

MAYRA LUIZA MARQUES DA SILVA BINOTI

**REDES NEURAS ARTIFICIAIS PARA PROGNÓSE DA PRODUÇÃO DE
POVOAMENTOS NÃO DESBASTADOS DE EUCALIPTO**

Dissertação apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Ciência Florestal, para obtenção do título de *Magister Scientiae*.

VIÇOSA
MINAS GERAIS – BRASIL
2010



**Ficha catalográfica preparada pela Seção de Catalogação e
Classificação da Biblioteca Central da UFV**

T

B614r
2010

Binoti, Mayra Luiza Marques da Silva, 1986-
Redes neurais artificiais para prognose da produção de
povoamentos não desbastados de eucalipto / Mayra Luiza
Marques da Silva Binoti. – Viçosa, MG, 2010.
viii, 54f. : il. (algumas col.) ; 29cm.

Orientador: Helio Garcia Leite.
Dissertação (mestrado) - Universidade Federal de Viçosa.
Inclui bibliografia.

1. Florestas – Administração. 2. Eucalipto – Populações. 3.
Levantamentos florestais. 4. Redes neurais (Computação).
I. Universidade Federal de Viçosa. II. Título.

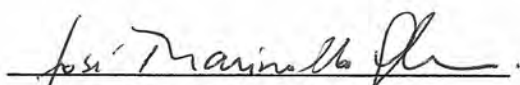
CDO adapt. CDD 634.9524

MAYRA LUIZA MARQUES DA SILVA BINOTI

**REDES NEURAIIS ARTIFICIAIS PARA PROGNÓSE DA PRODUÇÃO DE
POVOAMENTOS NÃO DESBASTADOS DE EUCALIPTO**


Dissertação apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Ciência Florestal, para obtenção do título de *Magister Scientiae*.

APROVADA: 23 de fevereiro de 2010.

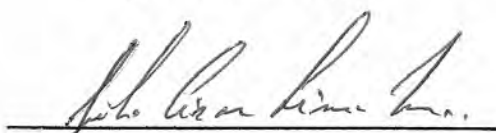


Prof. José Marinaldo Cleriani

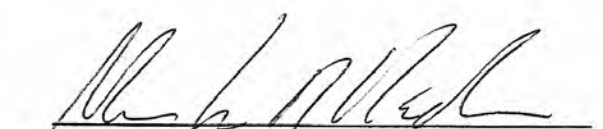
(Co-orientador)



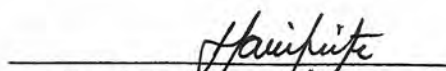
Prof. Carlos Pedro Boechat Soares



Prof. Júlio César Lima Neves



Prof. Márcio Leles Romarco de Oliveira



Prof. Helio Garcia Leite
(Orientador)

DEDICO

A Deus, que está sempre comigo e me presenteia com a vida.
Ao amor da minha vida e marido Daniel.
Ao meu pai Maurício, à minha mãe Neide.
Aos meus irmãos Matheus e Paulo Vitor.

"Não pretendo dizer que já alcancei esta meta e que cheguei à perfeição. Não. Mas me empenho em conquistá-la, uma vez que também eu fui conquistado por Jesus Cristo. Consciente de não tê-la ainda conquistado, só procuro isto: prescindindo do passado e atirando-me ao que resta pela frente, persigo o alvo, rumo ao prêmio celeste, ao qual Deus nos chama, em Jesus Cristo. Nós, mais aperfeiçoados que somos, ponhamos nisto nosso afeto, e se tendes outro sentir, sobre isto, Deus vos há de esclarecer. Contudo, seja qual for o grau a que chegamos, o que importa é prosseguir decididamente."

Carta de São Paulo aos Filipenses 3, 12-16

AGRADECIMENTOS

À Universidade Federal de Viçosa e ao Departamento de Engenharia Florestal pela oportunidade de desenvolver este trabalho.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo apoio financeiro.

Ao professor Helio Garcia Leite pela orientação neste trabalho, disposição e presença constante para conversar e discutir idéias, pela paciência, pelo empenho em conseguir os dados, pela amizade, atenção e todo zelo, pela pessoa que é.

Ao professor José Marinaldo Gleriani, pela disposição e total prontidão em ajudar e esclarecer as dúvidas, pela amizade.

Aos professores Márcio Leles Romarco de Oliveira, Carlos Pedro Boechat Soares e Júlio César Lima Neves, pela prontidão em participar da banca, pelas sugestões que muito acrescentaram a esta dissertação.

À Veracel por ter fornecido os dados e pela prontidão em esclarecer dúvidas.

Aos meus pais, Maurício e Neide, pela presença constante, pelo amor incondicional, pelo cuidado, por serem exatamente como são. Aos meus irmãos, Matheus e Paulo Vitor, pelo carinho, pela saudade não assumida, pelas visitas.

Ao meu amor e marido Daniel, meu maior incentivador sempre, luz da minha vida, pelo companheirismo, pelo amor, pela motivação, pela presença mesmo quando distante, por ser exatamente como é, por estar sempre ao meu lado.

À minha família, à minha nova família Binoti e Breda e às amigas por todo amor e carinho sempre. E a todos que por esquecimento não os tenha mencionado, mas que me auxiliaram a concluir este trabalho.

BIOGRAFIA

Mayra Luiza Marques da Silva Binoti, filha de Maurício de Oliveira da Silva e de Neide Marques Pereira de Oliveira da Silva, nasceu em 29 de abril de 1986, em João Monlevade, Minas Gerais.

Em 2003, concluiu o 2º grau na Escola Estadual Luiz Prisco de Braga, em João Monlevade, Minas Gerais.

Em 2004, iniciou o curso de Engenharia Florestal, na Universidade Federal de Viçosa, sendo o mesmo concluído em julho de 2008.

Recebeu Votos de Louvor pelo desempenho acadêmico durante o curso de graduação.

No período de 2006 a 2008, foi bolsista de iniciação científica pelo CNPq.

Em agosto de 2008, iniciou o Programa de Mestrado em Ciência Florestal, na Universidade Federal de Viçosa, submetendo-se à defesa da dissertação em 23 de fevereiro de 2010.

SUMÁRIO

	Página
RESUMO.....	vii
ABSTRACT	viii
INTRODUÇÃO.....	1
CAPÍTULO 1 – REDES NEURAIS ARTIFICIAIS	4
O que é uma rede neural artificial	4
Notas históricas.....	5
Inspiração biológica.....	6
Neurônio artificial.....	8
Função de ativação	9
Arquitetura das redes neurais artificiais	10
Aprendizagem.....	12
Referências Bibliográficas	17
CAPÍTULO 2 – PROGNÓSE EM NÍVEL DE POVOAMENTO EMPREGANDO REDES NEURAIS ARTIFICIAIS	19
1. INTRODUÇÃO.....	19
2. MATERIAL E MÉTODOS	22
Descrição dos dados	22
Treinamento das redes neurais artificiais	23
Generalização das redes neurais artificiais.....	23
Prognose da produção florestal	24
Avaliação das estimativas geradas pelas redes neurais artificiais	24

	Página
3. RESULTADOS E DISCUSSÃO.....	26
Projeção da área basal	26
Projeção do volume	28
4. CONCLUSÕES	34
5. REFERÊNCIAS BIBLIOGRÁFICAS	35
CAPÍTULO 3 – PROGNÓSE EM NÍVEL DE ÁRVORE INDIVIDUAL EMPREGANDO REDES NEURAS ARTIFICIAIS	37
1. INTRODUÇÃO.....	37
2. MATERIAL E MÉTODOS	40
Descrição dos dados	40
Treinamento das redes neurais artificiais	41
Generalização das redes neurais artificiais.....	42
Prognóse da produção florestal	42
Avaliação das estimativas geradas pelas redes neurais artificiais	43
3. RESULTADOS E DISCUSSÃO.....	44
Prognóse da produção a partir da projeção do dap e da altura total.....	44
Prognóse da produção a partir da projeção do volume inicial	47
4. CONCLUSÕES	51
5. REFERÊNCIAS BIBLIOGRÁFICAS	52
CONCLUSÕES GERAIS.....	54

RESUMO

BINOTI, Mayra Luiza Marques da Silva, M.Sc., Universidade Federal de Viçosa, fevereiro de 2010. **Redes neurais artificiais para prognose da produção de povoamentos não desbastados de eucalipto.** Orientador: Helio Garcia Leite. Co-orientadores: Carlos Antonio Álvares Soares Ribeiro e José Marinaldo Gleriani.

O objetivo deste estudo foi treinar, aplicar e avaliar a eficiência de redes neurais artificiais (RNA) para realizar a prognose da produção de povoamentos equiâneos de clones de eucalipto. Os dados utilizados foram provenientes de povoamentos localizados no sul da Bahia, totalizando cerca de 2.000 hectares de floresta. Foram utilizadas variáveis numéricas, como idade, área basal, *dap*, altura total, volume e variáveis categóricas, como classe de solo, textura, tipos de espaçamento, relevo, projeto e clone. Os níveis de detalhamento da modelagem foram para o povoamento e para árvores individuais. Os dados foram divididos aleatoriamente em dois grupos: treinamento (80%) e generalização (20%). Os dados de treinamento foram utilizados para criar as redes neurais, enquanto que os dados de generalização serviram para avaliar a capacidade da rede em fornecer resultados precisos para dados desconhecidos. Foram treinadas redes de três tipos: perceptron, perceptron de múltiplas camadas e redes de função de base radial. As RNA que apresentaram os melhores desempenhos no treinamento e generalização foram selecionadas para realizar a prognose com dados a partir do primeiro inventário florestal. Conclui-se que as RNA apresentaram resultados satisfatórios em ambos os níveis, povoamento total e árvore individual, comprovando o potencial e aplicabilidade da técnica na solução dos problemas de mensuração e manejo florestal.

ABSTRACT

BINOTI, Mayra Luiza Marques da Silva, M.Sc., Universidade Federal de Viçosa, February, 2010. **Artificial neural networks for prognosis of yield of non-thinned stands of eucalyptus**. Adviser: Helio Garcia Leite. Co-advisers: Carlos Antonio Álvares Soares Ribeiro and José Marinaldo Gleriani.

The aim of this study was to train, implement and evaluate the efficiency of artificial neural networks (ANN) to perform the prognosis of yield of even-aged stands of clones of eucalyptus. The data were from stands of eucalyptus located in south of Bahia, totaling about 2,000 hectares of forest. Were used numerical variables such as age, basal area, *dbh*, total height, volume and categorical variables such as class of soil, texture, spacing, topography, project and clone. The levels of detail of modeling were at the level of stand and individual tree. The data were randomly divided into two groups: training (80%) and generalization (20%). The training data were used to create neural networks, while the generalization data were used to evaluate the capacity of network to provide accurate results for the unknown data. Were trained three types of networks: perceptron, multilayer perceptron and radial basis function. The ANN that presents the best performances in training and generalization were selected to perform the prognosis with data from the first inventory. Concluded that the ANN showed satisfactory results for total stand and individual tree, proving the potential and applicability of the technique in solving problems of forest measurement and management.

INTRODUÇÃO

Redes neurais artificiais (RNA) são redes de neurônios artificiais, sendo aproximações grosseiras, ou seja, simplificações das redes e neurônios encontrados nos cérebros biológicos. Consistem em sistemas computacionais paralelos (camadas) constituídos de várias unidades de processamento simples (neurônios artificiais) conectadas entre si de uma maneira específica para executar uma determinada tarefa (Bullinaria, 2009).

Os estudos na área de RNA se justificam por diversas propriedades úteis e capacidades como: adaptabilidade (uma rede treinada para operar num ambiente específico pode ser retreinada para lidar com modificações e, atuando em ambiente não estacionário, uma rede pode ser projetada para modificar seus pesos em tempo real), tolerância a falhas e ruídos, aprendizagem e generalização a partir de dados de treinamento, paralelismo maciço que as tornam muito eficientes, uniformidade de análise e projeto e analogia neurobiológica (Braga et al., 2000; Haykin, 2001; Bullinaria, 2009).

Os problemas tratáveis através de redes neurais enquadram-se nas tarefas de aprendizagem: aproximação de função, classificação de padrões, agrupamento de dados, predição (séries temporais), otimização, recuperação de conteúdo e controle (Jain et al., 1996; Haykin, 2001).

A prognose da produção florestal se enquadra na tarefa de aproximação de função que consiste em projetar uma rede neural que aproxime a função desconhecida $f(x)$, que descreve o mapeamento dos pares de entrada-saída $\{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$ de um conjunto de n padrões de treinamento. O termo prognose florestal é utilizado como referência à qualquer procedimento que permita prever estoques de

colheita e de crescimento futuro, podendo incluir predição ou projeção. Predição envolve o uso de uma função que inclui a variável idade como independente e a variável produção como dependente. Projeção envolve funções do tipo $Y_2 = f(Y_1, X_k)$, em que $k = 1, 2, \dots, k$ variáveis e Y_1 e Y_2 são as ocasiões atual e futura (Campos e Leite, 2009).

Para manejar uma floresta equiânea é necessário um domínio sobre os seus três elementos essenciais, que são a classificação de terras, o estabelecimento de prescrições e a prognose (Davis e Johnson, 1987; Campos e Leite, 2009). Dessa maneira, qualquer pesquisa específica em uma dessas áreas contribui para um melhor manejo florestal.

A aplicação de redes neurais artificiais em manejo de florestas equiâneas é incipiente e promissora. Guan e Gertner, no início da década de 90 (1991a; 1991b; 1995), desenvolveram trabalhos para modelar a sobrevivência de árvores utilizando redes neurais artificiais. As redes ajustaram-se melhor aos dados do que o modelo estatístico empregado, tanto para predição quanto para projeção. Gordon (1998) comparou métodos tradicionais de modelagem do crescimento florestal com redes neurais artificiais Bayesianas que se mostraram uma alternativa vantajosa. Diamantopoulou (2005) comprovou a superioridade das RNA em relação aos algoritmos de regressão não-linear para estimar o volume de casca em pinus (*Pinus brutia* Ten.). Conclui ainda que as redes têm grande potencial para aplicação em modelagem florestal, sendo útil como alternativa às técnicas tradicionais. Görgens (2006) utilizando dados de cubagem de diferentes empresas florestais, testou algumas formas de pré-processamento dos dados e arquiteturas de RNA para estimar volume de árvores de eucalipto (*Eucalyptus* spp.) e de teca (*Tectona grandis* L.f.). Silva (2008) obteve redes neurais que estimaram de maneira precisa os diâmetros sem casca e do cerne ao longo do fuste para árvores de teca superando os resultados obtidos por modelos de *taper*.

A prognose da produção florestal pode ser desenvolvida utilizando RNA, empregando dados de crescimento e produção, variáveis dendrométricas, tradicionais dos bancos de dados de inventário florestais, variáveis edáficas, climáticas e coordenadas geográficas, dentre outras. Dessa forma, o objetivo deste estudo foi treinar, aplicar e avaliar a eficiência de redes neurais artificiais para realizar a prognose da produção de povoamentos não desbastados de clones de eucalipto, em nível de povoamento e de árvores individuais.

Diante do objetivo proposto foram formuladas as seguintes hipóteses: H_{01} : redes neurais artificiais são capazes de realizar a prognose da produção em nível de povoamento; H_{a1} : não H_{01} ; H_{02} : redes neurais artificiais são capazes de realizar a prognose da produção em nível de árvores individuais e H_{a2} : não H_{02} .

A dissertação foi organizada em três capítulos. No primeiro é apresentada uma abordagem teórica sobre redes neurais. O segundo capítulo comprova a eficiência das RNA para prognose em nível de povoamento e o terceiro comprova esta mesma eficiência, porém em nível de árvore individual.

CAPÍTULO 1

REDES NEURAIS ARTIFICIAIS

O que é uma rede neural artificial

Redes neurais artificiais (RNA) são redes de neurônios artificiais (Figura 1), ou seja, uma RNA é um sistema computacional paralelo constituído de várias unidades de processamento simples, conectadas entre si, de uma maneira específica para desempenhar uma determinada tarefa (Bullinaria, 2009). É um sistema paralelo, pois, seus elementos básicos, os neurônios artificiais ou nodos, encontram-se dispostos em uma ou mais camadas (paralelismo) e interligados entre si por um grande número de conexões, formando a rede (sistema). Estas conexões geralmente são associadas a pesos que armazenam o conhecimento representado pela rede e ponderam a entrada recebida por cada neurônio da rede (Braga et al., 2000).

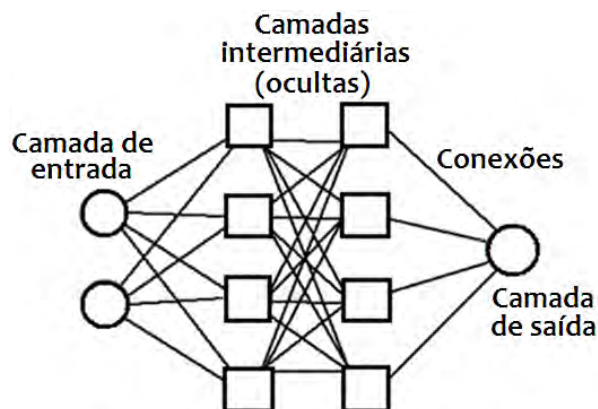


Figura 1 – Exemplo de estrutura de uma rede neural artificial.

Segundo Haykin (2001), uma rede neural artificial é uma máquina projetada para modelar, semelhante ao cérebro, uma tarefa ou função de interesse, com capacidade de armazenar conhecimento experimental e torná-lo disponível para uso. O bom desempenho de uma RNA se deve à interligação maciça de suas unidades de processamento (neurônios artificiais).

A forma como um determinado problema é representado internamente na RNA e o paralelismo de sua arquitetura torna a solução de problemas com RNA melhor do que as soluções convencionais (Lek et al., 1996; Braga et al., 2000; Haykin, 2001; Scrinzi et al., 2007). Outras características importantes das RNA são: mapeamento de entrada e saída; tolerância a falhas (neurônios e, ou, conexões danificados) e ruídos; adaptabilidade dos pesos das conexões às modificações do ambiente, ou seja, uma rede treinada pode ser retreinada ou uma rede pode ser projetada para modificar seus pesos em tempo real (ambiente não estacionário); capacidade de informar a confiança de uma decisão tomada (probabilidade); aprendizagem a partir de exemplos e generalização para dados desconhecidos; e analogia neurobiológica (Haykin, 2001; Bullinaria, 2009).

Em uma RNA, a solução do problema inicia-se com a aprendizagem (ou treinamento), onde um conjunto de exemplos, geralmente denominado conjunto de treinamento, é apresentado para a rede que extrai as características necessárias para representar a informação contida nos dados e gerar a resposta para o problema. Após a fase de aprendizagem a rede está pronta para aplicações posteriores, caso tenha a capacidade de generalizar, ou seja, gerar respostas coerentes para dados não-conhecidos (Braga et al., 2000).

Notas históricas

O trabalho inicial na área das redes neurais artificiais foi publicado em 1943 com o título "*A Logical Calculus of the Ideas Immanent in Nervous Activity*" quando foi proposto o primeiro modelo artificial de um neurônio biológico. Este trabalho foi desenvolvido pelo psiquiatra e neuroanatomista Warren McCulloch e pelo matemático Walter Pitts (McCulloch e Pitts, 1943).

Em 1949, Donald Hebb apresentou estudos sobre a aprendizagem de redes biológicas e artificiais. Uma importante contribuição destes estudos foi à teoria para

explicar o aprendizado em neurônios biológicos. Nesta teoria, Hebb mostrou que a aprendizagem baseia-se no reforço das sinapses entre neurônios excitados (Hebb, 1949), que é atualmente conhecida e utilizada em vários algoritmos de aprendizagem (Braga et al., 2000; Haykin, 2001).

Em 1958, Frank Rosenblatt propôs o perceptron, um novo modelo de RNA constituído por neurônios de McCulloch e Pitts. Neste modelo, existem sinapses (pesos) ajustáveis, permitindo que seja feito treinamento para classificar certos tipos de padrões, ou seja, dividir o espaço de entrada em regiões distintas para cada uma das classes existentes. Rosenblatt também propôs um algoritmo para treinar a rede (Rosenblatt, 1958).

Na década de 60, Widrow e Hoff propuseram uma regra de aprendizado baseada no método do gradiente de minimização do erro de saída de um neurônio com resposta linear (Widrow e Hoff, 1960). Esta regra é atualmente conhecida como regra delta e ainda muito utilizada.

Em 1969, Minsky e Papert ressaltaram as limitações do perceptron, como a incapacidade de resolver problemas não-linearmente separáveis (*hard learning problems*), por exemplo, detectar paridade, conectividade e simetria, e a inexistência de um algoritmo de treinamento para redes perceptron com mais de uma camada (Minsky e Papert, 1969). A repercussão deste trabalho enfraqueceu os estudos na área de redes neurais artificiais. Somente em 1982, retomaram-se as pesquisas na área devido ao artigo de John Hopfield que mostrou a relação entre redes recorrentes auto-associativas e sistemas físicos. Posteriormente, em 1986, Rumelhart, Hinton, e Williams descreveram o algoritmo de treinamento *error back-propagation* (Rumelhart et al., 1986), mostrando que a visão de Minsky e Papert sobre o perceptron era bastante pessimista, pois as redes perceptron de múltiplas camadas são capazes de resolver problemas não linearmente separáveis e o *error back-propagation* capaz de treiná-las.

Inspiração biológica

O desenvolvimento de pesquisa envolvendo redes neurais artificiais é motivado pela maneira como o cérebro humano processa informações, sendo capaz de organizar seus neurônios (unidades estruturais) de forma a desempenhar determinados processamentos, como reconhecimento de padrões, muito mais rápido e eficiente

que um computador convencional (Haykin, 2001). A estrutura dos neurônios, os tipos de conexões entre eles e o comportamento das redes de neurônios naturais formam a base para o estudo das RNA (Braga et al., 2000).

Apesar do estudo contínuo, o funcionamento das redes biológicas ainda não foi totalmente desvendado. A cada nova descoberta, os modelos existentes são atualizados. RNA tentam reproduzir as funções das redes biológicas, buscando implementar seu comportamento básico e sua dinâmica. Das similaridades entre as redes neurais naturais e as artificiais, citam-se: ambas são constituídas de unidades de computação paralela e distribuída que se comunicam por meio de conexões sinápticas, e ambas possuem detectores de características, redundância e modularização das conexões (Braga et al., 2000).

O neurônio biológico pode ser dividido em três partes: o corpo celular, os dendritos e o axônio (Figura 2). Os dendritos são ramificações que recebem as informações, na forma de impulsos nervosos, oriundas de outros neurônios e as conduzem para o corpo celular. Este processa as informações gerando novos impulsos nervosos que são transmitidos através do axônio aos dendritos de outros neurônios. O ponto de contato entre a terminação do axônio de um neurônio e o dendrito de outro é chamado de sinapse. As sinapses são responsáveis pela união funcional dos neurônios, ou seja, pela formação das redes neurais e controlam a transmissão de impulsos, isto é, o fluxo da informação entre os neurônios. Esta transmissão ocorre devido à liberação de moléculas neurotransmissoras que determinam se a sinapse será inibitória ou excitatória (Braga et al., 2000).

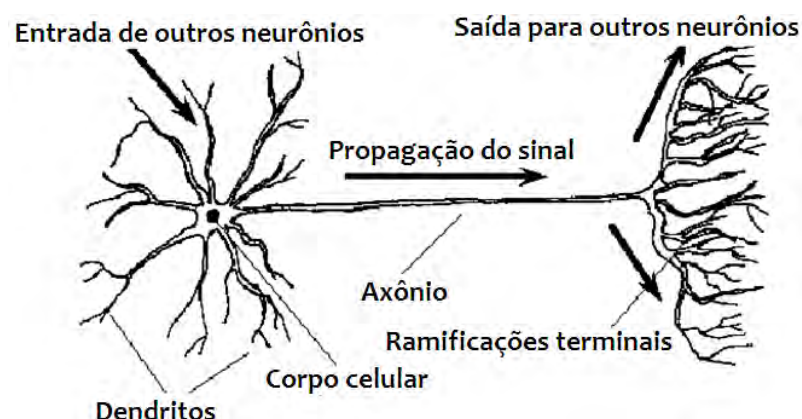


Figura 2 – Estrutura do neurônio biológico e a seqüência de propagação do sinal (Silva, 1998).

Os impulsos oriundos dos neurônios pré-sinápticos chegam ao corpo celular do neurônio pós-sináptico, onde são combinados e, se o valor resultante for superior ao limiar de excitação do neurônio, num pequeno intervalo de tempo, a célula "dispara", produzindo um impulso que é transmitido para as células seguintes (neurônios pós-sinápticos). Este sistema simples é responsável pela maioria das funções realizadas pelo nosso cérebro. A capacidade de realizar funções complexas surge com a operação em paralelo de todos os neurônios do cérebro (Braga et al., 2000).

Neurônio artificial

Um neurônio artificial é a unidade de processamento de informação de uma rede neural artificial. O primeiro modelo de neurônio artificial, proposto por McCulloch e Pitts (MCP) em 1943, é uma simplificação do que se sabia a respeito do neurônio biológico na época. Constituído de n entradas x_1, x_2, \dots, x_n (dendritos) e uma saída y (axônio). As entradas são associadas a pesos w_1, w_2, \dots, w_n que representam as sinapses que podem ser negativas ou positivas. É calculada a soma ponderada dos valores $x_i w_i$ recebidos, se o valor obtido ultrapassa o limiar (*threshold*) do neurônio, este “dispara”, ou seja, ativa a função de ativação e gera saída (Figura 3). No modelo original MCP, a função de ativação é a função de limiar que é ativada quando:

$$\sum_{i=1}^n x_i w_i \geq \theta$$

onde n é o número de entradas do neurônio, w_i é o peso associado à entrada x_i ; e θ é o limiar do neurônio.




Figura 3 – Neurônio de McCulloch e Pitts (Adaptado de Braga et al., 2000).

Algumas limitações do modelo MCP são: redes MCP com uma camada implementam apenas funções linearmente separáveis; pesos negativos são mais adequados para representar disparos inibidores; o modelo foi proposto com pesos fixos, não-ajustáveis e os neurônios em cada camada da rede disparam todos ao mesmo tempo (Braga et al., 2000).

Atualmente, um modelo básico de neurônio artificial pode ser representado pela Figura 4. Um sinal x_m na entrada da sinapse j conectada ao neurônio k é multiplicado pelo peso sináptico w_{km} que pode assumir valores negativos ou positivos. Uma junção aditiva soma os sinais de entrada ponderados pelas respectivas sinapses (pesos), o resultado v_k passa por uma função de ativação que gera a saída y_k do neurônio. O modelo inclui um *bias* b_k (limiar) que tem o efeito de aumentar ou diminuir a entrada líquida da função de ativação, se positivo ou negativo, respectivamente. Geralmente, este parâmetro é considerado como um peso sináptico associado a um novo sinal de entrada fixo em +1 (Haykin, 2001).




Figura 4 – Estrutura do neurônio artificial (Haykin, 2001).

Matematicamente, um neurônio artificial k pode ser descrito por:

$$y_k = \varphi(v_k)$$

em que: y_k é a saída do neurônio artificial, $\varphi(\cdot)$ é a função de ativação e v_k é o resultado do combinador linear, ou seja, $v_k = \sum_0^m x_m \cdot w_m$.

Função de ativação

Existem três tipos básicos de função de ativação: função de limiar, função linear por partes e função sigmóide (Figura 5). O neurônio com a função de ativação de limiar terá saída igual a 1 se $v_k \geq 0$ ou a 0 se $v_k < 0$, tal neurônio é conhecido como o modelo de McCulloch e Pitts. Na função linear por partes, a saída será 1 se $v_k \geq +1/2$, v se $+1/2 > v_k > -1/2$ e 0 se $v_k \leq -1/2$. Enquanto que a função de ativação

sigmóide é a mais comum na construção de redes neurais artificiais. Seu gráfico tem a forma de *s* e um exemplo deste tipo de função é a logística, definida por:

$$\varphi(v) = \frac{1}{1 + \exp(-av)}$$

onde *a* é o parâmetro que determina a inclinação da função sigmóide. Uma função sigmóide assume um intervalo contínuo de valores entre 0 e 1, sendo diferenciável, característica importante para as RNA.

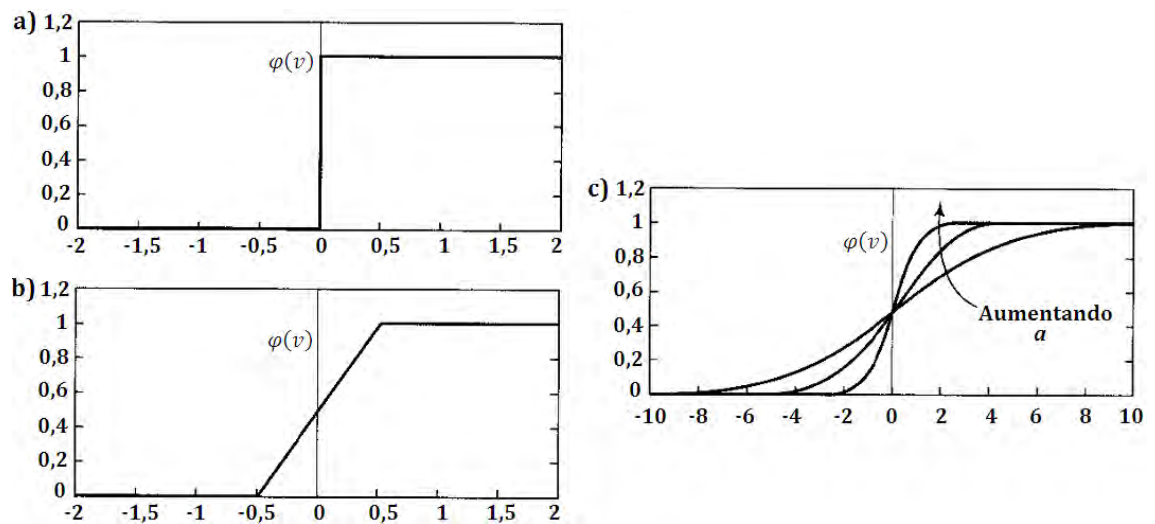


Figura 5 – Funções de ativação: a) função de limiar, b) função linear por partes e c) função sigmóide (Haykin, 2001).

Arquitetura das redes neurais artificiais

A arquitetura de uma RNA consiste na maneira como os neurônios estão estruturados e suas conexões, ou seja, número de camadas da rede, número de neurônios em cada camada, tipo de conexão entre os neurônios. Esses parâmetros definem o tipo de problema que pode ser tratado pela rede (Braga et al., 2000).

RNA consideram variáveis quantitativas e qualitativas na solução de problemas. Para cada variável quantitativa há um único neurônio na camada de entrada da rede, enquanto que o número de neurônios para uma variável qualitativa depende do número de classes desta variável, sendo necessário um neurônio para cada classe. Uma classe é determinada pelo seu respectivo neurônio com valor 1 (um) e os demais neurônios (das outras classes da variável qualitativa) com o valor 0 (zero).

As redes podem ser classificadas quanto ao número de camadas (redes de camada única ou redes de múltiplas camadas), ao tipo de conexões (*feedforward* ou

feedback) e à conectividade (rede parcialmente ou completamente conectada) (Braga et al., 2000; Bullinaria 2009).

Redes de camada única (Figura 6a) recebem esta denominação por terem apenas uma camada de neurônios de processamento, uma vez que a camada de entrada de qualquer RNA não realiza processamento de informações, apenas repassa os sinais de entrada ponderados para a primeira camada. Já as redes de múltiplas camadas (Figura 6b, 6c e 6d) apresentam uma ou mais camadas ocultas, ou seja, camadas que encontram-se entre a camada de entrada e a de saída. A presença de uma ou mais camadas ocultas permite que a RNA extraia estatísticas de ordem elevada do problema tratado e melhoram a capacidade de solução de problema. Isto se deve ao conjunto extra de conexões sinápticas e à dimensão extra de interações neurais. Nas redes multicamadas, os neurônios de cada camada têm como entrada os sinais de saída da camada anterior, e a saída da última camada consiste na resposta final da rede (Haykin, 2001).

Redes *feedforward* (Figura 6a, 6b e 6d) são redes do tipo alimentadas adiante ou acíclicas, enquanto que as redes *feedback* (Figura 6c), também denominadas de recorrentes, possuem pelo menos uma conexão de realimentação. Quanto à conectividade, numa rede totalmente conectada (Figura 6a, 6b e 6c), cada neurônio de uma camada está conectada a todos os neurônios da camada seguinte, já numa rede parcialmente conectada (Figura 6d), falta alguma conexão na rede (Haykin, 2001; Bullinaria, 2009).




Figura 6 – Tipos de arquiteturas de redes neurais artificiais: neurônios de entrada (●) e neurônios de processamento (○) (Adaptado de Bullinaria, 2009).

Aprendizagem

As Redes Neurais Artificiais possuem a capacidade de aprender com exemplos, ou seja, extrair informações importantes e criar uma representação do problema, e posteriormente fazer interpolações e extrapolações do que aprenderam. A etapa de aprendizagem consiste em um processo iterativo de ajuste de parâmetros da rede, ou seja, os pesos das conexões entre as unidades de processamento (neurônios artificiais), que guardam, ao final do processo, o conhecimento que a rede adquiriu do ambiente em que está operando.

No processo de aprendizado tem-se um algoritmo de aprendizado que consiste num conjunto de procedimentos para adaptar os parâmetros de uma RNA para que a mesma possa aprender uma determinada tarefa (Braga et al., 2000; Haykin, 2001). Os diversos algoritmos existentes diferem pela forma de ajuste dos pesos. Os métodos de treinamento podem ser agrupados em duas abordagens: aprendizado supervisionado e aprendizado não-supervisionado.

No aprendizado supervisionado, as entradas e saídas desejadas para a rede são fornecidas por um supervisor externo (usuário). Cada padrão de entrada submetido à rede gera uma saída calculada que é comparada à resposta desejada, ajustando-se os pesos das conexões para minimizar o erro (Figura 7). A minimização da diferença é feita por pequenos ajustes a cada etapa do treinamento, tendendo a uma solução caso esta exista. A soma dos erros quadráticos de todas as saídas é normalmente utilizada como medida de desempenho da rede e também como função de custo a ser minimizada pelo algoritmo de treinamento.




Figura 7 - Aprendizado supervisionado.

O aprendizado supervisionado pode ser implementado de duas formas: off-line ou on-line. No aprendizado off-line, os pesos são atualizados após todos os pa-

drões de treinamento terem sido apresentados. Esta técnica é geralmente mais estável, mas pode ser lenta se o conjunto de treinamento for grande e redundante. No aprendizado on-line, os pesos são atualizados após a apresentação de cada padrão de treinamento. A escolha da abordagem a ser utilizada depende da aplicação e da distribuição estatística dos dados.

No aprendizado não-supervisionado, não há um supervisor para acompanhar o processo de aprendizado (Figura 8). Muitos dos sistemas biológicos ocorrem através de aprendizado não-supervisionado, como por exemplo, os estágios iniciais dos sistemas de visão e audição. Neste processo, somente os padrões de entrada estão disponíveis para a rede, dessa maneira, a rede forma representações internas para codificar características da entrada e cria classes ou grupos. Este tipo de aprendizado só se torna possível quando existe redundância (várias cópias exatas dos mesmos padrões) nos dados de entrada, senão torna-se impossível encontrar quaisquer padrões ou características dos dados de entrada.




Figura 8 - Aprendizado não supervisionado.

A escolha de um tipo de aprendizagem e de rede neural artificial é determinada pela tarefa da aprendizagem que a rede deve executar, ou seja, pelo tipo de problema a ser solucionado. Assim, os problemas tratáveis através de redes neurais enquadram-se nas tarefas de aprendizagem: classificação de padrões, agrupamento de dados, aproximação de função, predição (séries temporais), otimização, recuperação de conteúdo e controle, Figura 9 (Jain et al., 1996; Haykin, 2001).

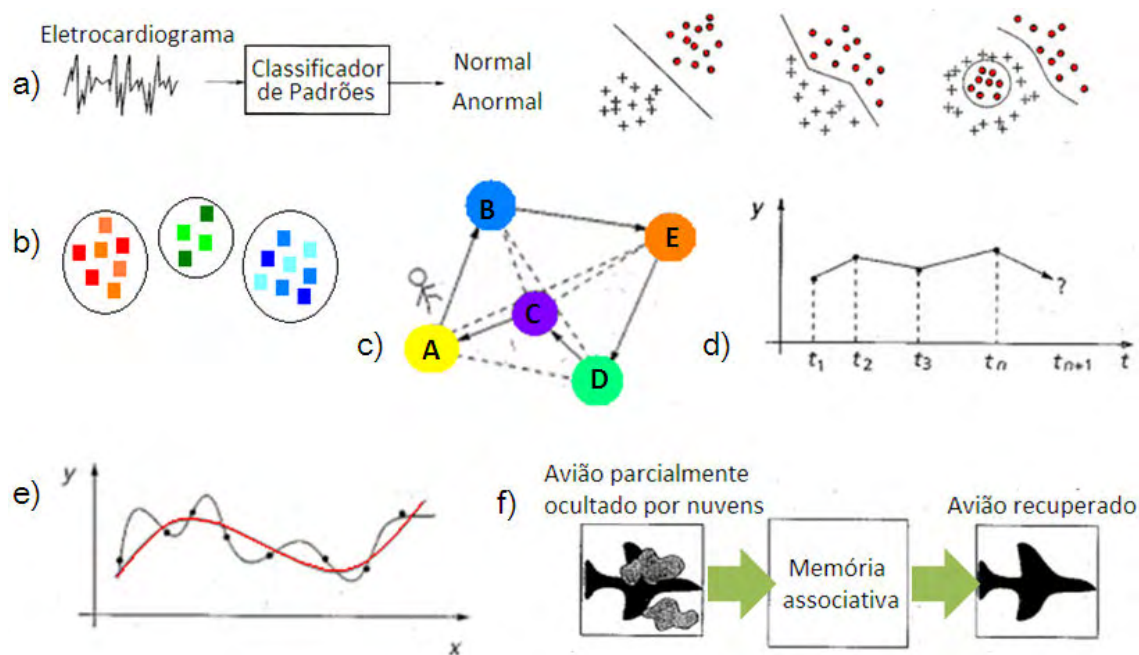


Figura 9 – Tarefas da aprendizagem em RNA: a) classificação de padrões, b) agrupamento de dados, c) otimização, d) previsão (séries temporais), e) aproximação de função e f) recuperação de conteúdo (Adaptado de Jain et al., 1996).

A classificação de padrões designa um padrão de entrada representado por um vetor de características para uma de várias classes pré-especificadas. Aplicações conhecidas incluem reconhecimento de caracteres, reconhecimento de fala e a classificação de células sanguíneas. No agrupamento de dados, também conhecido como classificação de padrões não supervisionada, um algoritmo explora a similaridade entre os padrões, de acordo com regras estatísticas pré-estabelecidas, e agrupa os padrões similares. Aplicações de agrupamento incluem mineração de dados e análise exploratória de dados.

Na previsão, dado um conjunto de n amostras $\{y(t_1), y(t_2), \dots, y(t_n)\}$ em uma sequência temporal, t_1, t_2, \dots, t_n , a tarefa é prever a amostra $y(t_{n+1})$ em algum tempo futuro t_{n+1} . Esta tarefa tem impacto significativo na tomada de decisão em negócios, ciência e engenharia. Previsão em mercado de ações e de condições meteorológicas são aplicações típicas. A otimização engloba uma variedade de problemas da matemática, estatísticas, engenharia, ciência, medicina e economia. A meta de um algoritmo de otimização é encontrar uma solução que satisfaça um conjunto de restrições

tal que uma função objetivo é maximizada ou minimizada. O problema do caixeiro-viajante é um exemplo clássico (Hiller e Lieberman, 2006).

Na recuperação de conteúdo, uma entrada na memória é acessada somente através de seu endereço, o qual é independente do conteúdo na memória. Se um pequeno erro ocorre no cálculo do endereço, um item completamente diferente pode ser obtido. O conteúdo na memória pode ser recordado por uma entrada parcial ou conteúdo distorcido. Esta memória associativa é extremamente desejável na construção de banco de dados de informação multimídia. Já na tarefa de controle, a meta é gerar uma entrada de controle tal que o sistema siga uma trajetória desejada determinada pelo modelo de referência, um exemplo é o controle do motor de marcha lenta.

Na aproximação de função, um conjunto de n padrões de treinamento, pares de entrada(s)-saída, $\{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$, são apresentados à RNA para que aproxime uma função desconhecida $f(x)$. Vários problemas de modelagem da ciência e engenharia necessitam de funções de aproximação. Esta tarefa da aprendizagem se enquadra no paradigma do aprendizado supervisionado e tem como arquiteturas de redes neurais que desempenham esta função os tipos: perceptron de camada única (ou apenas Perceptron), perceptron de múltiplas camadas (também denominado *Multilayer Perceptron* ou MLP) e redes de função de base radial (*Radial Basis Function* ou RBF), todas com conexões *feedforward* (alimentadas adiante), sem realimentação.

O Perceptron é a forma mais simples de uma rede neural artificial, consistindo em uma única camada de processamento da informação, ou seja, a camada de saída, pois a camada de entrada apenas direciona os sinais de entrada ponderados pelos pesos sinápticos à camada seguinte.

Um Perceptron de múltiplas camadas (MLP) possui uma ou mais camadas ocultas (intermediárias), além das camadas de entrada e de saída. Os sinais de entrada propagam-se para frente, camada por camada. O treinamento é do tipo supervisionado com um algoritmo bastante conhecido, o algoritmo de retropropagação do erro (*error back-propagation*), que é baseado na regra de aprendizagem por correção do erro. Nesta regra, os sinais de entrada são apresentados à rede que gera uma saída, que é comparada com a saída desejada, um erro é gerado e este erro aciona um mecanismo de controle que aplica uma seqüência de ajustes corretivos aos pesos sinápticos, a fim de aproximar a saída do resultado desejado, ou seja, a fim de minimizar o erro (Haykin, 2001).

Uma rede de função de base radial (RBF) é constituída de três camadas: a camada de entrada que conecta a rede aos exemplos de treinamento, a segunda camada (única oculta) aplica uma transformação não linear nas entradas e possui alta dimensionalidade (muitos neurônios) e a camada de saída que é linear e fornece a resposta da rede. Os neurônios da camada oculta possuem funções de ativação de base radial, geralmente gaussianas (Braga et al., 2000; Haykin, 2001).

REFERÊNCIAS BIBLIOGRÁFICAS

BRAGA, A. de P.; CARVALHO, A. P. de L. F. de; LUDEMIR, T. B. **Redes Neurais Artificiais**: Teoria e Aplicações. Rio de Janeiro, RJ. Editora LTC, 262 p. 2000.

BULLINARIA, J. A. **Introduction to Neural Computation**. Notas de aula. Disponível em: <http://www.cs.bham.ac.uk/~jxb/inc.html>. 2009.

CAMPOS, J. C. C.; LEITE, H. G. **Mensuração florestal**: perguntas e respostas. 3. ed. rev. e ampl. Viçosa: UFV, 2009. 548 p.

DAVIS, L.S.; JOHNSON, K. N. **Forest management**. 3. ed. New York: McGraw-Hill Book, 1987. 790 p.

DIAMANTOPOULOU, M. J. Artificial neural networks as an alternative tool in pine bark volume estimation. **Computers and electronics in agriculture**, v. 10, p. 235–244, 2005.

GORDON, C. **Artificial Neural Network Modeling of Forest Tree Growth**. 1998. 76 f. Dissertação (Mestrado) - University of the Witwatersrand, 1998.

GÖRGENS, E. **Estimação do volume de árvores utilizando redes neurais artificiais**. 2006. 84f. Dissertação (Mestrado em Ciência Florestal) - Universidade Federal de Viçosa, Viçosa, MG, 2006.

GUAN, B. T.; GERTNER G. Using a parallel distributed processing system to model individual tree mortality. **Forest Science**, v. 37, n. 3, p. 871-885, 1991a.

GUAN, B. T.; GERTNER G. Modeling red pine tree survival with an artificial neural network. **Forest Science**, v. 37, n. 5, p. 1429-1440, 1991b.

GUAN, B. T.; GERTNER G. Modeling individual tree survival probability with a random optimization procedure: An artificial neural network approach. **AI Application**, v. 9, n.1, p. 39-52, 1995.

HAYKIN, S. **Redes neurais: princípios e prática**. 2. ed. Porto Alegre: Bookman, 2001. 900 p.

HEBB, D. O. **The Organization of Behavior**. Wiley, 1949.

HILLER, F. S.; LIEBERMAN, G. J. **Introdução à pesquisa operacional**. 8.ed. São Paulo: Mcgraw-Hill, 2006. 852 p.

JAIN, A. K.; MAO, J.; MOHIUDDIN, K. M. Artificial Neural Networks: A Tutorial. **Computer**, v. 29, n. 3, p. 31-44, 1996.

LEK, S.; DELACOSTE, M.; BARAN, P.; DIMOPOULOS, I.; LAUGA, J.; AULAGNIER, S. Application of neural networks to modelling nonlinear relationships in ecology. **Ecological Modelling**, n. 90, p. 39-52, 1996.

MCCULLOCH S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **Bulletin of Mathematical Biophysics**, v. 5, p. 115-133, 1943.

MINSKY, M.; PAPERT, S. **Perceptrons: an introduction to computational geometry**. MIT Press, Massachusetts. 1969.

ROSENBLATT, F. The perceptron: A probabilistic model for information storage and organization in the brain. **Psychological Review**, v.65, p. 386-408, 1958.

RUMELHART, D. E.; HINTON, G.E.; WILLIAMS, R. J. Learning representations by back-propagating errors. **Nature**, v. 323, p. 533-536, 1986.

SCRINZI, G.; MARZULLO, L.; GALVAGNI, D. Development of a neural network model to update forest distribution data for managed alpine stands. **Ecological Modelling**, n. 206, p. 331-346, 2007.

SILVA, L. N. de C. **Análise e Síntese de Estratégias de Aprendizado para Redes Neurais Artificiais**. 1998. 184 f. Dissertação (Mestrado em Engenharia Elétrica) - Universidade Estadual de Campinas, Campinas, SP, 1998.

SILVA, M. L. M. **Estimação do diâmetro sem casca e diâmetro do cerne para árvores de *Tectona grandis* Linn. utilizando redes neurais artificiais**. 2008. 47 f. Monografia (Exigência para conclusão do curso de Engenharia Florestal) – Universidade Federal de Viçosa, Viçosa, MG, 2008.

WIDROW B.; HOFF, M. E. **Adaptative switching circuits**. Institute of Radio Engineers, Western Electronic Show and Conrention, 1960.

CAPÍTULO 2

PROGNOSE EM NÍVEL DE POVOAMENTO EMPREGANDO REDES NEURAS ARTIFICIAIS

1. INTRODUÇÃO

Em mensuração florestal, o termo prognose é utilizado como referência à predição, projeção ou qualquer outro procedimento que permita prever estoques de crescimento e, ou, de colheita em idades futuras. A predição envolve o uso de uma função que inclui a variável independente idade, enquanto que a projeção envolve funções onde a produção futura é relacionada com a produção atual, dentre outras variáveis (Campos e Leite, 2009). A prognose da produção é um dos três elementos essenciais do manejo sendo difícil estabelecer planos de manejo sem este elemento. As funções são denominadas de modelos de crescimento e produção. Portanto, a modelagem do crescimento e produção consiste em construir, ajustar e aplicar as funções com propósito de prognose para uso em diversas atividades florestais como a simulação da aplicação de tratamentos silviculturais.

A modelagem em nível de povoamento, também denominada povoamento total, não explica a variação do tamanho das árvores dentro do povoamento, pois estimam a produção por unidade de área, com base em atributos do povoamento, como idade, área basal, índice de local, etc. (Vanclay, 1994). O principal modelo empregado no Brasil é o de Clutter (Clutter, 1963). Neste modelo, constituído por um sistema de equações de regressão, a produção é expressa em função das idades

atual e futura, do índice de local na idade atual e das áreas basais atual e futura (Campos e Leite, 2009).

Uma alternativa à modelagem utilizando modelos de regressão é a utilização de redes neurais artificiais. Uma rede neural artificial (RNA) é um processador constituído de unidades de processamento simples (neurônios artificiais) que calculam determinadas funções. Essas unidades estão distribuídas em camadas e conectadas entre si por pesos que armazenam o conhecimento experimental e ponderam as entradas de cada unidade. O conhecimento adquirido torna-se disponível para uso (Braga et al., 2000).

As RNA têm apresentado desempenho superior aos modelos de regressão devido a diversos fatores como: estrutura maciça e paralelamente distribuída (camadas); habilidade de aprender e generalizar que as tornam capazes de resolver problemas complexos; são tolerantes à falhas e ruídos; podem modelar diversas variáveis e suas relações não-lineares; possibilidade de modelagem com variáveis categóricas (qualitativas), além das numéricas (quantitativas); analogia neurobiológica, pois as redes são inspiradas no cérebro humano (Lek et al., 1996; Haykin, 2001; Bullinaria, 2009).

Algumas dificuldades encontradas no treinamento das redes são: definição da melhor arquitetura (número de camadas e número de neurônio por camada), possibilidade de ocorrerem problemas como subtreinamento (*underfitting*) e sobretreinamento (*overfitting*), interpretação de como a rede obteve os resultados (muitas vezes denominada *black-box*), treinamento para em um ponto de mínimo local ao invés de parar no ponto de mínimo global da superfície de erro. Apesar destas dificuldades o desempenho e capacidade computacional das RNA não são comprometidos (Braga et al., 2000; Olden e Jackson, 2002; Özesmi et al, 2006).

A modelagem e prognose da produção florestal se enquadram na tarefa de aprendizagem de RNA denominada aproximação de funções. Esta tarefa consiste em treinar uma rede neural que aproxime a função desconhecida $f(x)$, que descreve o mapeamento dos pares de entrada-saída $\{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$ de um conjunto de n exemplos de treinamento (Jain et al., 1996; Haykin, 2001). O treinamento, também denominado de aprendizagem, consiste no ajuste dos parâmetros da rede a partir de dados de treinamento (exemplos) a fim de desempenhar uma determinada tarefa (Braga et al, 2000; Haykin, 2001).

Para realizar a aproximação de funções, existem três tipos de RNA: Linear (*Perceptron*), Perceptrons de múltiplas camadas (MLP – *Multilayer Perceptron*) e Redes de funções de base radial (RBF – *Radial Basis Function*). Todos os tipos possuem uma camada de entrada que não realiza processamento, apenas recebe as variáveis de entrada e as direcionam à próxima camada e uma camada de saída, ou seja, fornece a resposta final da rede. Uma rede Linear possui uma única camada de processamento, sendo conseqüentemente, a camada de saída. Uma rede MLP pode ter uma ou mais camadas intermediárias (entre as camadas de entrada e de saída), em que seus neurônios, geralmente, possuem funções de ativação de base sigmoidais. Enquanto que uma RBF possui apenas uma camada intermediária com funções de ativação de base radiais, por exemplo, a função gaussiana (Braga et al., 2000; Haykin, 2001).

O objetivo deste estudo foi modelar a produção volumétrica de povoamentos de clones de eucalipto em função de variáveis categóricas e numéricas e avaliar a exatidão da prognose empregando redes neurais artificiais.

2. MATERIAL E MÉTODOS

Descrição dos dados

Os dados utilizados foram provenientes de inventários florestais contínuos (IFC) conduzidos em povoamentos não desbastados de clones de eucalipto, localizados no sul da Bahia, em uma área de cerca de 2.000 hectares de floresta. As variáveis numéricas consideradas foram idade (meses), área basal (m^2ha^{-1}) e volume (m^3ha^{-1}) (Quadro 1). Sendo o volume com casca para celulose, até um diâmetro mínimo de 4 cm. Enquanto que as variáveis categóricas foram projeto (*P*), tipo de solo (*S*), relevo (*R*), textura (*T*), clone (*C*) e espaçamento (*E*). O número de classes dessas variáveis categóricas foi 4, 15, 3, 7, 9 e 6, respectivamente. O número de medições variou de 4 a 10, compreendendo 276 parcelas permanentes, com área média de 214 m^2 .

Quadro 1 – Análise descritiva das variáveis numéricas

Variável	Mínimo	Máximo	Média	Desvio padrão	Percentil 90
Área basal (m^2ha^{-1})	1,1	48,8	20,6	$\pm 5,9$	27,2
Idade (meses)	21	137	71	± 25	101
Volume (m^3ha^{-1})	12,1	1111,7	435,5	$\pm 189,6$	671,2

Os dados, englobando todas as medições disponíveis, foram divididos aleatoriamente em dois conjuntos, um para o treinamento das redes (226 parcelas) e outro para avaliar a generalização das redes treinadas (50 parcelas), com uma proporção de cerca de 80% dos dados para treinamento e 20% para generalização.

Os pontos que extrapolaram a tendência geral de cada clone, em área basal ou volume em função da idade, não foram eliminados a fim de verificar a capacidade das redes neurais artificiais em lidar com *outliers* ou ruídos.

Treinamento das redes neurais artificiais

O treinamento de uma RNA é o processo de ajuste de seus pesos através de um algoritmo de aprendizagem, que extrai características dos dados fornecidos e tem por objetivo gerar uma rede que desempenhe a tarefa de interesse.

Os dados foram organizados em dois tipos de estrutura: (A) informações dos inventários pareadas com amplitude de 12 meses, ou seja, IFC_1-IFC_2 , IFC_2-IFC_3 e assim sucessivamente; (B) informações dos inventários pareadas com diferentes intervalos de idade, ou seja, IFC_1-IFC_2 , IFC_1-IFC_3, \dots , IFC_2-IFC_3 , IFC_2-IFC_4 e assim sucessivamente.

Foram treinadas redes para projetar o volume e também para projetar a área basal, pois a área basal futura foi considerada como entrada das redes para projetar o volume. Foram treinadas 600 redes para projetar área basal: 100 Lineares (Perceptron), 100 Perceptrons de Múltiplas Camadas (MLP) e 100 Redes de Função de Bases Radial (RBF) para cada estrutura; e 600 redes para projetar volume. Destas foram pré-selecionadas 24 RNA (duas de cada tipo para cada estrutura para área basal e volume) com base na correlação entre observado e estimado.

A definição da arquitetura das redes, ou seja, número de neurônios por camada e número de camadas foi otimizada pela ferramenta *Intelligent Problem Solver* (IPS) do *software* Statistica 7 (Statsoft, INC, 2007). Diante do grande número de possíveis combinações das variáveis de entrada disponíveis foi solicitada a otimização desta seleção por algoritmos do IPS. As demais etapas do treinamento, como pré-processamento, o treinamento propriamente dito e o pós-processamento também foram realizadas pelo IPS.

Generalização das redes neurais artificiais

A generalização é a capacidade de uma rede neural produzir saídas adequadas para entradas que não estavam presentes durante o treinamento (aprendizagem).

Nesta etapa, foram utilizados dados de inventário de 50 parcelas permanentes não utilizados durante o treinamento.

A aplicação das redes treinadas aos dados da generalização foi feita pelo *software* Statistica 7.

Prognose da produção florestal

A prognose consistiu na aplicação das redes que apresentaram melhor resultado, em termos de exatidão, no treinamento e na generalização. Os dados do primeiro inventário (primeira medição das parcelas permanentes) das 50 parcelas separadas para a generalização foram utilizados para projeção da área basal e do volume. Nesta etapa também foi utilizado o *software* Statistica 7 para aplicação das redes.

Avaliação das estimativas geradas pelas redes neurais artificiais

A avaliação das estimativas geradas pelas redes neurais, nas três etapas, treinamento, generalização e prognose, foi feita empregando estatísticas e análise gráfica de resíduos. As estatísticas empregadas foram a correlação entre os valores estimados e observados, de área basal e volume, e a raiz do erro quadrado médio (RMSE%). A análise gráfica consistiu na inspeção estatística da dispersão dos erros (resíduos) percentuais em relação aos valores observados, sendo:

$$erro_{\%} = \frac{(\hat{Y} - Y)}{Y} \times 100$$

em que, Y é a saída observada nos inventários, \hat{Y} é a saída estimada pela RNA.

A correlação entre os valores observados e estimados ($r_{Y\hat{Y}}$) indica a força e a direção da relação entre as duas variáveis. Embora não permita inferir diretamente sobre igualdade entre valores observados e estimados (Campos e Leite, 2009), a correlação indica o grau de associação entre valores observados e estimados e, juntamente com a análise de resíduos, permite inferir sobre a qualidade da prognose ou estimação. Quanto mais próxima de 1, maior a correlação entre as variáveis, sendo:

$$r_{Y\hat{Y}} = \frac{cov(Y, \hat{Y})}{\sqrt{s^2(Y)s^2(\hat{Y})}}$$

Em que, s^2 é a variância e cov é a covariância.

A raiz do erro quadrado médio (RMSE) avalia a diferença quadrática média entre os valores observados e os valores estimados. Quanto menor o RMSE, melhor a precisão da estimativa (Mehtätalo et al., 2006), sendo:

$$RMSE(\%) = 100 \sqrt{\frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n}} / \bar{Y}$$

em que, \bar{Y} é a média da saída observada e n é o número total de dados.

3. RESULTADOS E DISCUSSÃO

Projeção da área basal

Nas 12 redes pré-selecionadas para projetar a área basal, em geral, todas as variáveis de entradas disponíveis, categóricas e numéricas, foram importantes e selecionadas pelo algoritmo de otimização (Tabela 1).

Tabela 1 – Características e precisão das redes neurais artificiais selecionadas pra projetar a área basal.

RNA	Tipo *	Arquitetura **	Entradas numéricas	Entradas categóricas	Treinamento		Generalização	
					$r_{\hat{y}}$	RMSE%	$r_{\hat{y}}$	RMSE%
1	Linear	38-1	I_1, I_2, B_1	P, S, R, T, E	0,9842	5,20	0,9825	4,92
2	Linear	47-1	I_1, I_2, B_1	P, S, R, T, C, E	0,9852	5,02	0,9820	4,97
3	MLP	20-1-1	I_1, B_1	R, C, E	0,9842	5,16	0,9835	4,78
4	MLP	12-2-1	I_2, B_1	P, E	0,9843	5,15	0,9828	4,85
5	RBF	41-197-1	I_1, I_2, B_1	P, S, R, T, C, E	0,9874	4,62	0,9734	6,08
6	RBF	41-131-1	I_1, I_2, B_1	P, S, R, T, C, E	0,9872	4,66	0,9800	5,24
7	Linear	38-1	I_1, I_2, B_1	P, S, R, T, E	0,8939	10,52	0,9540	9,88
8	Linear	47-1	I_1, I_2, B_1	P, S, R, T, C, E	0,9112	9,54	0,9559	8,90
9	MLP	34-3-1	I_1, I_2, B_1	S, T, C	0,9208	9,03	0,9357	9,83
10	MLP	32-2-1	I_1, I_2, B_1	P, R, T, C, E	0,9258	8,76	0,9519	8,88
11	RBF	44-383-1	I_1, I_2, B_1	P, S, T, C, E	0,9583	6,63	0,9170	10,56
12	RBF	44-380-1	I_1, I_2, B_1	P, S, T, C, E	0,9590	6,58	0,9478	8,59

* Tipo de RNA: Linear = Perceptron, MLP = *Multilayer Perceptron*, RBF = *Radial Basis Function*. ** Número de neurônios em cada camada. I_1 = idade atual, I_2 = idade futura, B_1 = área basal atual, P = projeto, S = tipo de solo, R = relevo, T = textura, C = clone, E = espaçamento.

A avaliação estatística das estimativas das redes, no treinamento e na generalização, mostrou que tanto pela correlação quanto pelo RMSE%, as redes da estru-

ra A (1 a 6) foram mais precisas do que as redes da estrutura B (7 a 12), com maior correlação e menor RMSE% (Tabela 1). A estrutura A foi superior à B devido ao fato de projetar a área basal com amplitude de idade menor e constante, ou seja, da atual para o próximo ano, enquanto que a estrutura B projeta a área basal com amplitudes de idade maiores e variáveis, pois projeta a área basal atual para os próximos nove anos.

Das redes da estrutura A, as redes 5 e 6 apresentaram melhor treino (maior correlação e menor RMSE%), porém pior generalização (maior RMSE%). Não é suficiente uma rede apenas bem treinada, pois uma boa generalização é essencial para a aplicação da mesma a novos dados. Assim, as redes 5 e 6 (duas RBFs), foram desconsideradas para projeção da área basal. Uma possível causa desse desempenho pode ser a ocorrência do sobre-treinamento, ou seja, a rede memoriza os dados de treinamento, suas características e ruídos, o que faz com que a função estimada "passe" pela maioria dos pontos de treinamento, gerando um "bom" treino. Entretanto, isto gera uma piora na capacidade de generalização da rede. (Braga et al., 2000). Segundo Bullinaria (2009), existem várias técnicas para evitar este problema, como parar o treinamento mais cedo (menos ciclos, interações e etc.) e adicionar ruídos aos padrões de treinamento, porém não foi objetivo deste estudo avaliá-las.

As demais redes da estrutura A, de 1 a 4, tiveram valores similares de correlação e RMSE% para o treino e generalização. A análise gráfica comprova essa similaridade de desempenho (Figura 1).

A prognose da área basal com as redes de 1 a 4 gerou projeções similares, porém a rede 3 mostrou-se superior às demais (Figura 1). Assim, a rede 3 foi utilizada para projetar a área basal, utilizada como entrada das redes para projetar o volume.

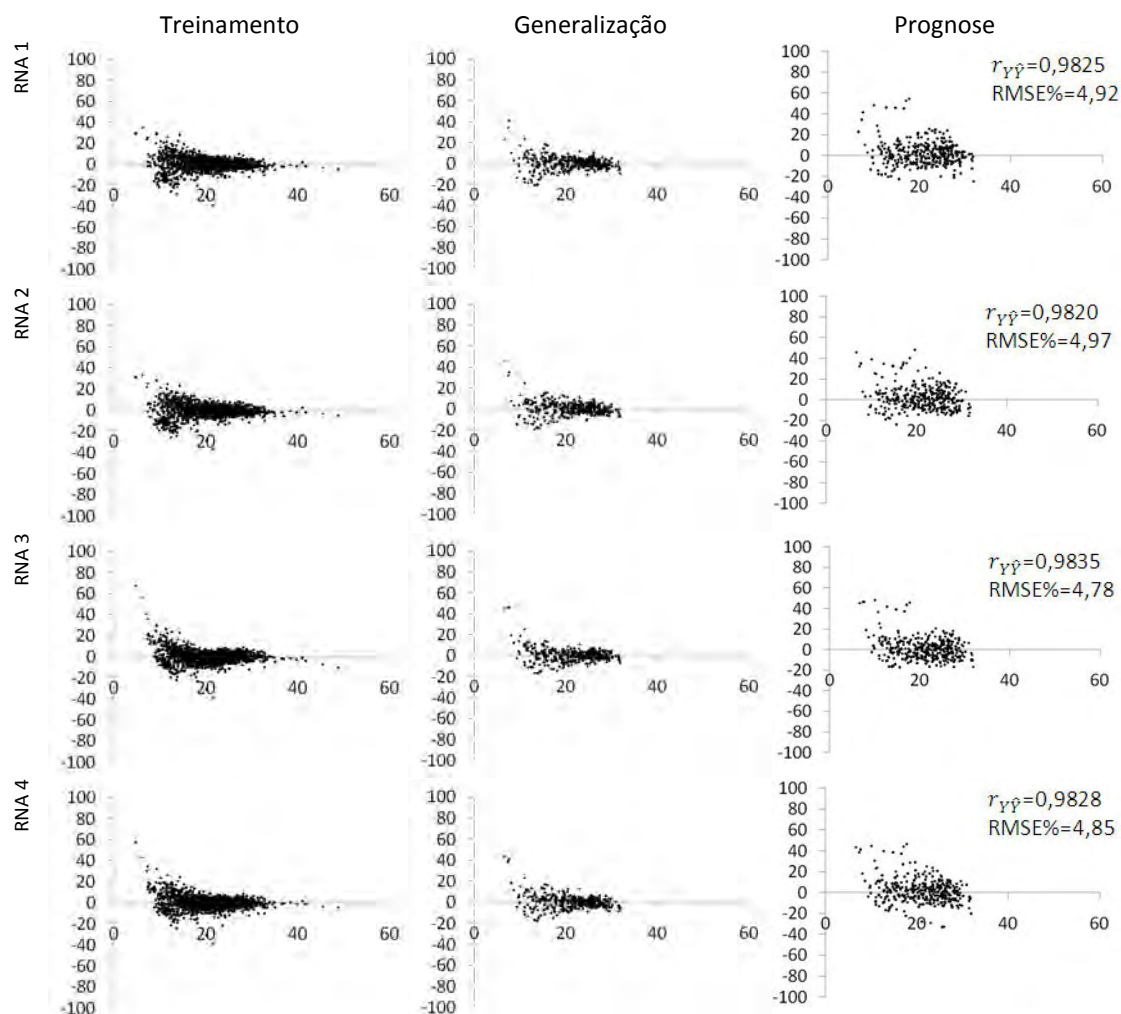


Figura 1 – Dispersão dos erros percentuais (eixo y) em relação aos valores observados de área basal (em m^2ha^{-1} , eixo x) no treinamento, generalização e prognose das redes de 1 a 4, respectivamente.

Projeção do volume

Nas 12 redes pré-selecionadas para projetar o volume, todas as variáveis de entradas disponíveis, categóricas e numéricas, foram importantes e selecionadas pelo algoritmo de otimização (Tabela 2). Dentre as variáveis categóricas, clone (C) foi predominante, sendo selecionada em todas as redes. Uma possível justificativa é que para estimar a produção volumétrica, o clone devido sua especificidade, representa as demais características ambientais, como tipo de solo, relevo, textura e prescrições como espaçamento. Dentre as variáveis numéricas, o volume inicial (V_I) e a área

basal futura (B_2) foram as variáveis predominantes devido a sua alta correlação com a produção volumétrica futura (V_2), 0,98 e 0,84.

Tabela 2 – Características e precisão das redes neurais artificiais selecionadas pra projetar o volume.

RNA	Tipo *	Arquitetura **	Entradas numéricas	Entradas categóricas	Treinamento		Generalização	
					$r_{\hat{Y}Y}$	RMSE%	$r_{\hat{Y}Y}$	RMSE%
13	Linear	49-1	I_1, I_2, B_1, V_1, B_2	P, S, R, T, C, E	0,9946	4,58	0,9942	4,48
14	Linear	48-1	I_1, B_1, V_1, B_2	P, S, R, T, C, E	0,9948	4,49	0,9944	4,44
15	MLP	12-2-1	B_1, V_1, B_2	C	0,9948	4,47	0,9946	4,34
16	MLP	13-2-1	I_1, B_1, V_1, B_2	C	0,9950	4,40	0,9950	4,16
17	RBF	11-133-1	V_1, B_2	C	0,9941	4,79	0,9918	5,40
18	RBF	26-133-1	V_1, B_2	S, C	0,9932	5,11	0,9923	5,14
19	Linear	48-1	I_2, B_1, V_1, B_2	P, S, R, T, C, E	0,9847	6,37	0,9862	7,66
20	Linear	49-1	I_1, I_2, B_1, V_1, B_2	P, S, R, T, C, E	0,9849	6,31	0,9865	7,43
21	MLP	26-3-1	I_2, B_2	S, C	0,9910	4,88	0,9872	6,63
22	MLP	44-3-1	I_1, I_2, V_1, B_2	S, R, T, C, E	0,9915	4,74	0,9887	6,39
23	RBF	43-966-1	I_1, I_2, B_1, V_1, B_2	P, S, R, T, C	0,9931	4,29	0,9637	11,71
24	RBF	43-738-1	I_1, I_2, B_1, V_1, B_2	P, S, R, T, C	0,9928	4,38	0,9787	8,62

* Tipo de RNA: Linear = Perceptron, MLP = *Multilayer Perceptron*, RBF = *Radial Basis Function*. ** Número de neurônios em cada camada. I_1 = idade atual, I_2 = idade futura, B_1 = área basal atual, B_2 = área basal futura, P = projeto, S = tipo de solo, R = relevo, T = textura, C = clone, E = espaçamento.

As redes treinadas a partir da estrutura B (19 a 24) forneceram generalizações inferiores às da estrutura A (13 a 18), com maiores valores de RMSE%. Na estrutura A, as redes apresentaram estimativas com precisão semelhante, tanto em correlação quanto em RMSE%, no treinamento e na generalização (Tabela 2 e Figura 2).

Na prognose da produção florestal, os dados do primeiro inventário florestal contínuo (IFC) juntamente com a área basal projetada pela RNA 3, foram utilizados pra projetar o volume. A rede 18 (RBF) foi superior às demais na prognose da produção, o que pode ser verificado pelo menor valor de RMSE% e maior correlação e também pela análise gráfica da dispersão dos erros percentuais (Figura 2).

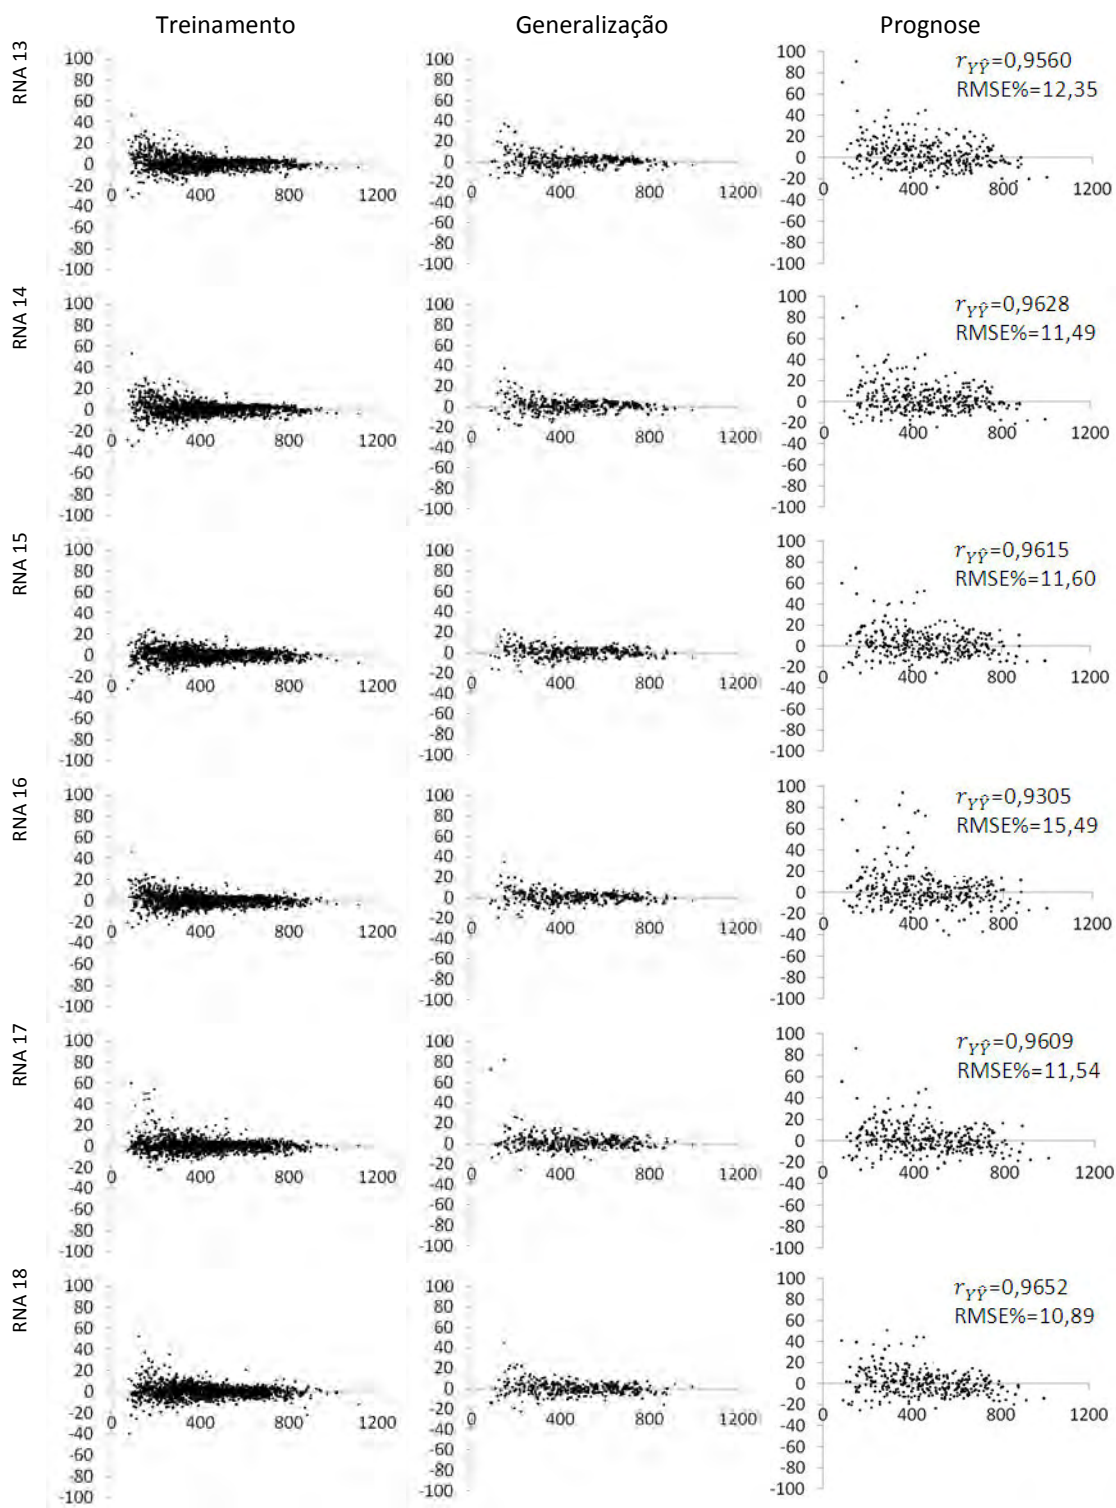


Figura 2 – Dispersão dos erros percentuais (eixo y) em relação aos valores observados de volume (em m^3ha^{-1} , eixo x) no treinamento, generalização e prognose das redes 13 a 18, respectivamente.

A prognose da produção volumétrica realizada pela rede 18 conseguiu modelar a tendência de crescimento de cada um dos oito clones presentes nas 50 parcelas permanentes selecionadas para a generalização (Figura 3). Apesar de considerar todos os clones, como classes da variável categórica, a rede possui um conjunto único de parâmetros para projetar o volume para todos os clones, ou seja, uma rede para modelar os oito clones ao invés de uma rede para cada clone, mostrando uma grande vantagem operacional em relação aos clássicos modelos de crescimento e produção.

Uma desvantagem observada nas redes neurais obtidas pela estrutura A foi a perda de precisão quando o intervalo de idades para projeção é maior que 12 meses, pois esta amplitude foi utilizada no treinamento das redes. Para aplicar as redes da estrutura A, por exemplo, para obter os volumes de 2010 e 2011 a partir do IFC de 2009, deve-se projetar as informações de 2009 para 2010, os valores obtidos servem de entrada da RNA para a projeção de 2010 para 2011. Assim, não é possível projetar para períodos maiores que 12 meses e garantir uma boa precisão das estimativas pelas redes obtidas pela estrutura A.

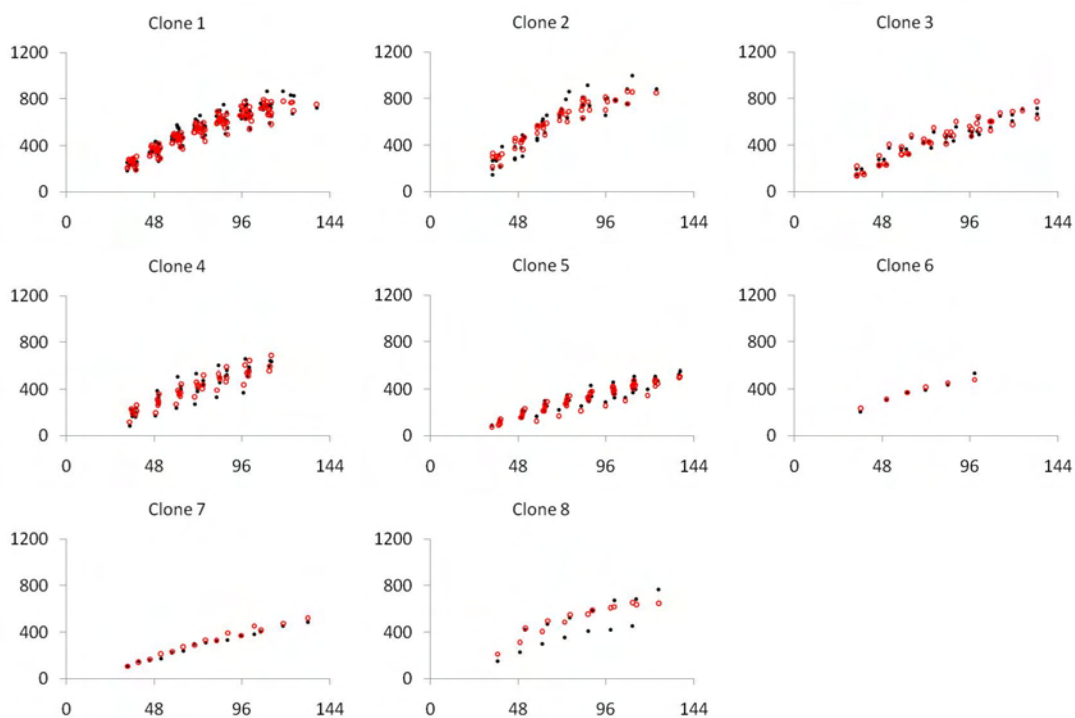


Figura 3 – Projeção da produção volumétrica, em m^3ha^{-1} (eixo y) a partir de informações do primeiro inventário (○), em função da idade em meses (eixo x), comparada com os dados observados (●).

Ao comparar as dispersões de resíduos (Figura 1 e 2) com resultados obtidos empregando modelos de crescimento e produção, ajustados para a mesma área de estudo, como Oliveira (2009), fica comprovado a eficiência das redes neurais para fins de prognose. Nessas figuras não foram observadas tendências.

Conforme os histogramas de frequência percentuais dos erros percentuais das estimativas das RNA (Figura 4 e 5), a maioria dos erros concentrou-se em $\pm 7,5\%$, no treinamento e na generalização e em $\pm 12,5\%$ na prognose. Considerando que estas estatísticas são em nível de parcela permanente pode-se inferir que os resultados da prognose com RNA foram altamente satisfatórios.

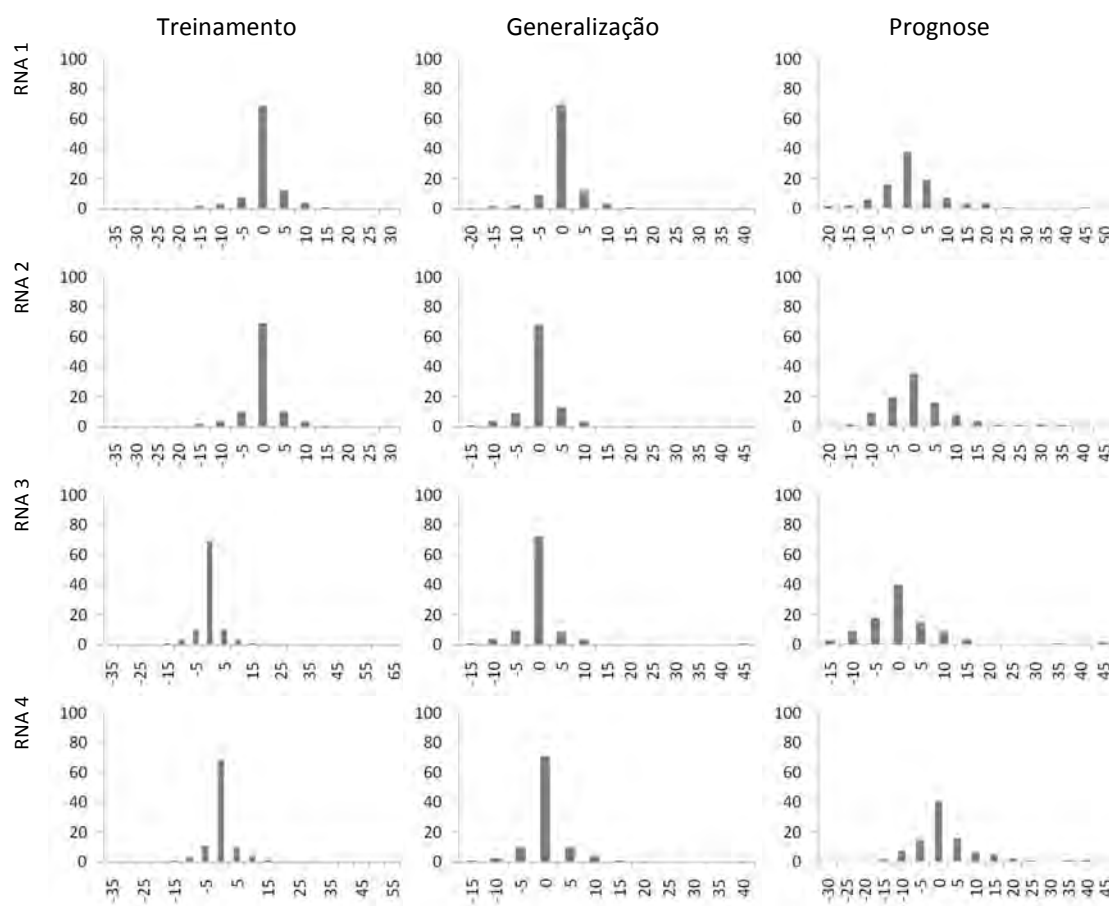


Figura 4 – Frequência percentual (eixo y) dos erros percentuais (eixo x) das estimativas das RNA para projeção da área basal, no treinamento, generalização e prognose das redes de 1 a 4, respectivamente.

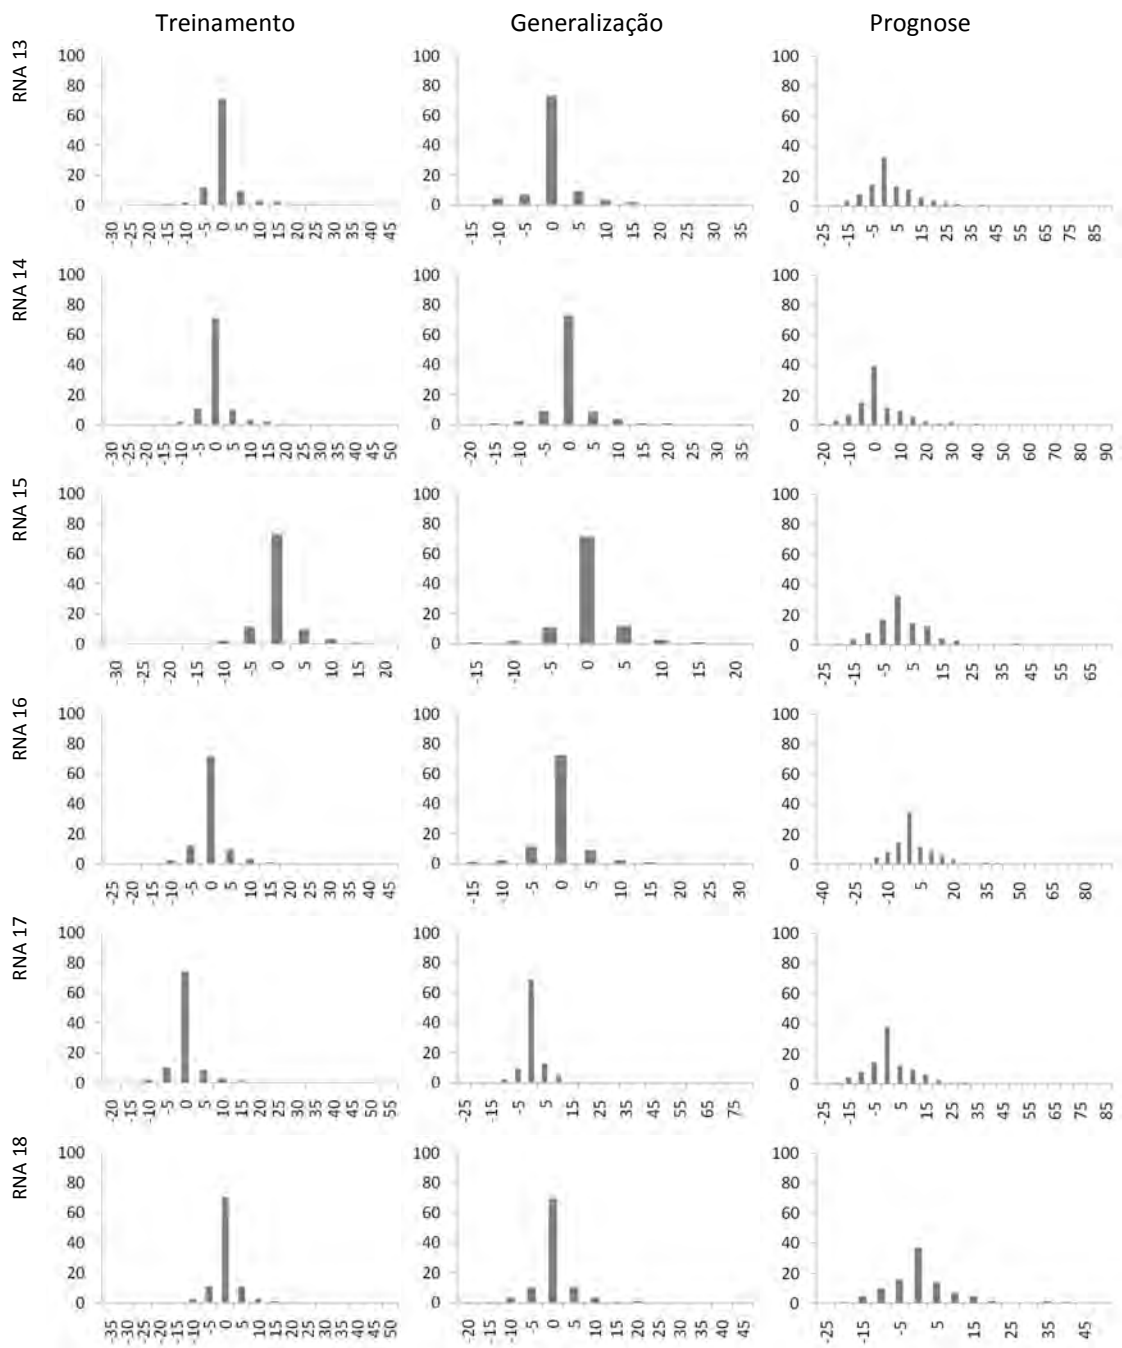


Figura 5 – Frequência percentual (eixo y) dos erros percentuais (eixo x) das estimativas das RNA para projeção do volume, no treinamento, generalização e prognose das redes de 13 a 18, respectivamente.

4. CONCLUSÕES

Tanto na projeção da área basal quanto na projeção do volume, observou-se que as redes neurais artificiais obtidas a partir da estrutura A, onde informações dos inventários foram pareadas com amplitude de 12 meses, são mais precisas que as redes obtidas da estrutura (B), onde as informações dos inventários foram pareadas com diferentes amplitudes.

Em geral, todas as variáveis, categóricas e numéricas, utilizadas como entradas das redes foram importantes. Sendo predominante, as variáveis clone, volume inicial e área basal futura, na projeção da produção volumétrica.

Redes neurais artificiais dos tipos Linear, MLP e RBF são capazes de desempenhar a tarefa de aproximação de funções para projeção da área basal e do volume em povoamentos de clones de eucalipto.

Redes neurais artificiais são capazes de realizar a prognose da produção volumétrica em nível de povoamento, comprovando o grande potencial da técnica para aplicações na área de mensuração e manejo florestal.

5. REFERÊNCIAS BIBLIOGRÁFICAS

BRAGA, A. de P.; CARVALHO, A. P. de L. F. de; LUDEMIR, T. B. **Redes Neurais Artificiais**: Teoria e Aplicações. 1 ed. Rio de Janeiro: LTC, 2000. 262 p.

BULLINARIA, J. A. **Introduction to Neural Computation**. Notas de aula. 2009. Disponível em: <<http://www.cs.bham.ac.uk/~jxb/inc.html>>. Acesso em: 20 de jun. 2009.

CAMPOS, J. C. C.; LEITE, H. G. **Mensuração florestal**: perguntas e respostas. 3. ed. rev. e ampl. Viçosa: UFV, 2009. 548 p.

CLUTTER, J.L. Compatible growth and yield for loblolly pine. **Forest Science**, v. 9, n. 3, p. 354-371, 1963.

HAYKIN, S. **Redes neurais**: princípios e prática. 2. ed. Porto Alegre: Bookman, 2001. 900 p.

JAIN, A. K.; MAO, J.; MOHIUDDIN, K. M. Artificial Neural Networks: A Tutorial. **Computer**, v. 29, n. 3, p. 31-44, 1996.

LEK, S.; DELACOSTE, M.; BARAN, P.; DIMOPOULOS, I.; LAUGA, J.; AULAGNIER, S. Application of neural networks to modelling nonlinear relationships in ecology. **Ecological Modelling**, v. 90, p. 39-52, 1996.

MEHTÄTALO, L.; MALTAMO, M.; KANGAS, A. The use of quantile trees in the prediction of the diameter distribution of a stand. **Silva Fennica**, v. 40, n. 3, p. 501-516, 2006.

OLDEN, J. D.; JACKSON, D. A. Illuminating the “black box”: a randomization approach for understanding variable contributions in artificial neural networks. **Ecological Modelling**, v. 154, p. 135-150, 2002.

ÖZESMI, S. L.; TAN, C. O.; ÖZESMI, U. Methodological issues in building, training, and testing artificial neural networks in ecological applications. **Ecological Modelling**, v. 195, p. 83-93, 2006.

OLIVEIRA, M. L. R. de; LEITE, H. G.; NOGUEIRA, G. S.; CAMPOS, J. C. C. Modelagem e prognose em povoamentos não desbastados de clones de eucalipto. **Revista Árvore**, v.33, n.5, p.841-852, 2009.

STATSOFT, INC. Statistica (data analysis software system), version 7. 2007. <www.statsoft.com>

VANCLAY, J.K. **Modelling forest growth and yield**. Wallingford, UK: CAB International, 1994. 312 p.

CAPÍTULO 3

PROGNOSE EM NÍVEL DE ÁRVORE INDIVIDUAL EMPREGANDO REDES NEURAS ARTIFICIAIS

1. INTRODUÇÃO

Os modelos de árvore individual (MAI) simulam o crescimento de cada árvore, em diâmetro, altura e copa, para obtenção do volume individual, além de estimar a sobrevivência das árvores. Posteriormente, as parcelas de inventário são totalizadas, a fim de obter volume, taxas de crescimento e outras características por unidade de área. Dessa forma, os MAI fornecem a melhor ferramenta para simular como as árvores no povoamento crescem sob diferentes prescrições de manejo. Representando um importante desenvolvimento na ciência florestal contemporânea (Davis et al., 2005).

Os MAI são geralmente constituídos por sub-modelos que modelam o crescimento em diâmetro, em altura e em volume, além de estimar a mortalidade regular. A incorporação de um modelo para estimar a mortalidade (ou sobrevivência) permite a simulação das produções e estruturas futuras do povoamento (Freire, 2002). Esta categoria de modelos pode ser dividida em duas abordagens: dependentes ou independentes da distância. O que as diferencia é a utilização de informação espacial das árvores, ou seja, a posição da árvore e o tamanho das árvores vizinhas no povoamento (Vanclay, 1994; Campos e Leite, 2009).

A metodologia tradicional utiliza-se de modelos de regressão para obter o crescimento em diâmetro e altura, e posteriormente o volume das árvores individuais.

Diversos trabalhos com MAI dependentes (Nyström e Kexi, 1997; Mabvurira e Mii-na, 2002; Fox et al., 2007) e independentes (Teck e Hilt, 1991; Freire, 2002; Uzoh e Oliver, 2008; Tahvanainen e Forss, 2008) da distância têm sido desenvolvidos, mostrando a importância e eficiência deste tipo de modelagem.

Uma das dificuldades para modelagem em nível de árvore, em povoamentos de clones de eucalipto, é que muitas vezes as bases de dados disponíveis não são apropriadas. Outra consideração importante é que nesse tipo de povoamento a mortalidade, até cerca de sete anos, é muitas vezes insignificante e, quando ocorre, incide em árvores dominadas que não resultaram em volume significativo quando do corte (Campos e Leite, 2009). Assim, o componente mortalidade ainda é um importante campo de pesquisa ao empregar MAI para povoamentos de clones de eucalipto. Embora este tipo de modelo não tenha sido utilizado em grande escala no Brasil, sua flexibilidade e nível de detalhamento, quando de sua aplicação, justificam a condução de pesquisas nesta área, especificamente para povoamentos equiâneos submetidos a desbaste.

Uma abordagem para modelagem em nível de árvore individual, diferente daquelas usuais, consiste no uso de redes neurais artificiais (RNA). Essas redes são sistemas computacionais paralelos constituídos por unidades de processamento simples, também denominadas neurônios artificiais ou nodos, conectadas entre si de uma maneira específica para desempenhar uma determinada tarefa. Os neurônios artificiais são modelos matemáticos simplificados dos neurônios biológicos. E processam as informações recebidas e ponderadas por pesos sinápticos fornecendo uma única resposta (Braga et al., 2000; Haykin, 2001; Bullinaria, 2009).

Neste estudo, a tarefa desejada é a aproximação de função, isto é, a rede neural deve aproximar-se à função desconhecida $f(x)$, que descreve o mapeamento dos pares de entrada(x)-saída(y) $\{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$ de um conjunto de n padrões de treinamento (exemplos). Para tal tarefa, existem três tipos de redes capazes de desempenhá-la: Linear, também conhecida como Perceptron de camada única, que consiste em uma camada de entrada e uma camada de saída; Perceptron de múltiplas camadas (*Multilayer Perceptron* – MLP) que possuem além da camada de entrada e de saída, uma ou mais camadas intermediárias (ou ocultas) que geralmente possuem funções de ativação sigmoidais e são treinadas pelo algoritmo de aprendizado *error back-propagation*; e as Redes de função de base radial (*Radial Basis Function* – RBF) que geralmente possuem três camadas e funções de ativação gaus-

sianas. A camada de entradas das redes apenas recebe as informações e transmite-as para a próxima camada, enquanto que as camadas intermediárias e de saída processam a informação (Jain et al., 1996; Haykin, 2001).

Guan e Gerter, no início da década de 90 (1991a), utilizaram redes neurais artificiais para modelar a mortalidade regular de árvores individuais. As redes foram mais eficientes do que o emprego da regressão logística, sendo consideradas pelos autores como um procedimento que resolve os problemas da estimação de parâmetros e da seleção do modelo, simultaneamente. No mesmo ano, os autores publicaram um trabalho em que utilizaram RNA para modelar a sobrevivência de árvores individuais. Neste trabalho, as redes ajustaram-se melhor aos dados do que o modelo estatístico empregado e apresentaram flexibilidade necessária para modelar a sobrevivência, para árvores pequenas e grandes e especialmente de crescimento lento (Guan e Gerter, 1991b). Em 1995, os mesmos publicaram um novo trabalho sobre o uso de RNA para modelar a probabilidade de sobrevivência das árvores individuais (Guan e Gerter, 1995), obtendo resultados satisfatórios.

Hasenauer e Merkl (2001) demonstraram uma aplicação de redes neurais para prever mortalidade de árvores individuais em modelos de crescimento e produção. Eles verificaram que as redes neurais tiveram desempenho melhor do que um modelo estatístico convencional de mortalidade com base na abordagem LOGIT.

Dessa forma, o componente mortalidade, em MAI, pode ser resolvido empregando RNA. Porém, em povoamentos com mortalidade insignificante, a eficiência das RNA para estimar crescimento de árvores individuais ainda não tinha sido objeto de estudo. Assim, o objetivo deste trabalho foi realizar a modelagem e a prognose do crescimento e da produção de povoamentos de clones de eucalipto, em nível de árvore individual, utilizando redes neurais artificiais, sem a inclusão do componente mortalidade.

2. MATERIAL E MÉTODOS

Descrição dos dados

Os dados utilizados neste estudo foram provenientes de inventários florestais contínuos (IFC) conduzidos em povoamentos de clones de eucalipto localizados no sul da Bahia. Apenas um clone foi utilizado no estudo, compreendendo 2.358 árvores em 113 parcelas permanentes, com o número de medições variando de cinco a dez.

As variáveis numéricas (quantitativas) consideradas foram: idade (meses), diâmetro com casca a 1,30 m do solo, em cm (*dap*), altura total, em m (*Ht*) e volume da árvore, em m³ (*V*) (Quadro 1). Enquanto que as variáveis categóricas (qualitativas) foram projeto (*P*), tipo de solo (*S*), relevo (*R*), textura (*T*) e espaçamento (*E*). O número de classes das variáveis categóricas foram 4, 11, 2, 6 e 5, respectivamente.

Quadro 1 – Análise descritiva das variáveis numéricas.

Variável	Mínimo	Máximo	Média	Desvio padrão
Idade (meses)	21	136	77	± 27
<i>dap</i> (cm)	4,7	26,7	15,6	± 4,1
Altura total (m)	7,4	37,0	23,4	± 5,6
Volume (m ³)	0,0456	1,5857	0,5450	± 0,2695

Os dados foram divididos aleatoriamente em dois conjuntos, um para o treinamento das redes neurais artificiais (1.824 árvores em 88 parcelas) e outro para avaliar a generalização das redes treinadas (534 árvores em 25 parcelas), com uma proporção de cerca de 80% dos dados para treinamento e 20% para generalização.

Este estudo enquadra-se na modelagem em nível de árvore individual do tipo independente da distância e não considera a mortalidade, por se tratar de dados de povoamento clonal, com mortalidade relativamente baixa (0 a 8,5 %).

Treinamento das redes neurais artificiais

O treinamento de uma RNA, também denominado aprendizagem, consiste no ajuste dos parâmetros da rede (pesos e bias) através de um algoritmo de aprendizagem. Neste processo os dados de treinamento (conjunto de exemplos) são apresentados a uma arquitetura pré-estabelecida, ou seja, um determinado arranjo de neurônio em camadas. E o algoritmo de treinamento extrai características a fim de representar a informação fornecida e desempenhar uma determinada tarefa.

Neste estudo, o treinamento se enquadra no tipo supervisionado, ou seja, a saída desejada é fornecida à rede que compara com a saída calculada, o erro (diferença entre saída desejada e calculada) é informado à rede que modifica seus parâmetros a fim de minimizar o erro global e encontrar uma solução.

Os dados de treinamento foram organizados na seguinte estrutura: as variáveis numéricas e categóricas dos inventários foram pareadas com amplitude média de 12 meses, ou seja, IFC₁-IFC₂, IFC₂-IFC₃ e assim sucessivamente. Esta estrutura foi utilizada para treinar as redes para projetar o *dap*, a altura total (*Ht*) e o volume, a partir de dados do inventário anterior. Assim, as projeções basearam-se nas seguintes relações funcionais:

$$dap_2 = f(P, S, R, T, E, dap_1, I_1, I_2)$$

$$Ht_2 = f(P, S, R, T, E, Ht_1, I_1, I_2)$$

$$V_2 = f(P, S, R, T, E, V_1, I_1, I_2)$$

em que, *P* é o projeto, *S* é o tipo de solo, *R* é o relevo, *T* é a textura do solo, *E* é o espaçamento da parcela na qual a árvore se encontra; *dap*₂, *Ht*₂ e *V*₂ são o *dap*, a altura total e o volume futuros da árvore, ou seja, no final dos próximos 12 meses, respectivamente; e *dap*₁, *Ht*₁ e *V*₁ são o *dap*, a altura total e o volume atuais da árvore, respectivamente e *I*₁ e *I*₂ são a idade atual e futura da árvore, respectivamente.

As projeções de *dap* e *Ht* obtidas pelas RNA foram utilizadas para o cálculo do volume das árvores, para tanto foram treinadas RNA para quantificar o volume, conforme a relação funcional:

$$V = f(P, S, R, T, E, dap, HT, I)$$

Foram treinadas 1.200 RNA: 300 para projetar o *dap* (100 Lineares, 100 MLPs e 100 RBFs para cada estrutura), 300 para projetar a *Ht*, 300 para projetar o volume e 300 para calcular o volume em função das variáveis: categóricas, idade, *dap* e *Ht* (essas duas últimas, projetadas). Destas foram selecionadas duas de cada tipo com base na correlação entre os valores estimados e observados, sendo, portanto, selecionadas 24 redes para o estudo.

A definição da arquitetura das redes, ou seja, número de neurônios por camada e número de camadas foi otimizada pela ferramenta *Intelligent Problem Solver* (IPS) do *software* Statistica 7 (Statsoft, INC, 2007). Diante do grande número de possíveis combinações das variáveis de entrada disponíveis foi solicitada a otimização desta seleção por algoritmos do IPS. As demais etapas do treinamento, como pré-processamento, o treinamento propriamente dito e o pós-processamento também foram realizadas pelo IPS.

Generalização das redes neurais artificiais

A generalização é a capacidade de uma rede neural produzir saídas adequadas para entradas que não estavam presentes durante o treinamento (aprendizagem). Nesta etapa, foram utilizados dados de 534 árvores distribuídas em 25 parcelas permanentes e não utilizadas durante o treinamento.

A estrutura dos dados de generalização foi semelhante à estrutura dos dados de treinamento. Assim, verificou-se a capacidade da rede em projetar o *dap*, a *Ht* e o volume, num intervalo de 12 meses. Também foi verificada a capacidade de generalização das redes treinadas para quantificar o volume.

A aplicação das redes treinadas aos dados da generalização foi feita pelo *software* Statistica 7.

Prognose da produção florestal

A prognose consistiu na aplicação das redes para projetar *dap*, *Ht* e volume (24 pré-selecionadas) nos dados do primeiro inventário das árvores separadas para a generalização. Posteriormente, a primeira projeção obtida serviu de entrada para a próxima projeção e assim sucessivamente, sempre com uma amplitude média de projeção de 12 meses.

Foram feitas projeções para os próximos nove anos a partir do primeiro inventário. Nesta etapa também foi utilizado o *software* Statistica 7 para aplicação das redes.

Avaliação das estimativas geradas pelas redes neurais artificiais

A avaliação das estimativas geradas pelas redes neurais, nas três etapas, treinamento, generalização e prognose, foi feita empregando estatísticas e análise gráfica de resíduos. As estatísticas empregadas foram a correlação entre os valores estimados e observados, de *dap*, *Ht* e volume, e a raiz do erro quadrado médio (RMSE%). A análise gráfica consistiu na inspeção estatística da dispersão dos erros (resíduos) percentuais em relação aos valores observados, sendo:

$$erro_{\%} = \frac{(\hat{Y} - Y)}{Y} \times 100$$

em que, Y é a saída observada nos inventários, \hat{Y} é a saída estimada pela RNA.

A correlação entre os valores observados e estimados ($r_{Y\hat{Y}}$) indica a força e a direção da relação entre as duas variáveis. Embora não permita inferir diretamente sobre igualdade entre valores observados e estimados (Campos e Leite, 2009), a correlação indica o grau de associação entre valores observados e estimados e, juntamente com a análise de resíduos, permite inferir sobre a qualidade da prognose ou estimação. Quanto mais próxima de 1, maior a correlação entre as variáveis. Sendo:

$$r_{Y\hat{Y}} = \frac{cov(Y, \hat{Y})}{\sqrt{s^2(Y)s^2(\hat{Y})}}$$

em que, Y é a saída observada nos inventários, \hat{Y} é a saída estimada pela RNA, s^2 é a variância e cov é a covariância.

A raiz do erro quadrado médio (RMSE) avalia a diferença quadrática média entre os valores observados e os valores estimados. Quanto menor o RMSE, melhor a precisão da estimativa (Mehtatalo et al., 2006), sendo:

$$RMSE(\%) = 100 \sqrt{\frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n}} / \bar{Y}$$

em que, \bar{Y} é a média da saída observada e n é o número total de dados.

3. RESULTADOS E DISCUSSÃO

Prognose da produção a partir da projeção do *dap* e da altura total

As características e estatísticas das redes neurais artificiais treinadas para projetar o *dap* e a altura total, bem como para quantificar o volume das árvores, são apresentadas na Tabela 1.

Nas redes para a projeção do *dap*, RNA de 1 a 6, todas as variáveis categóricas, ou seja, projeto, tipo de solo, relevo, textura e espaçamento, foram importantes, assim como todas as variáveis numéricas, idade atual, idade futura e *dap* atual, uma vez que foram freqüentemente selecionadas pelo algoritmo de seleção utilizado. As RNA do tipo RBF (5 e 6) tiveram melhor treinamento e também melhor desempenho na generalização, pois apresentaram mais valores de correlação e menores valores de RMSE%. Além destas, a RNA 3, uma MLP, teve o melhor desempenho na generalização e qualidade de treinamento próximo das RBFs. Neste caso, as redes 3, 5 e 6, foram selecionadas para projetar o *dap* a partir das informações do inventário inicial.

Tabela 1 – Características e estatísticas das Redes Neurais Artificiais selecionadas para projetar o *dap* (1 a 6), altura total (7 a 12) e quantificar o volume (13 a 18).

RNA	Tipo *	Arquitetura **	Entradas numéricas	Entradas categóricas	Treinamento		Generalização	
					$r_{Y\hat{Y}}$	RMSE%	$r_{Y\hat{Y}}$	RMSE%
1	Linear	30-1	I_1, dap_1, I_2	P, S, R, T, E	0,9872	3,66	0,9902	2,93
2	Linear	29-1	I_1, dap_1	P, S, R, T, E	0,9872	3,66	0,9900	2,96
3	MLP	24-3-1	I_1, dap_1, I_2	P, S, T	0,9927	2,77	0,9962	1,84
4	MLP	30-9-1	I_1, dap_1, I_2	P, S, R, T, E	0,9929	2,73	0,9823	4,13
5	RBF	30-493-1	I_1, dap_1, I_2	P, S, R, T, E	0,9934	2,63	0,9909	2,81
6	RBF	30-328-1	I_1, dap_1, I_2	P, S, R, T, E	0,9933	2,65	0,9917	2,71
7	Linear	30-1	I_1, Ht_1, I_2	P, S, R, T, E	0,9866	3,02	0,9903	2,63
8	Linear	29-1	I_1, Ht_1	P, S, R, T, E	0,9866	3,03	0,9904	2,67
9	MLP	24-5-1	I_1, Ht_1, I_2	P, S, R, E	0,9938	2,06	0,9952	1,80
10	MLP	25-6-1	I_1, Ht_1, I_2	P, S, R, T	0,9938	2,06	0,9744	3,78
11	RBF	30-371-1	I_1, Ht_1, I_2	P, S, R, T, E	0,9957	1,71	0,9912	2,15
12	RBF	30-373-1	I_1, Ht_1, I_2	P, S, R, T, E	0,9959	1,68	0,9894	2,47
13	Linear	29-1	dap, Ht	P, S, R, T, E	0,9806	11,22	0,9813	10,14
14	Linear	30-1	I, dap, Ht	P, S, R, T, E	0,9830	10,50	0,9791	11,98
15	MLP	28-1-1	dap, Ht	P, S, T, E	0,9999	0,72	0,9998	1,17
16	MLP	2-1-1	dap, Ht	-	0,9999	0,63	0,9998	1,22
17	RBF	28-823-1	dap, Ht	P, S, T, E	1,0000	0,56	0,9871	8,54
18	RBF	29-823-1	dap, Ht	P, S, R, T, E	1,0000	0,49	0,9865	8,90

* Tipo de RNA: Linear = Perceptron, MLP = *Multilayer Perceptron*, RBF = *Radial Basis Function*. ** Número de neurônios em cada camada. I_1 = idade atual, I_2 = idade futura, Ht_1 = altura total atual, dap_1 = *dap* atual, I = idade, Ht = altura total, P = projeto, S = tipo de solo, R = relevo, T = textura, E = espaçamento.

Para projetar da altura total, RNA de 7 a 12, todas as variáveis, categóricas e numéricas, também foram importantes. As RNA do tipo RBF tiveram melhor treino e generalização, além da RNA 9 (MLP) com generalização superior às demais, além do bom treinamento, sendo, portanto, estas redes selecionadas para a projeção da altura total das árvores.

Na projeção do crescimento em diâmetro (*dap*) pelas RNA, a rede 6 ($r_{Y\hat{Y}} = 0,9177$ e $RMSE\% = 8,40$) apresentou melhor desempenho do que as redes 3 ($r_{Y\hat{Y}} = 0,9149$ e $RMSE\% = 8,47$) e 5 ($r_{Y\hat{Y}} = 0,9110$ e $RMSE\% = 8,97$), além da dispersão dos resíduos ter sido mais homogênea. Na projeção do crescimento em altura total (*Ht*), a rede 11 foi selecionada por apresentar melhores resultados estatísticos, $r_{Y\hat{Y}} = 0,8714$ e $RMSE\% = 9,31$, e dispersão dos resíduos mais homogênea em torno do eixo das abscissas, as redes 9 ($r_{Y\hat{Y}} = 0,8409$ e $RMSE\% = 9,75$) e 10 ($r_{Y\hat{Y}} = 0,8022$ e $RMSE\% = 11,09$) forem inferiores (Figura 1). Assim, as RNA 6 e 11, ambas do tipo RBF, foram selecionadas para a projeção do *dap* e da altura total, respectivamente.

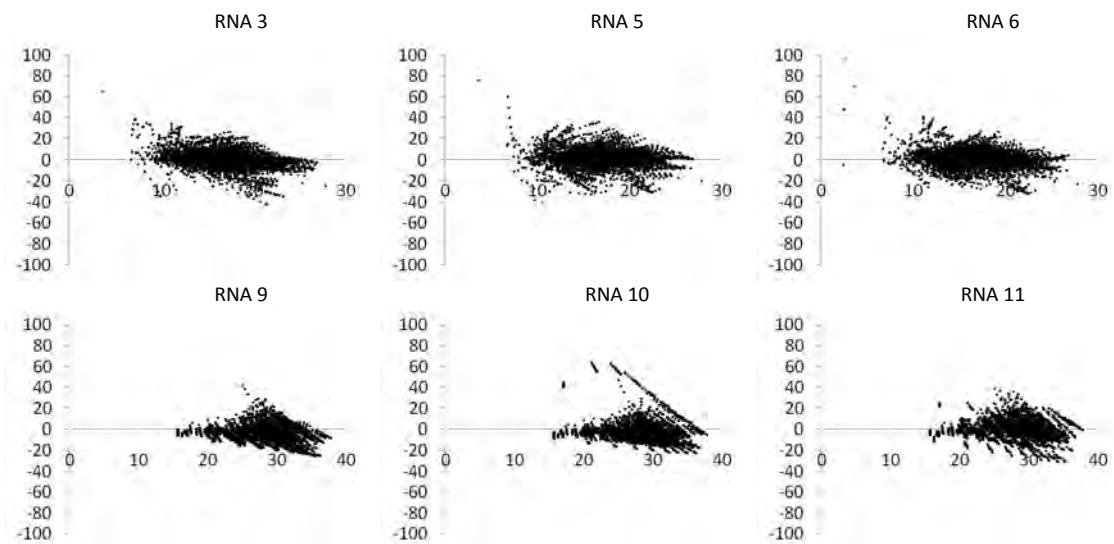


Figura 1 – Dispersão dos erros percentuais (eixo y) das projeções das RNA para *dap* (RNA 3, 5 e 6) e altura total (RNA 9, 10 e 11) em função dos valores observados (eixo x).

Dentre as redes para quantificar o volume das árvores em função do *dap*, da *Ht*, da idade e das variáveis categóricas, as redes do tipo MLP e RBF forem superiores no treinamento, porém o bom desempenho na generalização manteve-se apenas nas MLPs. Destas, a RNA 16 calcula o volume apenas em função do *dap* e da *Ht*, sem fazer estratificação entre as árvores em termos de projeto, tipo de solo, relevo, textura ou espaçamento, ou seja, o algoritmo de seleção das variáveis de entrada, não selecionou nenhuma variável categórica para esta arquitetura com seus respectivos parâmetros. No cálculo do volume das árvores, a partir dos valores de *dap* e *Ht* projetados do primeiro IFC, a melhor rede foi a RNA 18 (RBF), conforme as estatísticas e a dispersão dos erros percentuais das estimativas de volume por unidade de área, após totalizar as parcelas (Figura 2).

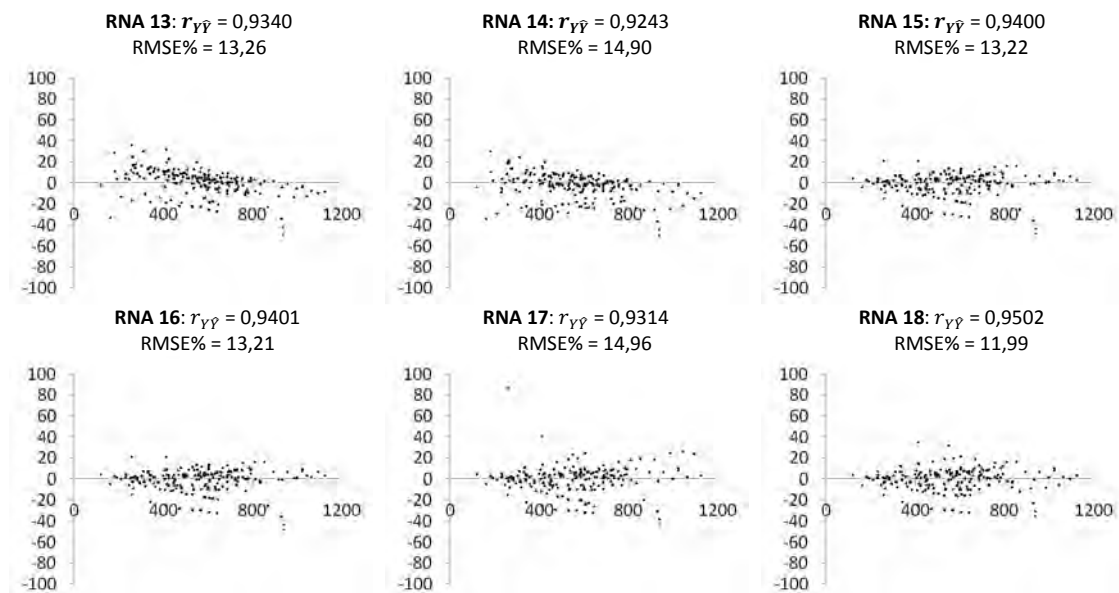


Figura 2 – Estatísticas e dispersão dos erros percentuais (eixo y) das estimativas das RNA para quantificar o volume em função do *dap* e *Ht* projetados a partir do primeiro inventário, em relação ao volume observado (m^3ha^{-1} , eixo x).

As dispersões observadas nas Figuras 1 e 2 podem ser consideradas como satisfatórias quando comparadas, por exemplo, como resultados divulgados por Campos e Leite (2009).

Prognose da produção a partir da projeção do volume inicial

No treinamento das redes para a projeção dos volumes individuais das árvores, em geral, todas as variáveis categóricas e numéricas foram importantes e selecionadas pelo algoritmo de otimização. As redes do tipo RBF apresentaram melhor treinamento, porém pior generalização, as Lineares com desempenho médio em comparação com as demais (pior treinamento e generalização média) e as MLPs apresentaram um bom treinamento e a melhor generalização (Tabela 2).

Tabela 2 – Características e estatísticas das Redes Neurais Artificiais selecionadas para projetar o volume futuro em função do volume atual.

RNA	Tipo *	Arquitetura **	Entradas numéricas	Entradas categóricas	Treinamento		Generalização	
					$r_{\hat{Y}Y}$	RMSE%	$r_{\hat{Y}Y}$	RMSE%
19	Linear	29-1	I_1, V_1	P, S, R, T, E	0,9928	5,92	0,9953	4,29
20	Linear	30-1	I_1, V_1, I_2	P, S, R, T, E	0,9929	5,87	0,9954	4,28
21	MLP	30-4-1	I_1, V_1, I_2	P, S, R, T, E	0,9938	5,51	0,9957	4,14
22	MLP	11-6-1	I_1, V_1	P, E	0,9954	4,72	0,9972	3,37
23	RBF	30-771-1	I_1, V_1, I_2	P, S, R, T, E	0,9975	3,46	0,7378	40,80
24	RBF	30-771-1	I_1, V_1, I_2	P, S, R, T, E	0,9975	3,47	0,9655	11,97

* Tipo de RNA: Linear = Perceptron, MLP = *Multilayer Perceptron*, RBF = *Radial Basis Function*. ** Número de neurônios em cada camada. I_1 = idade atual, I_2 = idade futura, V_1 = volume atual, P = projeto, S = tipo de solo, R = relevo, T = textura, E = espaçamento.

Na projeção do volume das árvores do primeiro inventário, as melhores estimativas foram obtidas pelas RNA do tipo MLP, as redes Lineares apresentaram tendência de superestimação, enquanto que as RBFs tiveram um desempenho bastante inferior às demais, com baixa precisão. Dentre as MLP, a RNA 22 foi a que melhor projetou o volume das árvores individuais, conforme as estatísticas e a dispersão dos erros percentuais das estimativas da produção volumétrica por unidade de área (há), após totalizar as parcelas dos inventários (Figura 3).

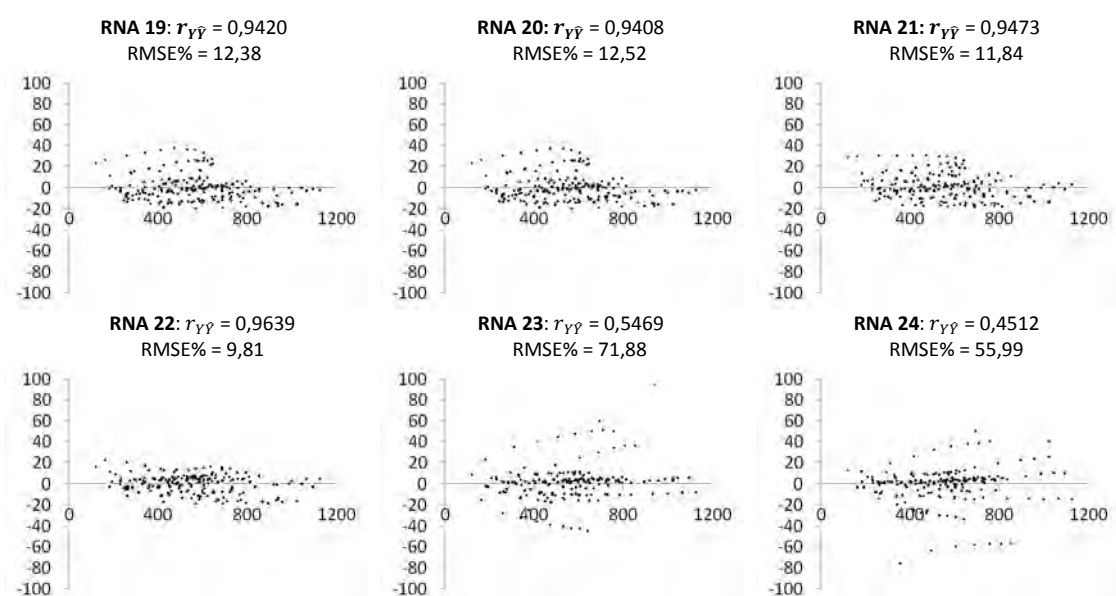


Figura 3 – Estatísticas e dispersão dos erros percentuais (eixo y) das estimativas das RNA para projetar o volume futuro em função do volume inicial do primeiro inventário, em relação ao volume observado (m^3ha^{-1} , eixo x).

Observou-se que em ambas as situações, volume futuro obtido pela projeção do *dap* e *Ht* e volume futuro obtido em função do volume atual, foi possível obter

boas estimativas a partir de informação a nível de árvores individuais. Pela análise estatística e gráfica, a estimativa do volume pela relação funcional $V_2 = f(P, S, R, T, E, V_1, I_1, I_2)$, foi superior com a RNA 22 (MLP), porém a estimativa pela relação funcional $V = f(P, S, R, T, E, dap, Ht, I)$, com *dap* e *Ht* projetados, também proporcionou resultados satisfatórios, através da RNA 18 (RBF) (Figuras 2, 3 e 4) . Assim, o manejador florestal, poderia optar por qualquer uma das abordagens, porém a prognose pela relação funcional $V_2 = f(P, S, R, T, E, V_1, I_1, I_2)$ é operacionalmente mais prática e viável.




Figura 4 – Projeção da produção volumétrica (m^3ha^{-1} , eixo y) a partir de informações do primeiro inventário (\circ) em função da idade (meses, eixo x) comparada com os dados observados (\bullet).

As variáveis categóricas foram importantes nas estimativas das RNA, como forma de estratificação das árvores no povoamento florestal. Sendo esta, uma grande vantagem das RNA, pois permitem a modelagem de variáveis qualitativas, além das variáveis numéricas.

A maioria dos erros percentuais concentrou-se em $\pm 12,5\%$ na projeção do *dap*, da *Ht*, na quantificação do volume e na projeção do volume (Figura 5). Considerando que estas estatísticas são em nível de parcela permanente pode-se inferir que os resultados da prognose com RNA foram altamente satisfatórios.

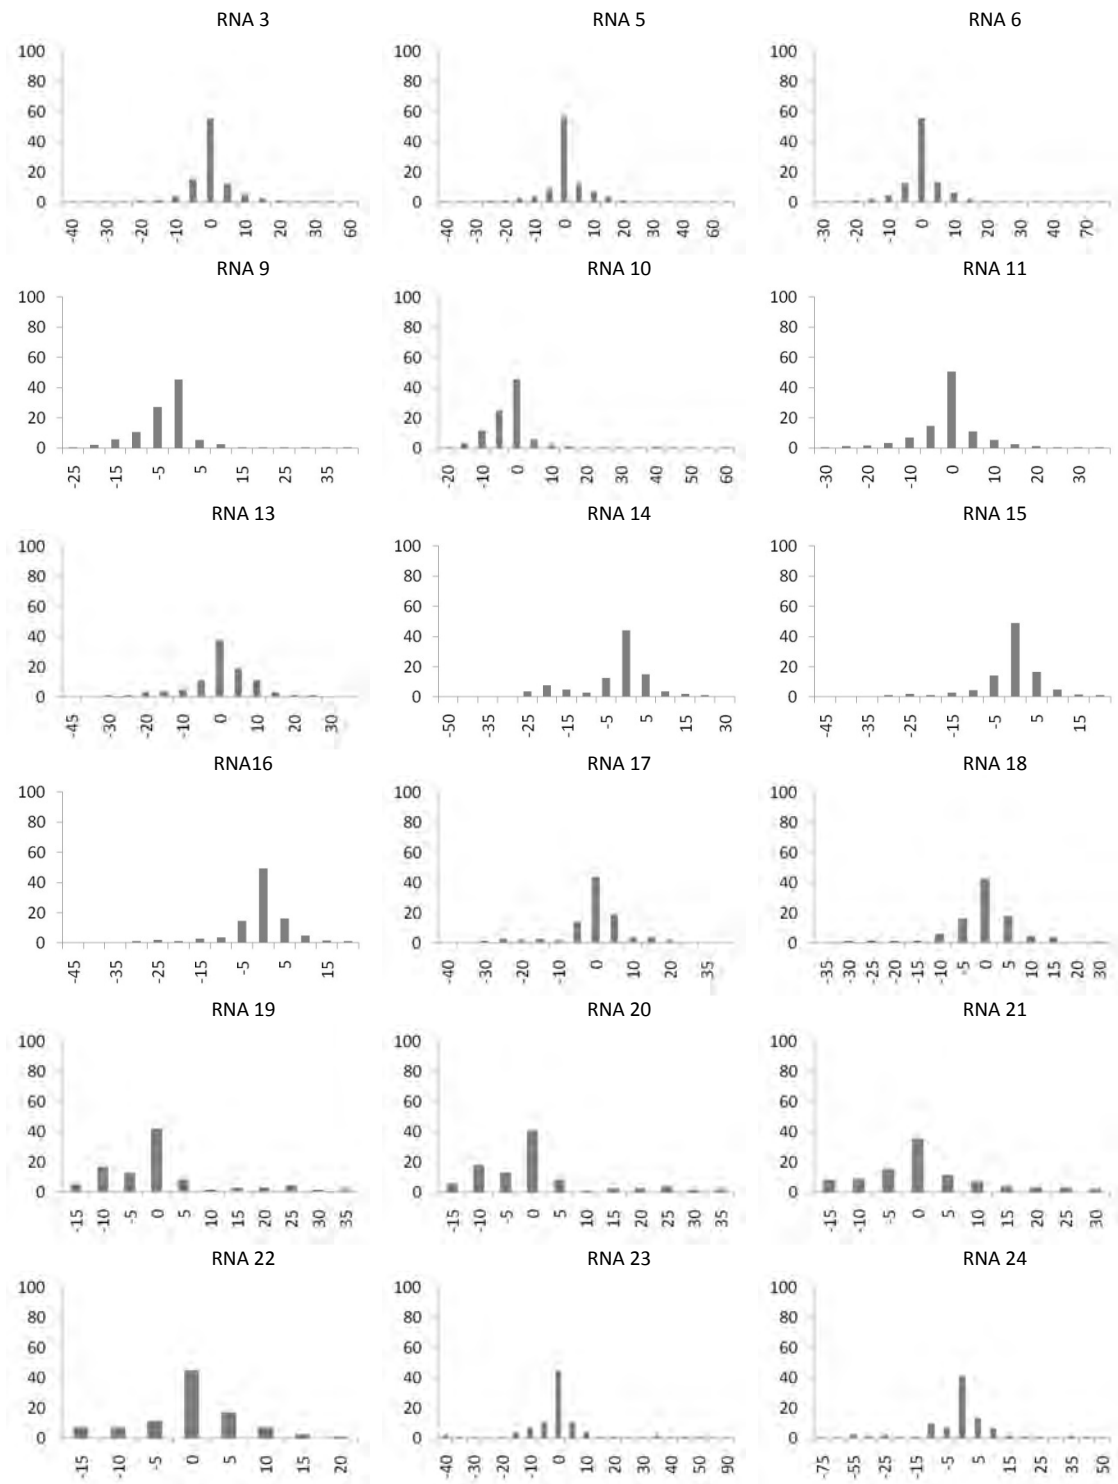


Figura 5 – Frequência percentual (eixo y) dos erros percentuais (eixo x) das estimativas das RNA, na projeção do *dap* (RNA 3, 5 e 6), da *Ht* (RNA 9, 10 e 11), na quantificação do volume (RNA de 13 a 18) e na projeção do volume (RNA de 19 a 24).

4. CONCLUSÕES

A modelagem do crescimento de árvores em povoamentos de clones de eucalipto pode ser feita empregando redes neurais artificiais, seja pela projeção do diâmetro e da altura das árvores, ou pela projeção direta dos volumes individuais.

As redes neurais artificiais dos tipos Perceptrons de Múltiplas Camadas (MLPs) e Redes de Função de Base Radial (RBF) são eficientes para modelagem do crescimento de árvores em povoamentos de clones de eucalipto e prognose da produção por hectare.

Os resultados obtidos neste estudo comprovam o potencial das redes neurais artificiais para modelagem do crescimento e produção, em nível de árvores individuais.

5. REFERÊNCIAS BIBLIOGRÁFICAS

BRAGA, A. de P.; CARVALHO, A. P. de L. F. de; LUDEMIR, T. B. **Redes Neurais Artificiais**: Teoria e Aplicações. 1 ed. Rio de Janeiro: LTC, 2000. 262 p.

BULLINARIA, J. A. **Introduction to Neural Computation**. Notas de aula. 2009. Disponível em: <<http://www.cs.bham.ac.uk/~jxb/inc.html>>. Acesso em: 20 de jun. 2009.

CAMPOS, J. C. C.; LEITE, H. G. **Mensuração florestal**: perguntas e respostas. 3. ed. rev. e ampl. Viçosa: UFV, 2009. 548 p.

DAVIS, L. S.; JOHNSON, K. N.; BETTINGER, P.; HOWARD, T. E. **Forest Management**: To sustain ecological, economic, and social values. 4 ed. 2005.

FOX, J. C.; BI, H.; ADES, P. K. Spatial dependence and individual-tree growth models I. Characterising spatial dependence. **Forest Ecology and Management**, v. 245, p. 10-19, 2007.

FREIRE, J. P. A. **Modelação do crescimento da árvore individual independente da distância para a *Pinus pinaster* Aiton**. em Portugal. 2002. 115 f. Dissertação (Mestrado em Silvicultura de Espécies de Crescimento Rápido) - Universidade Técnica de Lisboa, Lisboa, Portugal, 2002.

GUAN, B. T.; GERTNER, G. Using a parallel distributed processing system to model individual tree mortality. **Forest Science**, v. 37, n. 3, p. 871-885, 1991a.

GUAN, B. T.; GERTNER, G. Modeling red pine tree survival with an artificial neural network. **Forest Science**, v. 37, n. 5, p. 1429-1440, 1991b.

GUAN, B. T.; GERTNER, G. Modeling individual tree survival probability with a random optimization procedure: An artificial neural network approach. **Artificial Intelligence Application**, v. 9, n.2, p. 39-52, 1995.

HASENAUER, H.; MERKL, D.; WEINGARTNER, M. Estimating tree mortality of Norway spruce stands with neural networks. **Advances in Environmental Research**, v. 5, n. 4, p. 405-414, 2001.

HAYKIN, S. **Redes neurais: princípios e prática**. 2. ed. Porto Alegre: Bookman, 2001. 900 p.

JAIN, A. K.; MAO, J.; MOHIUDDIN, K. M. Artificial Neural Networks: A Tutorial. **Computer**, v. 29, n. 3, p. 31-44, 1996.

MABVURIRA, D.; MIINA, J. Individual-tree growth and mortality models for *Eucalyptus grandis* (Hill) Maiden plantations in Zimbabwe. **Forest Ecology and Management**, v. 161, p. 231-245, 2002.

MEHTÄTALO, L.; MALTAMO, M.; KANGAS, A. The use of quantile trees in the prediction of the diameter distribution of a stand. **Silva Fennica**, v. 40, n. 3, p. 501-516, 2006.

NYSTRÖM, K.; KEXI, M. Individual tree basal area growth models for Young stands of Norway spruce in Sweden. **Forest Ecology and Management**, v. 97, p. 173-185, 1997.

STATSOFT, INC. Statistica (data analysis software system), version 7. 2007. <www.statsoft.com>

TAHVANAINEN, T.; FORSS, E. Individual tree models for the crown biomass distribution of Scots pine, Norway spruce and birch in Finland. **Forest Ecology and Management**, v. 255, p. 455-467, 2008.

TECK, R. M.; HILT, D. E. **Individual tree diameter growth model for the Northeastern United States**. Research Paper NE-649. United States Department of Agriculture, Forest Service, Northeastern Forest Experiment Station, 1991, 11 p.

UZOH, F. C. C.; OLIVER, W. W. Individual tree diameter increment model for managed even-aged stands of ponderosa pine throughout the western United States using a multilevel linear mixed effects model. **Forest Ecology and Management**, v. 256, p. 438-445, 2008.

VANCLAY, J.K. **Modelling forest growth and yield**. Wallingford, UK: CAB International, 1994. 312 p.

CONCLUSÕES GERAIS

Variáveis categóricas são importantes na estratificação dos dados de inventário, auxiliando a extração de características e a solução do problema tratado pelas redes neurais artificiais.

Redes neurais artificiais dos tipos Perceptron (Linear), MLP e RBF são capazes de desempenhar a tarefa de aproximação de funções para projeção da área basal, do volume por unidade de área, do diâmetro, da altura total e dos volumes das árvores individuais de povoamentos de clones de eucalipto.

Redes neurais artificiais são capazes de realizar a modelagem do crescimento e a prognose da produção volumétrica em nível de povoamento e de árvore individual, comprovando o grande potencial da técnica para aplicações na área de mensuração e manejo florestal.