T. J. D. Characterizing Diameter Distributions by the use of the Weibull Distribution. **Forestry**, v.58, n.1, p. 57-66, 1985.

RIBEIRO, A.; FERRAZ FILHO, A. C. Estudo da metodologia proposta para classificação dos diferentes estágios de regeneração no Cerrado. **Pesquisa Florestal Brasileira**, v.33, n.73, p.91-98, 2013. Disponível em: <<http://dx.doi.org/10.4336/2013.pfb.33.73.390>>. doi: 10.4336/2013.pfb.33.73.390

RIBEIRO, A.; FERRAZ FILHO, A. C.; SCOLFORO, J. R. S.; PÉLLICO NETTO, S.; MACHADO, S. A. Estrutura da distribuição diamétrica em plantio experimental de candeia (*Eremanthus erythropappus* (DC.) Macleish. **Ciência Florestal**, v. 24, n. 4,

p. 1055-1065, 2014. Disponível em: <<http://dx.doi.org/10.5902/1980509816618>>. doi: 10.5902/1980509816618.

RODRIGUES, E. F.; OLIVEIRA, T. F.; MADRUGA, M. R.; SILVEIRA, A. M. Um método para estimar o volume comercial do *Schizolobium amazonicum* (Huber) Ducke utilizando redes neurais artificiais. **Rev. Bras. Biom.**, São Paulo, v.28, n.1, p.16-23, 2010.

RUMELHART, D.; HINTONT, G; WILLIAMS, R. Learning representations by backpropagating erros. **Nature**, v.323, p.533–536, 1986.

WRIGHT, S.J.; MULLER-LANDAU, H.C.; CONDIT R., HUBBELL, S.P. Gap-dependent recruitment, realized vital rates, and size distributions of tropical trees. **Ecology** v.84, p.3174 –3185, 2003. Disponível em: <<http://dx.doi.org/10.1890/02-0038>>. doi: 10.1890/02-0038.