

# ÁREA FOLIAR ESPECÍFICA E CLOROFILA EM EUCALIPTO ESTIMADAS POR REDES NEURAIS ARTIFICIAIS<sup>1</sup>

## *Estimates of Specific Leaf Area and Chlorophyll Content in Eucalyptus by Artificial Neural Networks*

Bruno Oliveira Lafetá<sup>2</sup>, Reynaldo Campos Santana<sup>3</sup>, Gilciano Saraiva Nogueira<sup>4</sup>; Tamires Mousslech Andrade Penido<sup>5</sup> e Laércio Couto<sup>6</sup>

**Resumo:** O objetivo do presente trabalho foi avaliar a eficiência da estimação da área foliar específica e do conteúdo de clorofila em eucalipto, sob diferentes espaçamentos, empregando redes neurais artificiais (RNA). O experimento foi instalado em blocos ao acaso, com três blocos, no esquema de parcelas subdivididas 5 x 3, tendo na parcela sido estudado o efeito de diferentes espaçamentos de plantio (T1 - 3,0 x 0,5 m, T2 - 3,0 x 1,0 m, T3 - 3,0 x 1,5 m, T4 - 3,0 x 2,0 m e T5 - 3,0 x 3,0 m) e na subparcela, os terços da copa (inferior, médio e superior). Uma árvore-amostra, com diâmetro médio quadrático, foi abatida para determinação do conteúdo de clorofila total (CT) e da área foliar específica (AFE) em cada unidade experimental. Foram utilizadas redes *feedforward*, treinadas por meio do algoritmo *backpropagation*. As redes MLPs foram as mais simples e apresentaram os menores desvios e tendenciosidades, evidenciando o realismo biológico. Conclui-se, assim, que a modelagem por RNA utilizando MLPs é a adequada para estimar a AFE e o CT.

**Palavras-chave:** espaçamento de plantio, MLP, RBF e inteligência artificial.

**Abstract:** *This study aimed to evaluate estimation efficiency for specific leaf area and chlorophyll content in Eucalyptus under different spacings by using artificial neural networks (ANNs). The experiment was established in a randomized three-block design, 5 x 3 split-plot design. The effect of the different plant spacing (T1 - 3.0 x 0.5 m; T2 - 3.0 x 1.0 m; T3 - 3.0 x 1.5 m; T4 - 3.0 x 2.0 m and T5 - 3.0 x 3.0 m) was studied in the plot, and the parts of the canopy (lower, middle and top) were studied in the split-plot. One sample tree, with quadratic mean diameter, was harvested for determination of chlorophyll content (CT) and specific leaf area (SLA) in each experimental unit. Feedforward networks trained by the backpropagation algorithm were used. MLP networks were the simplest and showed the smallest deviations and biases, which highlights the biological realism. It was concluded that ANN modeling using MLPs proved to be adequate for estimating SLA and CT.*

**Keywords:** planting spacing, MLP, RBF, artificial intelligence.

<sup>1</sup> Recebido para publicação em 19.11.2012 e aceito em 2.12.2012.

<sup>2</sup> Eng. Florestal, Universidade Federal dos Vales do Jequitinhonha e Mucuri – UFVJM/DEF, Rodovia MG 367, n. 5000, Alto do Jacuba, 39100-000 Diamantina-MG, Brasil, <brunoolafeta@yahoo.com.br>. <sup>3</sup> Prof. Adjunto, UFVJM/DEF, Diamantina-MG, Brasil, <silviculturavfjm@yahoo.com.br>, <nogueirags@yahoo.com.br>. <sup>4</sup>Aluna de Engenharia Florestal, UFVJM/DEF, Diamantina-MG, Brasil, <miresmp@hotmail.com>. <sup>5</sup>Adjunct Professor, Faculty of Forestry, University of Toronto, 33 Willcocks street, Toronto, Ontario, Canada M5S 3B3, <laercio.couto@utoronto.ca>.

## 1 INTRODUÇÃO

A produtividade florestal, definida como o potencial de um sítio produzir madeira, é influenciada por uma série de fatores, dentre os quais se destaca o espaçamento de plantio, que interfere na proporção de alocação de carbono nos diferentes componentes das árvores. Conhecer a alocação de carbono é muito importante para definir os usos potenciais da madeira, podendo ela variar com as condições edafoclimáticas e as práticas silviculturais adotadas. Segundo Leite et al. (1997), a produção de biomassa por área de todos os componentes da parte aérea e o índice de área foliar apresentaram relação linear decrescente com o aumento da área útil inicial, em densidade de plantio variando entre 500 e 5.000 plantas por hectare, aos 31 meses de idade.

A definição da área útil a ser adotada em plantios de eucalipto pode resultar em mudanças estruturais do dossel. Essas mudanças podem promover alterações na área foliar específica, nos ângulos foliares, no índice de área foliar, na cobertura arbórea e no teor de clorofila (LACLAU et al., 2010; MAIRE et al., 2011). A clorofila e a área foliar específica estão envolvidas em uma variedade de processos que influenciam a produtividade florestal, como a utilização da luz, interceptação de chuva, transpiração, fotossíntese e respiração (MAIRE et al., 2011), o que as torna importantes para compreensão do desenvolvimento de uma floresta e para caracterização de adaptações de plantas às condições ambientais. Elas também possuem grande significado prático, pois podem ser utilizadas como variáveis para parametrização de modelos de predição processuais. Entre esses modelos, a área foliar específica é a mais comumente empregada no 3-PG (LANDSBERG; WARING, 1997) e no Cabala (NOUVELLON et al., 2010).

As redes neurais artificiais (RNA) são modelos computacionais que simulam a estrutura e o funcionamento do cérebro humano (BINOTI, 2010). Constituídas por unidades

simples de processamento (ou neurônios artificiais), interligadas entre si com ponderações ajustáveis, as redes formam um sistema dinâmico para execução de uma dada tarefa (COELHO et al., 2007), gerando uma ou mais saídas (*outputs*) com um conjunto de dados de entrada (*inputs*). Podem apresentar desempenho superior aos modelos convencionais de regressão, como observado na modelagem de volume para *Eucalyptus* spp. e *Ectectona grandis* (GORGENS et al., 2009).

A arquitetura da rede (ou disposição das camadas) exerce influência no processamento dos dados de entradas, permitindo aproximações lineares ou não na camada intermediária. As arquiteturas mais comuns e utilizadas integram as redes de base radial (*Radial Basis Function* ou RBF) e as de múltiplas camadas (*Multilayer perceptron* ou MLP). As redes do tipo RBF, normalmente, apresentam algumas vantagens em relação a outros tipos de RNA, incluindo estruturas mais simples, algoritmos de aprendizado rápido e melhor capacidade de aproximação (BRAGA et al., 2007; COELHO et al., 2007). As MLPs, por sua vez, constroem aproximadores globais e são recomendadas para resolução de problemas mais complexos (BRAGA et al., 2007).

O emprego de técnicas estatísticas avançadas associadas a estudos ecofisiológicos pode ser uma alternativa viável no estabelecimento de critérios práticos de caracterização e classificação de sítios, pois permite obter informações sobre a dinâmica de crescimento dentro de povoamentos florestais, enriquecendo estudos sobre a sustentabilidade e produção de um ecossistema florestal. Portanto, o objetivo deste trabalho foi avaliar a eficiência de estimação da área foliar específica e do conteúdo de clorofila em eucalipto sob diferentes espaçamentos, empregando redes neurais artificiais.

## 2 MATERIAL E MÉTODOS

O estudo foi conduzido a 17°50' de latitude sul e 42°49' de longitude oeste em área da

Aperam Bioenergia, no município de Itamarandiba-MG. O clima predominante na região é do tipo Cwa, segundo a classificação de Köppen, com médias anuais de temperatura e precipitação pluviométrica de 20 °C e 1.160 mm, respectivamente.

O experimento foi instalado em dezembro de 2002, utilizando um híbrido de *Eucalyptus grandis* W. Hill ex Maiden x *Eucalyptus camaldulensis* Dehnh, sobre Latossolo Vermelho-Amarelo, em relevo plano a 1.097 m altitude. Adotou-se o delineamento em blocos ao acaso, com três blocos, no esquema de parcelas subdivididas 5 x 3, tendo sido estudado na parcela o efeito de espaçamentos de plantio (T1 - 3,0 x 0,5 m, T2 - 3,0 x 1,0 m, T3 - 3,0 x 1,5 m, T4 - 3,0 x 2,0 m e T5 - 3,0 x 3,0 m; 3 m foi a distância fixa entre linhas de plantio) e na subparcela, os terços da copa (inferior, médio e superior). Foram definidas seis linhas de plantio com 28 plantas por tratamento, totalizando 168 indivíduos, dos quais 48 foram mensurados, por ter sido adotada a bordadura dupla.

Aos 101 meses de idade foram mensurados o diâmetro a 1,30 m de altura do solo (DAP) e a altura total (Ht) de todas as árvores. Uma árvore-amostra, árvore com diâmetro médio quadrático, foi abatida para determinação do conteúdo de clorofila total (CT) e da área foliar específica (AFE) em cada unidade experimental, totalizando 15 indivíduos.

O CT foi mensurado com o medidor ClorofiLOG modelo CFL 1030 da Falker, que leva em consideração os teores de clorofila *a* e *b* (ICF – índice de clorofila Falker) em dez folhas coletadas em cada terço da copa das árvores-amostras, somando 30 unidades por copa.

Utilizando as mesmas folhas, calculou-se a AFE ( $\text{cm}^2 \text{g}^{-1}$ ) pela seguinte fórmula:  $AFE = AF.MS^{-1}$ , em que  $AF$  = área foliar ( $\text{cm}^2$ ) e  $MS$  = massa seca (g). Mensurou-se a AF com o medidor de área foliar CI-203 CID Inc. e a massa seca, em estufa de circulação forçada de ar a 65 °C, até peso constante.

O treinamento de uma rede neural artificial, também denominado aprendizagem, consiste no ajuste dos parâmetros da rede (pesos e *bias*) por meio de um algoritmo de aprendizagem. As variáveis utilizadas como entrada das RNA para estimação simultânea do CT e da AFE foram numéricas ( $DAP_{(\text{cm})}$ ,  $Ht_{(\text{m})}$  e espaçamento entre plantas ( $Esp_{(\text{m})}$ )) e categóricas (*Copa*: terço inferior – 1; médio – 2 e superior – 3; *Fisiologia*: AFE – 1 e CT – 2), utilizando as árvores-amostras.

Utilizaram-se redes anteroalimentadas (*feedforward*), treinadas por meio do algoritmo da retropropagação do erro (*backpropagation*), ou seja, durante o treinamento da rede foram realizados cálculos a partir da camada de entrada da rede para a de saída, e o erro foi propagado para camadas anteriores. Em todos os pré-processamentos foram feitas a normalização e a equalização dos dados, visando à maior sensibilidade da rede à variação desses dados, para captar melhor seu comportamento. Os dados foram divididos em grupos de calibração (80% das amostras) e validação (20%), utilizando o método randômico de amostragem.

Foram treinadas 200 RNA para estimar a AFE e o CT, sendo 100 Multilayer Perceptron (MLP) e 100 Radial Basis Function (RBF). Adotou-se o modelo heurístico *backward elimination*, conforme descrito por Cerqueira et al. (2001). Dessas RNA foram selecionadas duas de cada tipo, com base nos desvios dos valores estimados e observados. A definição da arquitetura das redes, ou seja, o número de camadas e o número de neurônios por camada, foi otimizada pela ferramenta Intelligent Problem Solver (IPS) do software Statistica 7.0 (STATSOFT, 2007).

A avaliação da acurácia e a precisão do treinamento das RNA foram realizadas por meio do  $erro_{\%}$ , do teste de  $RMSE_{\%}$ , do teste de  $Bias_{\%}$  e da análise gráfica. As estimativas foram comparadas por meio do teste *t* pareado, a 5% de probabilidade, com os valores observados conforme Gorgens et al. (2009). O erro foi assim definido:

$$\text{erro}_{\%} = \left( \frac{\hat{y} - y}{y} \right) 100 ,$$

enquanto a raiz do quadrado médio do erro ( $RMSE_{\%}$ ) e a tendenciosidade ( $Bias_{\%}$ ) foram determinadas segundo Mabvurira e Miina (2002)

$$RMSE_{\%} = 100 \left( \frac{\sqrt{\frac{\sum (y_i - \hat{y}_i)^2}{n-1}}}{\sum \hat{y}_i / n} \right)$$

e

$$Bias_{\%} = 100 \left( \frac{(\sum (y_i - \hat{y}_i)) / n}{\sum \hat{y}_i / n} \right)$$

em que  $y_i$  e  $\hat{y}_i$  são os valores observados e preditos, respectivamente.

Os pontos que extrapolaram a tendência geral de cada espaçamento não foram eliminados, a fim de verificar a capacidade das redes neurais artificiais em lidar com outliers ou ruídos. Para averiguar se os dados estimados atendem às pressuposições para realização da análise de variância, a normalidade foi testada conforme Shapiro Wilk e a homogeneidade das variâncias, por meio da análise gráfica. Todas as análises estatísticas foram realizadas com o auxílio do software Statistica 7.0 (STATSOFT, 2007).

### 3 RESULTADOS E DISCUSSÃO

As funções de ativação não lineares na camada intermediária, que gera campos receptivos locais, foram verificadas somente nas redes RBFs (Quadro 1). De acordo com Braga et al. (2007), a segunda camada da RBF normalmente aplica uma transformação gaussianas nos *inputs* (HAYKIN, 2001). Embora as MLPs tenham apresentado funções lineares puras nas camadas intermediárias, ambas as arquiteturas podem resolver problemas onde as classes não são linearmente

separáveis, haja vista que as RBFs apresentam neurônios ocultos não lineares e as MLPs, múltiplas camadas. As aproximações não lineares pelas camadas intermediárias são importantes, pois permitem que a composição das funções nas camadas sucessivas tenha capacidade de resolver os problemas de maior ordem no espaço de entrada (HAYKIN, 2001). O maior número de neurônios na camada intermediária das RBFs resultou em maior complexidade nas suas redes (Quadro 1). Deve-se ressaltar que todas as RNA apresentam somente uma camada de entrada, cujo papel é receber as variáveis de entrada e as direcionar à próxima camada, não processando quaisquer informações (BINOTI, 2010).

Ainda que as RNA tenham apresentado bom treino e a pior validação (Quadro 2), este desempenho não foi necessariamente gerado pela memorização excessiva dos dados de treinamento. Segundo Palma e Portugal (2009), o sobre-treinamento pode ocorrer quando se tem muitos neurônios na camada intermediária, fato não observado nessas redes. Além disso, aplicou-se a normalização dos dados como heurística, prática comum no processamento estatístico das RNA, que possibilita a aproximação da solução ideal (STATSOFT, 2007; SOARES et al., 2011). Todas as redes para estimação da AFE e do CT apresentaram ausência de significância estatística pelo teste *t* pareado, a 5,0% de probabilidade, exceto no treinamento das RBFs (Quadro 2).

De modo geral, as redes MLPs apresentaram arquitetura mais simples (Quadro 1), menos desvios e menos tendenciosidades, expressos pelos menores *Bias*,  $RMSE_{\%}$  e amplitude do erro, evidenciando melhor capacidade de aprendizado (Quadro 2). Portanto, as redes MLPs foram as mais adequadas para calcular a AFE e o CT. Optou-se pelas RNAs 3 e 4 para as análises gráficas subsequentes (Figuras 1 e 2).

As redes MLPs apresentaram homogeneidade de variâncias (Figura 1) e ausência de ruídos ao assumir como *outliers* as linhas

**Quadro 1** - Características das redes neurais artificiais (RNA) construídas para estimar a área foliar específica e o conteúdo de clorofila total aos 101 meses de idade

**Table 1** - Characteristics of artificial neural networks (ANNs) constructed to estimate specific leaf area and total chlorophyll content at 101 months of age

RNA	n	Arquitetura	Entrada		Função de Ativação	
			Numérica	Categórica	Intermediária	Saída
1	90	RBF 8-14-1	<i>DAP, Ht, Esp</i>	<i>Copa, Físio</i>	Gaussiana	Identidade
2	90	RBF 8-14-1	<i>DAP, Ht, Esp</i>	<i>Copa, Físio</i>	Gaussiana	Identidade
3	90	MLP 8-6-1	<i>DAP, Ht, Esp</i>	<i>Copa, Físio</i>	Identidade	Exponencial
4	90	MLP 8-5-1	<i>DAP, Ht, Esp</i>	<i>Copa, Físio</i>	Identidade	Exponencial

*DAP* = diâmetro a 1,30 m de altura do solo (cm); *Ht* = altura total (m); *Esp* = espaçamento entre plantas (m); n = número de observações; Físio = fisiologia; *Copa*: terço inferior - 1, médio - 2 e superior - 3; e Fisiologia: AFE - 1 e CT - 2.

**Quadro 2** - Precisão das redes neurais artificiais (RNA) construídas para estimar a área foliar específica e o conteúdo de clorofila total aos 101 meses de idade

**Table 2** - Accuracy of artificial neural networks (ANNs) constructed to estimate specific leaf area and total chlorophyll content at 101 months of age

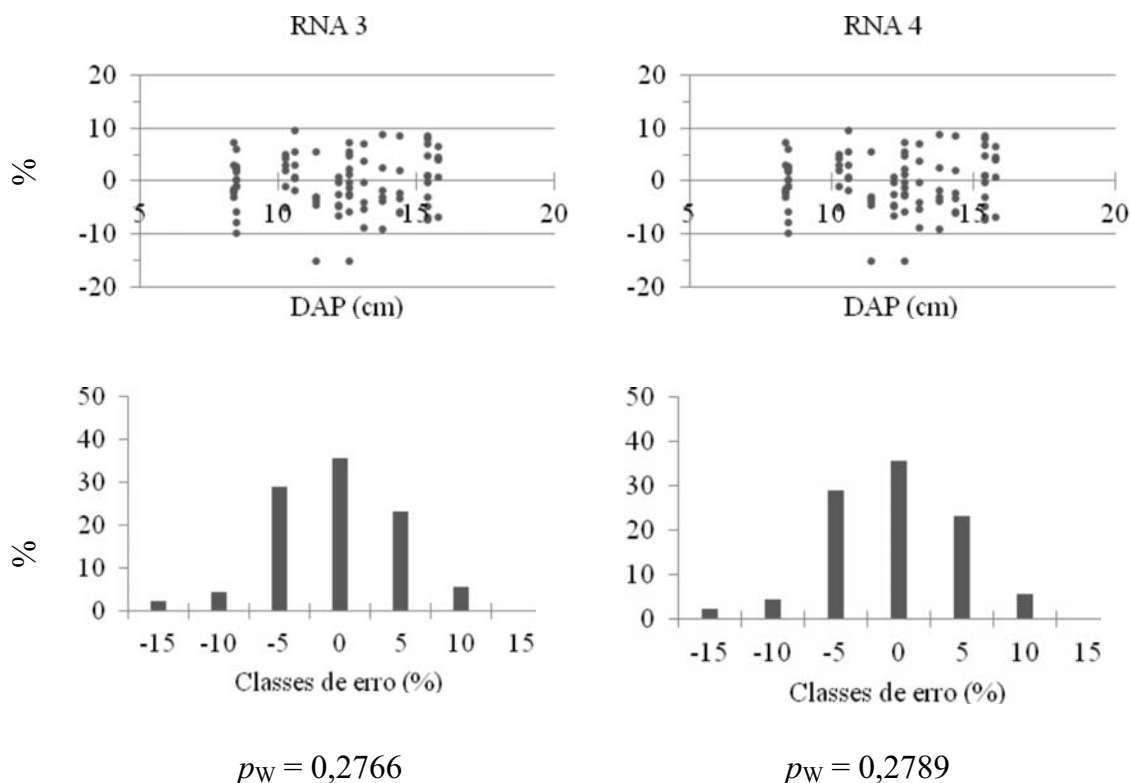
RNA	Fase	RMSE%	Bias%	Erro Relativo (%)			Teste <i>t</i>
				Maximo	Média	Mínimo	<i>p</i>
1	Treinamento	2,8	0,0	13,9	0,3	-16,9	0,0127
	Validação	10,2	4,4	10,6	-3,0	-18,9	0,0961
2	Treinamento	2,7	0,0	15,2	0,3	-8,6	0,0124
	Validação	10,9	4,4	16,0	-2,8	-22,1	0,2077
3	Treinamento	2,4	0,1	9,5	0,1	-9,1	0,2791
	Validação	8,9	3,3	8,6	-2,4	-15,2	0,6606
4	Treinamento	2,4	0,1	9,5	0,1	-9,1	0,2788
	Validação	8,9	3,3	8,6	-2,4	-15,2	0,6632

*p* = probabilidade pelo teste *t* pareado.

de dados que, após o processamento, tiveram AFE e CT superiores a 2,5 unidades de desvio-padrão, em relação ao dado observado correspondente, o que comprova a habilidade das RNA em lidar com os *outliers* durante o processo de ajuste de seus pesos, mediante o uso de um algoritmo de aprendizagem. Os erros evidenciaram distribuição normal, conforme teste de Shapiro Wilk, a 5,0% de probabilidade (Figura 1), portanto os dados estimados por essas redes poderiam ser submetidos à análise de variância. Essa vantagem estatística permite fácil interpretação de resultados experimentais e auxilia nas tomadas de decisão.

Os dados estimados e observados pelas redes selecionadas estão apresentados na Figura 2. As redes MLPs geraram estimativas similares. Embora uma desvantagem observada tenha sido a perda na precisão à medida que aumentou o tamanho das árvores em diâmetro, esses desvios estavam uniformemente distribuídos entre as observações, sem maiores discrepâncias. Ressalta-se que os ensaios experimentais não estão isentos de erros, sendo a variância total, em parte, atribuída a fatores controlados de causas conhecidas e independentes e também a fatores não controlados de natureza aleatória.



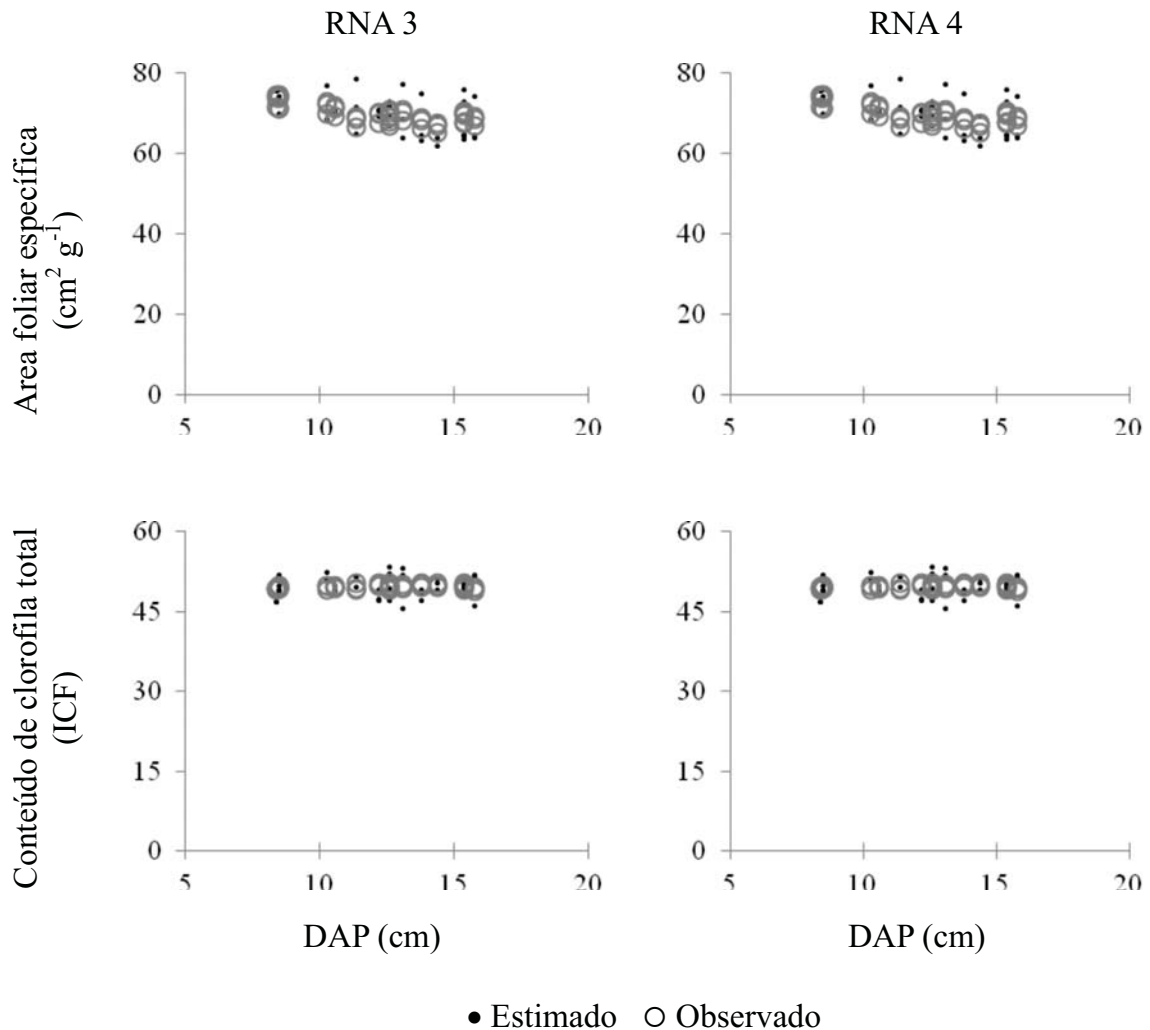


**Figura 1** -Dispersão dos resíduos percentuais em função do DAP e das classes de erro para as redes MLPs construídas para estimar a área foliar específica e o conteúdo de clorofila total aos 101 meses de idade.

**Figure 1** - Dispersion of residual percentage as a function of DBH and error classes for MLP networks built to estimate specific leaf area and total chlorophyll content at 101 months of age.

Os valores estimados para a AFE estão coerentes com a tendência observada por Maire et al. (2011), para *Eucalyptus* spp. Sua amplitude de variação, por hectare, no terço inferior da copa foi de 69,9 a 76,1 cm<sup>2</sup> g<sup>-1</sup>, no terço médio de 67,2 a 72,8 cm<sup>2</sup> g<sup>-1</sup> e no terço superior de 69,3 a 75,4 cm<sup>2</sup> g<sup>-1</sup>, sendo os maiores valores observados nos menores espaçamentos de plantio (Figura 3). Este fato pode ser resultado de uma resposta do vegetal para compensar o maior sombreamento entre as folhas imposta pela competição, uma vez que a AFE é um atributo influenciado por variáveis ambientais como precipitação, temperatura (WHITEHEAD; BEADLE, 2004) e intensidade luminosa (FORRESTER et al., 2003).

Observou-se pouca variação entre os espaçamentos para o CT, e o coeficiente de variação foi de 0,8%. Sua amplitude de variação, por hectare e em ICF, no terço inferior da copa foi de 49,2 a 50,7, no terço médio de 49,2 a 50,1 e no terço superior de 49,9 a 50,6 (Figura 3). O coeficiente de variação do CT foi 4,3 vezes inferior ao da AFE. De acordo com Maire et al. (2011), alterações na AFE em virtude de mudanças estruturais no dossel podem ocorrer em maior intensidade que no conteúdo de clorofila, que é praticamente constante entre idades e povoamentos de eucalipto, diante da queda das folhas após o amarelecimento.

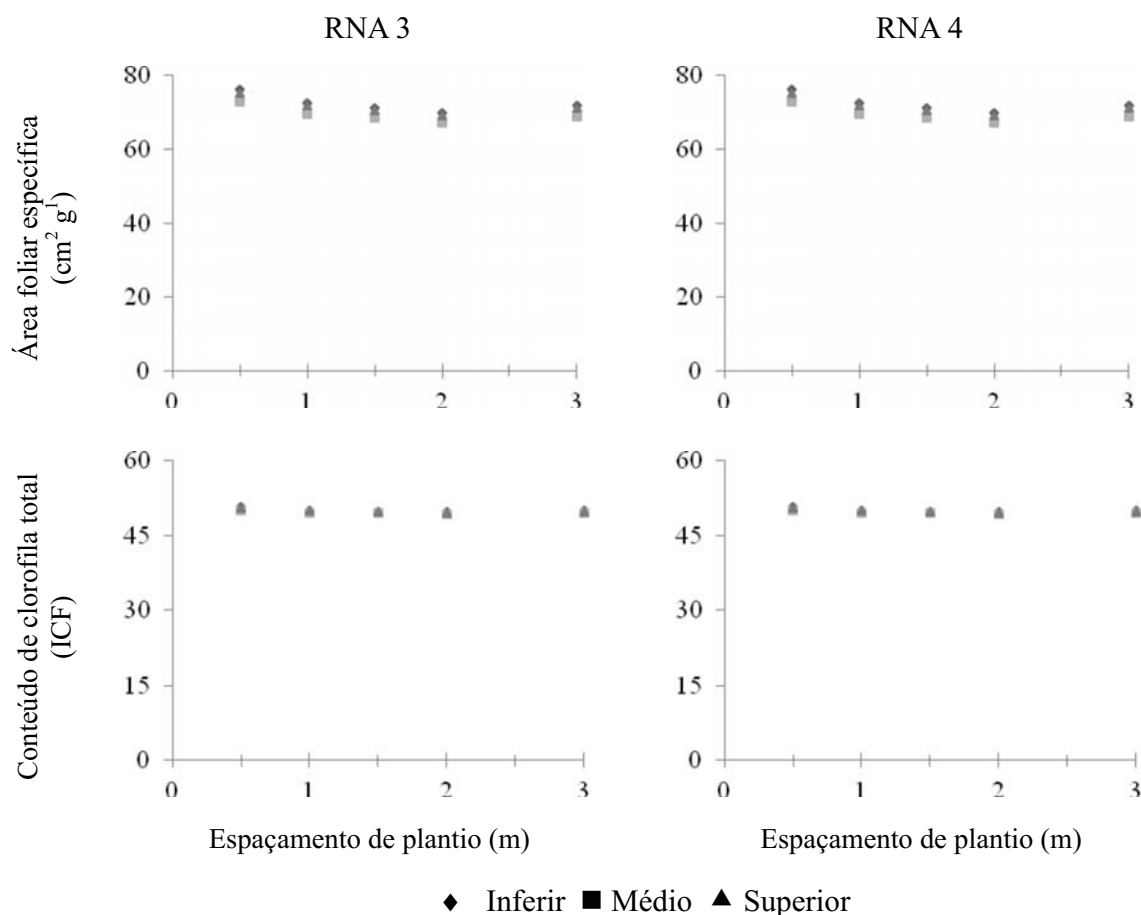


**Figura 2** -Estimação da área foliar específica (AFE) e do conteúdo de clorofila total (CT) pelas redes MLPs aos 101 meses de idade.

**Figure 2** - Estimation of specific leaf area (SLA) and total chlorophyll content (TCC) by MLP networks at 101 months of age".

As redes MLPs foram capazes de aprender e generalizar o conhecimento assimilado para todas as árvores mensuradas, ou seja, para um conjunto de dados desconhecidos não empregados durante o treinamento (Figura 3). Assim, demonstraram que podem captar o realismo biológico. Sua capacidade de generalização e conectividade permitiu que se utilizasse apenas uma rede para realizar a

estimação da AFE e do CT para eucalipto em três posições diferentes na copa, em cinco espaçamentos de plantio, de forma mais direta e com apenas uma ferramenta estatística. Ao contrário, o uso dos métodos tradicionais implicaria a realização da análise de variância seguida por testes de médias e de regressão individualmente, para cada atributo ecofisiológico.



**Figura 3** - Estimativas por hectare em função dos terços da copa da área foliar específica (AFE) e do conteúdo de clorofila total (CT, aplicando as redes MLPs aos 101 meses de idade).  
**Figure 3** - Estimates per hectare, as a function of canopy parts, of specific leaf area (SLA) and total chlorophyll content (TC), applying MLP networks at 101 months of age.

#### 4 CONCLUSÃO

A modelagem por RNA utilizando MLPs demonstrou ser adequada, precisa e realista biologicamente para estimar a área foliar específica e o conteúdo de clorofila total em eucalipto.

#### AGRADECIMENTOS

À CAPES, ao CNPq, à Aperam Bioenergia, à UFVJM e à UFV, por toda assistência, auxílio financeiro e apoio.

#### REFERÊNCIAS BIBLIOGRÁFICAS

- BINOTI, M. L. M. S. **Redes neurais artificiais para prognose da produção de povoamentos não desbastados de eucalipto**. 2010. 54 f. Dissertação (Mestrado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa, MG, 2010.
- BRAGA, A. P. et al. **Redes neurais artificiais: teoria e aplicações**. 2.ed. Rio de Janeiro: LTC, 2007. 226 p.
- CERQUEIRA, E. O. et al. Redes neurais e suas aplicações em calibração multivariada. **Química Nova**, v. 24, n. 6, p. 864-873, 2001.



- COELHO, L. S. et al. Previsão não-linear dos preços de troncos de eucalipto baseada em uma abordagem neuroevolutiva. **Gestão & Produção**, v. 14, n. 1, p. 139-154, 2007.
- FORRESTER, D. et al. Competition in thinned silver top ash (*Eucalyptus sieberi* L. Johnson) stands from early coppice growth. **Forest Ecology and Management**, v. 174, n. 1, p. 459-475, 2003.
- GORGENS, E.B. et al. Estimação do volume de árvores utilizando redes neurais artificiais. **Revista Árvore**, v. 33, n. 6, p. 1141-1147, 2009.
- HAYKIN, S. **Redes neurais: princípios e prática**. 2.ed. Porto Alegre: Bookman, 2001. 900 p.
- LACLAU, J. P. et al. Biogeochemical cycle of nutrients in tropical *Eucalyptus* plantations: Main features shown by intensive monitoring in Congo and Brazil. **Forest Ecology and Management**, v. 259, n. 9, p. 1771-1785, 2010.
- LANDSBERG, J. J.; WARING, R. H. A generalized model of forest productivity using simplified concepts of radiation-use efficiency, carbon balance and partitioning. **Forest Ecology and Management**, v. 95, n. 3, p. 209-228, 1997.
- LEITE, F. P. et al. Crescimento de *Eucalyptus grandis* em diferentes densidades populacionais. **Revista Árvore**, v. 21, n. 3, p. 313-321, 1997.
- MABVURIRA, D.; MIINA, J. Individual-tree growth and mortality models for *Eucalyptus grandis* (Hill) Maiden plantations in Zimbabwe. **Forest Ecology and Management**, v. 161, n. 1/3, p. 231-245, 2002.
- MAIRE, G. et al. Leaf area index estimation with MODIS reflectance time series and model inversion during full rotations of *Eucalyptus* plantations. **Remote Sensing of Environment**, v. 115, n. 2, p. 586-599, 2011.
- NOUVELLON, Y. et al. Within-stand and seasonal variations of specific leaf area in a clonal *Eucalyptus* plantation in the Republic of Congo. **Forest Ecology and Management**, v. 259, n. 9, p. 1796-1807, 2010.
- PALMA, A. A.; PORTUGAL, M. S. Análise empírica da formação de expectativas de inflação no Brasil: Uma aplicação de redes neurais artificiais a dados em painel. **Revista de Economia Contemporânea**, v. 13, n. 3, p. 391-437, 2009.
- SOARES, F. A. A. M. N. et al. Recursive diameter prediction and volume calculation of eucalyptus trees using Multilayer Perceptron Networks. **Computers and Electronics in Agriculture**, v. 78, n. 1, p. 19-27, 2011.
- STATSOFT, INC. Statistica (data analysis software system), version 7.
- WHITEHEAD, D.; BEADLE, C. L. Physiological regulation of productivity and water use in Eucalyptus: a review. **Forest Ecology and Management**, v. 193, n. 1/2, p. 113-140, 2004.