



UNIVERSIDADE FEDERAL DO ESPÍRITO SANTO
CENTRO DE CIÊNCIAS AGRÁRIAS
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS FLORESTAIS

GIOVANNI CORREIA VIEIRA

**PROGNOSE DO DIÂMETRO E DA ALTURA DE ÁRVORES INDIVIDUAIS
UTILIZANDO INTELIGÊNCIA ARTIFICIAL**

JERÔNIMO MONTEIRO – ES

FEVEREIRO – 2015

GIOVANNI CORREIA VIEIRA

**PROGNOSE DO DIÂMETRO E DA ALTURA DE ÁRVORES INDIVIDUAIS
UTILIZANDO INTELIGÊNCIA ARTIFICIAL**

Dissertação apresentada ao Programa de Pós-Graduação em Ciências Florestais do Centro de Ciências Agrárias da Universidade Federal do Espírito Santo, como parte das exigências para obtenção do Título de Mestre em Ciências Florestais, na Área de Concentração Ciências Florestais. Orientador: Adriano Ribeiro de Mendonça. Coorientadores: Gilson Fernandes da Silva e Sidney Sára Zanetti.

JERÔNIMO MONTEIRO – ES

FEVEREIRO – 2015

Dados Internacionais de Catalogação-na-publicação (CIP)
(Biblioteca Setorial de Ciências Agrárias, Universidade Federal do Espírito Santo, ES, Brasil)

657p \ Vieira, Giovanni Correia, 1985-
Prognose do diâmetro e da altura de árvores individuais
utilizando inteligência artificial / Giovanni Correia Vieira. – 2015.
52 f. : il.

Orientador: Adriano Ribeiro de Mendonça.
Coorientadores: Gilson Fernandes da Silva; Sidney Sára Zanetti.
Dissertação (Mestrado em Ciências Florestais) – Universidade
Federal do Espírito Santo, Centro de Ciências Agrárias.

1. Redes neurais artificiais. 2. Sistemas neuro-fuzzy. 3. Manejo
florestal. 4. Mensuração florestal. 5. Árvores - Crescimento. I.
Mendonça, Adriano Ribeiro de. II. Silva, Gilson Fernandes da. III.
Zanetti, Sidney Sára. IV. Universidade Federal do Espírito Santo. Centro
de Ciências Agrárias. V. Título.

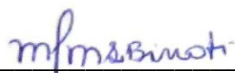
CDU: 630

PROGNOSE DO DIÂMETRO E DA ALTURA DE ÁRVORES INDIVIDUAIS UTILIZANDO INTELIGÊNCIA ARTIFICIAL

GIOVANNI CORREIA VIEIRA

Dissertação apresentada ao Programa de Pós-Graduação em Ciências Florestais do Centro de Ciências Agrárias da Universidade Federal do Espírito Santo, como parte das exigências para obtenção do Título de Mestre em Ciências Florestais, na Área de Concentração Ciências Florestais. Orientador: Adriano Ribeiro de Mendonça. Coorientadores: Gilson Fernandes da Silva e Sidney Sára Zanetti.

Aprovada em 23 de fevereiro de 2015.



Prof. Dra. Mayra Luiza Marques da Silva Binoti - UFES
Examinadora externa



Prof. Dr. José Franklin Chichorro - UFES
Examinador interno



Prof. Dr. Gilson Fernandes da Silva - UFES
Coorientador



Prof. Dr. Sidney Sára Zanetti - UFES
Coorientador



Prof. Dr. Adriano Ribeiro de Mendonça - UFES
Orientador

AGRADECIMENTOS

À Universidade Federal do Espírito Santo, pela oportunidade de estudo;

À Fundação de Amparo à Pesquisa do Espírito Santo, pela concessão da bolsa de estudos;

Ao Prof. Dr. Adriano Ribeiro de Mendonça, pela orientação, sugestões e amizade;

Aos coorientadores Prof. Dr. Gilson Fernandes da Silva e Prof. Dr. Sidney Sára Zanetti, pelas importantes considerações e sugestões;

Aos membros da Comissão Examinadora, Prof. Dr^a. Mayra Luiza Marques da Silva Binoti e Prof. Dr. José Franklim Chichorro, pelas relevantes contribuições para esta dissertação;

Ao Clayton Fraga, pela ajuda na análise de consistência da base de dados;

Aos amigos do Laboratório de Manejo e Mensuração Florestal: Evandro Silva, Diego Armando, Jeangelis Santos, Bráulio Pizzolo, Tharcia Batista, Luciana Lorenzoni, Janiel Cerqueira, Taise Aozane, pela amizade, ajuda e boa convivência neste período;

À minha família pelo apoio e incentivo.

SUMÁRIO

1. INTRODUÇÃO	8
2. OBJETIVO GERAL	10
2.1. OBJETIVOS ESPECÍFICOS	10
3. REVISÃO DE LITERATURA	11
3.1. MODELOS DE CRESCIMENTO E PRODUÇÃO FLORESTAL	11
3.2. REDES NEURAS ARTIFICIAIS	14
3.3 SISTEMAS FUZZY.....	20
3.4. SISTEMAS NEURO-FUZZY.....	23
4. METODOLOGIA.....	26
4.1. DESCRIÇÃO DA ÁREA E COLETA DOS DADOS	26
4.2. CLASSIFICAÇÃO DE SÍTIO	27
4.3. ÍNDICES DE COMPETIÇÃO.....	27
4.4. REDES NEURAS ARTIFICIAIS	29
4.5. SISTEMA <i>NEURO-FUZZY</i>	30
4.6. AVALIAÇÃO DO AJUSTE E VALIDAÇÃO DOS MODELOS DE CRESCIMENTO EM NÍVEL DE ÁRVORE INDIVIDUAL	31
5. RESULTADOS E DISCUSSÃO.....	33
5.1. CLASSIFICAÇÃO DO SÍTIO	33
5.2. ÍNDICES DE COMPETIÇÃO.....	33
5.3. CRESCIMENTO EM DAP E ALTURA TOTAL	36
5.3.1. Redes neurais artificiais para estimar o crescimento em DAP e altura total.....	36
5.3.2. Sistema <i>Neuro-fuzzy</i> para estimar o crescimento em DAP e altura total.....	42
6. CONCLUSÕES	45
7. REFERÊNCIAS BIBLIOGRÁFICAS	46

RESUMO

VIEIRA, Giovanni Correia, **Prognose do diâmetro e da altura de árvores individuais utilizando inteligência artificial**. 2015. Dissertação (Mestrado em Ciências Florestais) – Universidade Federal do Espírito Santo, Jerônimo Monteiro. Orientador: Prof. Dr. Adriano Ribeiro de Mendonça. Coorientadores: Prof. Dr. Gilson Fernandes da Silva; Prof. Dr. Sidney Sára Zanetti.

Os modelos de árvores individuais são compostos por submodelos que estimam, geralmente, a competição, a mortalidade e o crescimento em diâmetro e altura de cada árvore. São usualmente adotados quando se deseja o melhor detalhamento da informação para estimar multiprodutos da floresta. Nesses modelos, as estimativas do crescimento em diâmetro a 1,30 m do solo (DAP) e a altura total (H) é obtida por meio de análise de regressão. Recentemente, técnicas de inteligência artificial estão sendo utilizadas com bom desempenho na mensuração florestal. Portanto, o objetivo desse trabalho foi avaliar o desempenho de técnicas de inteligência artificial (redes neurais artificiais e sistemas *neuro-fuzzy*) para estimar o crescimento em DAP e altura de árvores de eucalipto. Utilizou-se dados de inventários florestais contínuos de eucalipto, com medições anuais de DAP, altura total das 15 primeiras árvores da parcela e altura dominante, de acordo com o conceito de Assmann (1970), de 398 parcelas. O banco de dados foi dividido em 70% das parcelas para o treinamento das redes neurais artificiais e do sistema *neuro-fuzzy*; 15% das parcelas para a validação cruzada; e 15% das parcelas para validação dos sistemas. Com base nos resultados, notou-se que o índice de competição independente da distância 5 – IID₅, proposto por Glover; Hool (1979), foi o que teve a maior correlação com as variáveis idade, crescimento em DAP e altura. Observou-se que as técnicas de inteligência artificial apresentaram boa precisão na estimativa do crescimento em DAP e altura total. As duas técnicas abordadas podem ser utilizadas para a prognose do DAP e altura total.

Palavras-chave: Redes neurais artificiais, Sistemas *neuro-fuzzy*, Mensuração florestal.

ABSTRACT

VIEIRA, Giovanni Correia. **Prognosis of the diameter and height of individual trees using artificial intelligence**. 2015. Dissertation (Masters degree in Forest Sciences) – Federal University of Espírito Santo, Jerônimo Monteiro, ES. Adviser: Prof. Dr. Adriano Ribeiro de Mendonça. Co-advisors: Prof. Dr. Gilson Fernandes da Silva; Prof. Dr. Sidney Sára Zanetti.

The models are composed of individual trees submodels estimating generally competition, mortality and growth height and diameter of each tree. Are usually adopted when you want the best detailed information to estimate forest multiproducts. In these models, estimates of growth in diameter at 1.30 m above the ground (DBH) and total height (H) is obtained by regression analysis. Recently, artificial intelligence techniques are being used with good performance in forest measurement. Therefore, the aim of this study was to evaluate the performance of artificial intelligence techniques (artificial neural networks and neuro-fuzzy systems) to estimate the growth in DAP and height of eucalyptus trees. We used continuous data eucalyptus forest inventories annually measurements DAP total height of the first 15 trees and dominant height of the portion, according to the concept of Assmann (1970), 398 parts. The database was divided into 70% of the plots for the training of artificial neural networks and neuro-fuzzy system; 15% of the plots for the cross-validation; and 15% of the plots for validating systems. Based on the results, it was noted that the independent competition index of distance 5 - IID5 proposed by Glover; Hool (1979), was the one that had the highest correlation with the age, growth in DAP and height. It was observed that the artificial intelligence techniques showed good accuracy in estimating the growth in DBH and total height. The two techniques discussed can be used for prognosis and overall height of DAP.

Keywords: Artificial neural networks, Neuro-fuzzy systems, forest measurement

1. INTRODUÇÃO

O consumo de madeira em tora no Brasil, oriunda de projetos de reflorestamento foi de 185,3 milhões de m³ em 2013, resultando no aumento de 1,8% em relação a 2012 (IBÁ, 2014). Nesse sentido, o setor florestal apresenta potencialidades para crescimento, devido a versatilidade da madeira, que é utilizada para diversos fins. Considerando a importância do setor florestal, a previsão do crescimento e da produção é fundamental para o planejamento do segmento, assegurando a produção necessária para atender a demanda da população e retorno dos investimentos (SCOLFORO, 2006).

Entre os modelos de crescimento e produção, os modelos que expressam o crescimento de árvores individuais são adequados quando se deseja um melhor detalhamento da informação para estimar multiprodutos da floresta (CAMPOS; LEITE, 2013). Segundo os autores, esses modelos são compostos de submodelos que estimam a competição, a mortalidade e o crescimento em diâmetro e altura de cada árvore.

No que se refere a competição, os índices de competição expressam a condição competitiva de uma árvore em relação aos seus competidores, por recursos como luz, água e nutrientes (BIGING; DOBBERTIN, 1992). Esses índices podem ser dependentes da distância, quando é utilizada a distância dos competidores em relação à árvore objeto, ou independentes, quando não se considera a distância das árvores competidoras em relação à árvore objeto (SCOLFORO, 2006).

A mortalidade regular é uma variável de difícil determinação, pois a complexidade dos processos fisiológicos dificulta a determinação precisa do momento de sua ocorrência (HAMILTON JUNIOR, 1986; YANG et al., 2003), desse modo, modelos que estimam a probabilidade de mortalidade vem sendo o método convencional para estimar a mortalidade (CRECENTE-CAMPO et al., 2009).

Na busca de métodos mais eficientes de projeção do crescimento e produção, a utilização da inteligência artificial no setor florestal tem se destacado. As redes neurais artificiais (RNA's) merecem destaque, pois podem ser utilizadas como alternativa aos métodos tradicionais de modelagem em árvore individual (GUAN; GERTNER, 1991).

Técnicas como a lógica *fuzzy* e o sistema híbrido *neuro-fuzzy*, tem demonstrado bom desempenho em resolver problemas de aproximação de função em diversas áreas, como medicina, indústria, engenharia elétrica, controle e automação. A lógica *fuzzy* é uma poderosa ferramenta para trabalhar com informações incertas, imprecisas e incompletas, tornando as características do raciocínio humano acessíveis para os computadores (LENKE, 2005).

Martins (2011) afirma que a carência de estudos no Brasil sobre modelos de crescimento e produção em árvore individual está relacionada à maior complexidade desses modelos.

2. OBJETIVO GERAL

Avaliar o desempenho de técnicas de inteligência artificial para estimar o crescimento em DAP e altura total de árvores de eucalipto.

2.1. OBJETIVOS ESPECÍFICOS

- Determinar qual o índice de competição que mais se correlaciona com o crescimento em DAP, altura e área basal;
- Avaliar o desempenho de redes neurais artificiais na projeção do crescimento em DAP e altura total;
- Avaliar o desempenho de sistemas *neuro-fuzzy* na projeção do crescimento em DAP e altura total.

3. REVISÃO DE LITERATURA

3.1. MODELOS DE CRESCIMENTO E PRODUÇÃO FLORESTAL

No manejo florestal, a projeção do crescimento e da produção é uma das atividades mais importantes para o planejamento e análise da viabilidade econômica de projetos florestais, em que a precisão influencia diretamente na decisão do manejador (SCOLFORO, 2006).

Os modelos de crescimento e produção são classificados em modelos de povoamento total, modelos de distribuição diamétrica e modelos de árvores individuais.

Os modelos em nível de povoamento são mais simples, utilizados para estimar a variável de interesse para o povoamento como um todo. Esse tipo de modelo é adequado para situações em que o objetivo é apenas o volume de madeira ou biomassa para a área plantada, como ocorre na produção de madeira para fabricação de celulose e carvão (CAMPOS; LEITE, 2013).

Os modelos de crescimento e produção por classe diamétrica são utilizados na predição do crescimento em altura e volume das árvores para cada classe de diâmetro. Segundo Scolforo (2006), o maior detalhamento facilita o planejamento da produção, possibilitando otimizar os rendimentos do povoamento por meio da utilização de multiprodutos.

Já os modelos de crescimento e produção de árvores individuais, são utilizados para simular o crescimento de cada árvore em diâmetro e altura, a competição e a probabilidade de mortalidade de cada árvore (DAVIS; JOHNSON, 1987).

Segundo Hasenauer (2000), os modelos de crescimento de árvores individuais são compostos de outros submodelos capazes de estimar a mortalidade e a competição.

Biging; Dobbertin (1992) afirmam que as árvores de um povoamento disputam por recursos como água, luz e nutrientes. Alguns fatores como a idade, o tamanho, as características genéticas, a condição competitiva e o ambiente, influenciam no

crescimento das árvores (AVERY; BURKHART, 1994). Entre as variáveis citadas anteriormente, a competição é considerada a variável mais difícil de determinar (ZHANG et al., 1997). Em geral, o efeito da concorrência entre as árvores tem sido estimado por meio de índices de competição, que expressam a capacidade competitiva de uma árvore em relação aos seus competidores (CAMPOS; LEITE, 2013).

Para Moravie et al. (1999), os principais objetivos dos índices de competição são: entender os principais fatores e processos que influenciam no crescimento das árvores; estabelecer variáveis de fácil mensuração, que indiquem o potencial de crescimento e capacidade de superação da competição; desenvolver índices que possam ser utilizados com boa precisão na predição do crescimento em diâmetro e altura das árvores.

Os índices de competição são classificados em dependentes ou independentes da distância. Nos índices dependentes da distância, utiliza-se a distância dos competidores em relação à árvore objeto, enquanto que nos índices independentes não se considera essa distância (CAMPOS; LEITE, 2013).

Em princípio, espera-se que os modelos dependentes da distância apresentem melhores resultados, por considerarem a distribuição espacial das árvores. No entanto, observam-se resultados semelhantes desses índices quando comparados a índices mais simples, que não se considera a distância das árvores competidoras (DANIELS et al., 1986; FOX et al., 2007; CHASSOT, 2009). Em geral, o desempenho de um índice de competição está relacionado com a espécie e situações específicas da floresta. Nesse sentido, os índices independentes da distância apresentam como vantagens a facilidade de aplicação, o menor custo e menor dispêndio de tempo na coleta de dados (SCOLFORO, 2006).

A mortalidade é outra variável que sofre influência da competição na floresta. A probabilidade de uma árvore permanecer viva depende de seu estresse competitivo e do vigor individual, ou seja, da habilidade da árvore de competir em um determinado ambiente (SCOLFORO, 2006; WARING, 1987). Segundo Cao (1997), a grande competição entre as árvores vizinhas é uma das principais responsáveis pela ocorrência desse evento.

Yang et al. (2003) afirmam que houve um grande avanço na compreensão qualitativa dos processos de mortalidade das árvores em um povoamento florestal,

porém a quantificação da mortalidade necessita de mais estudos.

A mortalidade é classificada de acordo com os fatores responsáveis pela sua ocorrência, em regular ou irregular. A regular ocorre por fatores não catastróficos, como competição, fatores genéticos e idade, que podem ser estimadas (CAMPOS; LEITE, 2013). Já a irregular é definida por estes autores como aquelas provocadas por causas catastróficas, como pragas, incêndios, estresses ambientais e danos mecânicos, sendo difícil de estimar.

A complexidade dos processos fisiológicos que envolvem a mortalidade das árvores dificulta a determinação precisa do momento de ocorrência, sendo uma das variáveis menos compreendidas nos modelos de crescimento e produção (HAMILTON JUNIOR, 1986; YANG et al., 2003). Nesse sentido, a probabilidade de mortalidade vem sendo o método convencional para estimar a mortalidade (CRECENTE-CAMPO et al., 2009).

As funções contínuas, que estimam a probabilidade de mortalidade no intervalo entre 0 e 1, são as mais utilizadas. Nesse contexto, as funções Weibull (GLOVER; HOOL, 1979), Gama (BUFORD; HAFLEY, 1985), Beta (SOMERS et al., 1980), Exponencial (SHAO; SHUGART, 1997), Exponencial negativa e Normal (MONSERUD; STERBA, 1999) são empregadas para estimar a mortalidade.

Observa-se um aumento na utilização dos modelos não lineares, como o de Richards (BUFORD; HAFLEY, 1985), o logístico (HAMILTON, 1986) e o modelo proposto por West (1981), por apresentarem maior relação biológica com as variáveis responsáveis pela mortalidade.


Outra forma importante para realizar a predição de crescimento e produção com melhor eficiência de ajuste é a utilização de técnicas de inteligência artificial. Guan; Gertner (1991), afirmam que essas técnicas merecem destaque, podendo ser utilizadas como alternativa aos métodos tradicionais de modelagem de árvores individuais.

3.2. REDES NEURAIS ARTIFICIAIS

O cérebro é o órgão mais complexo e fascinante do corpo humano, com 10^{11} neurônios capazes de processar informações e se comunicar com milhares de outros em paralelo (BRAGA et al., 2007).

Os neurônios (Figura 1) são compostos por dendritos, responsáveis por receber as informações de outros neurônios e encaminhá-las até o corpo celular, que possui a função de processar a informação e transmitir para o axônio o resultado do processamento. O axônio transmite as informações para os dendritos dos neurônios seguintes por meio das sinapses (BRAGA et al., 2007). O autor complementa que a comunicação entre os neurônios ocorre quando as combinações dos sinais recebidos estão acima do limiar de excitação, no qual é gerado um impulso elétrico e propagado para os neurônios seguintes, por meio de neurotransmissores específicos.

Figura 1 – Modelo de neurônio biológico adaptado de Junqueira; Carneiro (2013) por Santos (2014)




As redes neurais artificiais (RNA's) surgiram ao se perceber que, apesar de uma informação trafegar no cérebro um milhão de vezes mais devagar que em um computador, o cérebro humano consegue processar uma grande quantidade de informações e tratar problemas complexos com velocidade.

Neste contexto, Haykin (2001) define redes neurais artificiais como um processador distribuído, macivamente paralelo, com capacidade de armazenar o conhecimento e torná-lo disponível. Para este autor, as RNA's foram inspiradas no cérebro humano, em que o conhecimento é adquirido por um processo de aprendizado, sendo o conhecimento armazenado pelas intensidades das forças de conexão entre os neurônios, conhecidas como pesos sinápticos.


O modelo desenvolvido para representar o neurônio artificial (Figura 2) é composto por m sinapses de entrada, que representam os dendritos do neurônio natural, em que pesos específicos (W_{kj}) são atribuídos a cada uma das entradas X_j para simular as sinapses (HAYKIN, 2001). Posteriormente, um somatório (Σ) é utilizado para obter a soma dos produtos das entradas pelos respectivos pesos, incluindo um *bias* (b_k) aplicado externamente para aumentar ou diminuir a entrada líquida da função de ativação (HAYKIN, 2001). Por fim, é utilizada uma função de ativação $[\phi(v)]$, que restringe a amplitude de saída de um neurônio (Y). Tipicamente, o intervalo padronizado da amplitude de saída de um neurônio é escrito como unitário fechado $[0,1]$ ou alternativamente $[-1,1]$ (HAYKIN, 2001).

Figura 2 – Modelo de um neurônio artificial, adaptado de Haykin (2001)



Existem várias funções matemáticas utilizadas como funções de ativação (Figura 3), sendo as mais comuns a função linear, função tangente hiperbólica, função degrau e a função sigmoide (BRAGA et al., 2000).

Figura 3 – Funções de ativação utilizadas em redes neurais artificiais (BRAGA et al., 2007)




A arquitetura da rede refere-se ao formato como os neurônios estão estruturados e suas conexões, devendo-se observar a quantidade de neurônios, o número de camadas e sua estruturação, a forma como os sinais estão sendo propagados (*feedforward* ou recorrentes), assim como a forma como eles estão arranjados (BRAGA et al., 2007).

Geralmente, os neurônios de uma mesma camada possuem comportamentos semelhantes, como a mesma função de ativação e padrão de conexão dos pesos, sendo que os neurônios de uma mesma camada podem estar conectados ou não entre si (RÉ, 2000).

As camadas são classificadas em: camada de entrada, onde as variáveis são apresentadas à rede; camadas intermediárias ou ocultas, onde é feito o processamento, e a camada de saída, responsável por apresentar o resultado (Figura 4).

Figura 4 – Modelo genérico de arquitetura de uma rede neural artificial, adaptado de Haykin (2001)



Às redes *Multilayer Perceptron* (MP), são compostas de multicamadas do tipo *feedforward*, com funções de ativação, que possuem uma ou mais camadas ocultas, sendo capazes de identificar padrões não lineares dos dados (LIPPNANN, 1987, BRAGA et al., 2007).

No que se refere ao treinamento da rede, este é o processo em que a rede “aprende” a identificar as relações existentes em um conjunto de dados (BARBALHO, 2001). Em que o conhecimento é adquirido por meio do ajuste dos pesos sinápticos das conexões entre os neurônios a cada novo exemplo apresentado à rede, possibilitando à rede responder mais corretamente a outras situações na fase posterior de testes (HAYKIN, 2001).

Segundo Fausett (1995), existem três tipos de treinamento de RNA's:

a) Supervisionado: Nesse tipo de treinamento é apresentado uma saída desejada para cada entrada no sistema, em que os parâmetros da rede são ajustados a cada iteração, com base na diferença entre a resposta da rede atual e a resposta desejada. Esse procedimento ocorre até obter o menor erro possível (BRAGA et al., 2007).

b) Não supervisionado: permite à rede aprender sem um conjunto de “respostas desejadas” como saídas. Os pesos sinápticos são ajustados de acordo com a similaridade dos padrões de entrada apresentados à rede, ou seja, ao passo que a rede adquire padrões representativos de cada classe. Esse tipo de rede é adequado para reconhecer padrões em conjunto de dados (CRIMMINS, 2001).

c) O híbrido: é composto por treinamento supervisionado e não supervisionado, como é o caso da rede RBF, em que a primeira camada da conexão é treinada de forma não supervisionada e a segunda, de forma supervisionada.

O algoritmo *backpropagation* é o mais utilizado para o treinamento supervisionado, em que o erro é obtido em dois passos por meio das diferentes camadas da rede (HAYKIN, 2001).

No passo para frente, um padrão de atividade é aplicado aos nós sensoriais e seu efeito propagado por todas as camadas até produzir uma saída como resposta real da rede, nesse sentido de propagação os pesos sinápticos da rede são todos fixos (HAYKIN, 2001). Já no passo para trás, todos os pesos são ajustados de acordo com a regra de correção do erro, em que a resposta real da rede é subtraída de uma resposta desejada, gerando um sinal de erro que é retropropagado por todas as camadas (HAYKIN, 2001).

Para contornar problemas de lentidão na convergência do algoritmo *backpropagation*, outras técnicas de otimização foram agregadas ao algoritmo, sendo o algoritmo de Levenberg-Marquardt, que combina as melhores características do método de gradiente descendente e Gauss-Newton o mais utilizado (HAGAN; MENHAJ, 1994).

O algoritmo Levenberg-Marquardt utiliza uma combinação de dois métodos, o gradiente descendente e o método iterativo de Gauss-Newton, para solucionar problemas não lineares, em que sua atualização da rede considera tanto a inclinação da superfície do erro (método do gradiente descendente) quanto à curvatura desta superfície (método de Gauss-Newton). Quando distante do ponto de mínimo, o método do gradiente descendente predomina. Já ao aproximar-se do ponto de mínimo, o algoritmo de Gauss-Newton é utilizado (SILVA, SPATTI, FLAUZINO, 2010).


Uma das características mais importantes das RNA's é a capacidade de generalização, ou seja, é importante que a rede consiga extrapolar para novos dados o conhecimento adquirido na fase de treinamento. Para manter essa característica é necessário evitar que a rede seja mais complexa que o necessário, pois nessas circunstâncias pode ocorrer o excesso de ajuste, em que a rede modela relações indesejáveis, como o erro (BRAGA et al., 2007).

Para contornar esse problema pode-se realizar simulações de rede com várias arquiteturas, de modo que sempre que ocorrer igualdade ou pouca diferença na performance das redes avaliadas, utiliza-se a que possui configuração mais simples (menor número de neurônios e camadas).

Com relação ao treinamento demasiado, que ocorre quando o número de iterações é superior ao necessário, pode levar a adaptação da rede à característica específica dos dados utilizados no treinamento (CALÔBA; CALÔBA; SALIBY, 2002).

No método de treinamento com parada antecipada, é possível controlar o treinamento e evitar o excesso de ajuste. Nesse método, é possível identificar o excesso de ajuste por meio da validação cruzada (*cross validation*), em que uma amostra de treinamento é utilizada para o treinamento da rede e outra é utilizada para a validação cruzada após cada iteração (HAYKIN, 2001). Enquanto o quadrado médio do erro (QME) da amostra de validação for menor que o QME das iterações anteriores, o treinamento da rede é continuado, caso contrário o treinamento deve ser finalizado, já que após esse ponto a rede perde a capacidade de generalização (Figura 5).

Figura 5 – Regra da parada antecipada baseada na validação cruzada (HAYKIN, 2001)



3.3 SISTEMAS FUZZY

A lógica *fuzzy* ou nebulosa surgiu ao se perceber a dificuldade da lógica clássica em lidar com situações imprecisas e vagas, onde o conceito binário do princípio da não contradição não atende as características da percepção humana em diversas ocasiões do cotidiano. O raciocínio humano é capaz de trabalhar com certa precisão com dados incertos, incompletos e ambíguos. A lógica nebulosa é uma generalização da lógica clássica que possibilita valores intermediários entre o falso e o verdadeiro, sendo adequadas para resolver problemas que não possuem fronteiras bem definidas, isto é, a transição de uma classe para outra é suave e não abrupta (TANAKA, 1997).

Desse modo, não se analisa uma variável como tendo apenas um estado atual, mas sim n estados, cada um com seu grau de pertinência (ZADEH, 1965). Trata-se de uma generalização da função característica da lógica clássica, para que ela pudesse assumir infinitos valores no intervalo fechado entre 0 e 1 (ARTERO, 2009).

Nesse sentido, um elemento pode pertencer parcialmente a um conjunto, isto é, um conjunto *fuzzy* A em um universo X é definido por uma função de pertinência $\mu_A(x): X \rightarrow [0,1]$, em que $\mu_A(x)$ indica o quanto x é compatível com A (ZADEH, 1965). Nesse modelo, dada uma distribuição de possibilidade $\pi: X \rightarrow [0,1]$ para qualquer valor de $x_i \in X$, $\pi(x_i)$, analisa até que ponto é possível que $x = x_i$ partindo do pressuposto que tem somente um valor verdadeiro (SHAW; SIMÕES, 2007). Nesse contexto, dada uma distribuição de possibilidade relativa π , à variável x é considerada como a função de pertinência de um conjunto nebuloso dos valores possíveis de x (ZADEH, 1978).

Com essa generalização, torna-se possível um elemento pertencer a mais de um conjunto nebuloso com diferentes graus de pertinência (WUERGES; BORBA, 2010). Nessa nova ótica de analisar um problema, não se afirma que uma árvore, por exemplo, é alta ou baixa, mas pode-se atribuir um grau de pertinência igual a 0,6 para a classe alta, 0,3 para a classe média e 0,1 para a classe baixa.

O conjunto *fuzzy* é representado por um conjunto de pares ordenados $A = \mu_A(x), x \in X$. Quando o universo X é discreto, normalmente usa-se a notação da equação 1:

$$A = \sum_{x \in X} \mu_A(x_i) \quad (1)$$

Já quando o universo X for contínuo, normalmente emprega-se a notação da equação 2:


$$A = \int_{x \in X} \mu_A(x) \quad (2)$$

Em que os símbolos Σ e \int representam a operação de união lógica.

A máquina de inferência *fuzzy* é composta por funções de pertinência, operadores lógicos *fuzzy* e regras do tipo *Se-Então*, que são utilizadas para mapear uma dada entrada para uma saída desejada (TANAKA, 1991).


O processo de inferência ocorre com a fuzzificação dos dados, em que é atribuído a cada elemento um grau de certeza, variando entre 0 e 1, por meio de funções de pertinência. Com relação às funções de pertinência, as mais comuns são (PAGLIOSA, 2003):

Função Triangular:




$$\mu_A(X) = \begin{cases} 0, & \text{se } x \leq a \\ \frac{(x-a)}{(m-a)}, & \text{se } x \in [a, m] \\ \frac{(b-x)}{(b-m)}, & \text{se } x \in [m, b] \\ 0, & \text{se } x \geq b \end{cases} \quad (3)$$

Função Trapezoidal:



$$\mu_A(X) = \begin{cases} 0, & \text{se } x < a \\ \frac{(x-a)}{(m-a)}, & \text{se } x \in [a, m] \\ 1, & \text{se } x \in [m, n] \\ \frac{(b-x)}{(b-n)}, & \text{se } x \in [n, b] \\ 0, & \text{se } x > b \end{cases} \quad (4)$$

Função Gaussiana:



$$\mu_A(X) = \begin{cases} 0, & \text{se } x \text{ está fora do domínio} \\ e^{-\frac{(x-m)^2}{2s^2}}, & \text{caso contrário} \end{cases} \quad (5)$$

No estágio de fuzzificação também ocorre a ativação das regras relevantes para cada situação. Essas regras são, em geral, inferências do tipo “SE... ENTÃO...” utilizadas para associar adequadamente as funções de pertinência das entradas com as funções de pertinência da saída (SHAW; SIMÕES, 2007).

As regras podem ser fornecidas por especialistas em forma de sentenças linguísticas ou extraídas por métodos de extração de regras de dados numéricos, como é o caso do sistema híbrido *neuro-fuzzy* (SHAW; SIMÕES, 2007).

O próximo passo é a defuzzificação, em que ocorre a representação dos valores obtidos do conjunto *fuzzy* por um valor real de saída. Existem diversos métodos de defuzzificação, sendo os mais comuns o centroide, bissetor, média dos máximos, maior dos máximos e menores dos máximos, sendo empírica a decisão sobre qual método utilizar (MAMDANI, 1974).

Os fatores que devem ser observados na modelagem de um sistema de inferência *fuzzy* são: a escolha correta do número de conjuntos *fuzzy*, funções de pertinência e de regras adequadas, assim como o método de defuzzificação apropriado (ARTERO, 2009).

Extrair regras na forma de sentenças do tipo “se... então...” de um conjunto de dados pode não ser uma tarefa fácil, até mesmo para um especialista, assim como a escolha correta do método de defuzzificação. Nesse sentido, os métodos de inteligência artificial híbridos, como o *neuro-fuzzy*, apresentam potencialidades, pois conseguem extrair tanto as regras de pertinência, regras de inferência e o melhor método de defuzzificação (SUGENO; KANG, 1988).

3.4. SISTEMAS NEURO-FUZZY

O sistema *neuro-fuzzy* consiste em um sistema de inferência *fuzzy* (FIS), com estrutura paralela distribuída, de modo que os algoritmos de aprendizado das redes neurais são utilizados para ajustar os parâmetros do FIS (JANG, 1993). Esse sistema apresenta-se como um diferencial a utilização das redes neurais para o aprendizado, com as vantagens inerentes aos sistemas de inferência *fuzzy* (LEITE, 2009).

Segundo Pal; Mitra (1992), à utilização de conjuntos *fuzzy* dentro de redes neurais possibilita fazer inferências de situações da vida real de forma mais parecida com o raciocínio humano.

Quanto à tipologia, as redes *neuro-fuzzy* são divididas em dois grupos. No primeiro caso, utiliza pesos *fuzzy* nas conexões entre nós, enquanto que no segundo os dados são fuzzificados na primeira ou segunda camada, mas os pesos da rede não são *fuzzy*, sendo o mais utilizado na prática (JANG, 1993).

Na identificação dos parâmetros, os sistemas *neuro-fuzzy* são baseados no método utilizado para o ajuste dos pesos, que definem os perfis das funções de pertinência dos antecedentes e consequentes das regras *fuzzy*. A maioria dos sistemas *neuro-fuzzy* identifica os antecedentes e os consequentes com peso fixo e valor unitário para cada regra (JANG, 1993). Nesse sentido, o *Adaptative Network Based Fuzzy Inference System* – ANFIS, que apresenta essa característica, é um dos mais utilizados.

O ANFIS consiste em um sistema capaz de criar regras com base no conhecimento ou experiência contida no conjunto de dados, ou seja, é capaz de implementar regras *fuzzy* automaticamente, a partir de um conjunto de dados (JANG, 1993).

Para Barbalho (2001), o sistema é capaz de criar regras *fuzzy* com funções de pertinência adequadas e ajustar automaticamente os parâmetros dessas funções para maximizar a performance da representação das relações existentes entre entrada e saída dos dados.

A estrutura do sistema ANFIS, segundo Barbalho (2001), é composta de 5 camadas: na primeira camada cada uma das unidades representa uma função de pertinência associada a uma das entradas, tendo como característica a adaptabilidade; na segunda camada, calcula-se o sinal de saída, pela multiplicação dos sinais que chegam até esta camada, o grau de pertinência ao qual cada elemento é submetido e o consequente de cada regra; na terceira camada, cada nó realiza a normalização dos graus de ativação das regras, ou seja, trata-se de uma camada não adaptativa; na quarta camada, que é adaptativa, a saída de cada neurônio é obtida pelo produto entre a saída normalizada da camada anterior e o grau de ativação do consequente. Na quinta camada ocorre o processo de defuzzificação que calcula a saída final.

Os dois algoritmos ANFIS mais comuns são o *grid partition* e o *subtractive clustering*. O *grid partition* divide o espaço de dados em subespaços retangulares com base no número pré-definido de funções de pertinência, em que o antecedente de uma regra *fuzzy* define uma área no espaço das variáveis de entrada, enquanto que o consequente descreve o comportamento da variável de saída dentro da área *fuzzy* definida no antecedente (SILVA, 2014). O uso do *grid partition* é limitado a poucas entradas, já que o número de regras aumenta exponencialmente com o

aumento do número de entradas, ocasionando dificuldade de processamento (WEI et al., 2007).

Já o *subtractive clustering* proposto por CHIU (1994) é um melhoramento do algoritmo não supervisionado denominado de método da montanha. Esse algoritmo procura os centros dos grupos com base na densidade dos pontos amostrados, sendo o ponto com maior número de vizinhos selecionado como o centro (WEI et al., 2007).

4. METODOLOGIA

4.1. DESCRIÇÃO DA ÁREA E COLETA DOS DADOS

Para a realização desse trabalho, foram utilizados dados de inventário florestal contínuo de 28 clones, em que foram medidos anualmente o diâmetro a 1,30 m (DAP), em centímetros, a altura total das 15 primeiras árvores da parcela e a altura dominante, em metros, de acordo com o conceito de Assmann (1970), de 398 parcelas de 200 m² a 350 m².

Os dados foram obtidos de plantios comerciais de eucalipto no município de Virginópolis, MG, cujas coordenadas geográficas são 18°49'5" de latitude sul e 42°41'46" de longitude oeste, sendo o clima da região Cwa, de acordo com a classificação de Köppen (LIMA et al., 2008).

O banco de dados foi dividido em 70% das parcelas para treinamento das redes neurais artificiais e do sistema *neuro-fuzzy*; 15% das parcelas para a validação cruzada; e 15% das parcelas para a validação das técnicas. Os valores médios das variáveis do povoamento nas três classes de produtividade estão na Tabela 1.

Tabela 1 – Valores médios das variáveis Diâmetro a 1,30 (DAP), altura total (H) e Área Basal (G) por idade

Idade (meses)	DAP(cm)			H(m)			G (m ² /ha)	N° (ár./ha)
	Mín.	Méd.	Máx.	Mín.	Méd.	Máx.		
24	5.23	12.10	16.97	8.60	15.77	21.77	11.87	3.050
36	5.40	13.40	18.27	8.90	18.43	23.53	14.80	3.103
48	5.20	15.40	22.60	9.43	21.33	27.13	19.50	3.082
60	5.33	16.27	26.23	11.40	24.23	31.77	21.83	3.126
72	5.50	17.30	27.90	11.50	25.67	32.27	24.80	3.126
84	5.73	18.17	29.60	12.23	27.43	35.33	27.77	3.167
96	8.20	19.50	30.60	14.10	28.90	35.30	30.27	2.991

Em que DAP diâmetro a altura do peito; H: altura total; B/ha: área basal por hectare; N° árv./ha: número de árvores por hectare; Mín.: mínimo; Méd.: médio; Máx.: máximo.

4.2. CLASSIFICAÇÃO DE SÍTIO

Para a classificação de sítio foi ajustado o modelo de Schumacher linearizado (Equação 6) para estimar a altura dominante média das árvores das parcelas. Foi utilizado o método da curva guia para classificar os sítios. Estes foram classificados em três classes de produtividade: alta, média e baixa. A idade de referência utilizada foi de 72 meses.

$$\ln(\overline{HDC}) = \beta_0 + \beta_1 \left(\frac{1}{I}\right) + \varepsilon \quad (6)$$

Em que: HDC é a altura dominante média das árvores da parcela e I é a idade atual.

4.3. ÍNDICES DE COMPETIÇÃO

Foram avaliados quatro índices de competição independentes da distância. Após isso, o índice de melhor performance foi utilizado no sistema de simulação de crescimento e produção em nível de árvore individual para estimar a competição entre as árvores.

A competição entre as árvores por recursos foi estimada com base nas expressões da Tabela 2.

Tabela 2 – Índices de competição independente da distância analisados

Autor/Índice	Equação para o cálculo do índice de competição independente da distância
STAGE (1973)	$IID_1 = BAI = \frac{d_i^2}{q^2}$
Índice BAL_i	$IID_2 = BAL_i$
GLOVER; HOOL (1979)	$IID_3 = \frac{d_i h_i}{\bar{D}^2 \bar{H}}$
TOMÉ; BURKART (1989)	$IID_4 = \frac{d_i}{d_{dom}}$
GLOVER E HOOL (1979)	$IID_5 = \frac{d_i}{\bar{D}^2}$

Em que d_i : diâmetro da árvore objeto (cm); d_{dom} : diâmetro da árvore dominante (cm); q : diâmetro quadrático (cm); h_i : altura total da árvore objeto (m); \bar{D} : média aritmética dos diâmetros das árvores da unidade amostral (cm); \bar{H} : altura média das árvores da unidade amostral (m); BAI : índice de área basal; e BAL_i : somatório das áreas seccionais das árvores maiores que a árvore-objeto.

Foi realizado o teste de Shapiro-Wilk baseado na estatística W para verificar se as variáveis atendem à pressuposição de distribuição normal bidimensional.

Em que:

H_0 : A amostra provém de uma população Normal

H_1 : A amostra não provém de uma população Normal

Sendo:

$$W = \frac{b^2}{\sum_{i=1}^n (x_i - \bar{x})^2} \quad (7)$$

Em que x_i são os valores da amostra ordenados e b é determinado da seguinte forma:

$$b = \begin{cases} \sum_{i=1}^{n/2} a_{n-i+1} (x_{(n-i+1)} - x_{(i)}) & \text{se } n \text{ é par} \\ \sum_{i=1}^{(n+1)/2} a_{n-i+1} (x_{(n-i+1)} - x_{(i)}) & \text{se } n \text{ é ímpar} \end{cases}$$

A avaliação do comportamento dos índices de competição em função da idade

foi feita com base no coeficiente de correlação linear de Pearson entre os índices de competição e o crescimento em diâmetro, altura, idade e área basal, como proposto por Daniels (1976), González et al. (2006) e Martins (2011).

$$r_{xy} = \frac{\sum(x_i - \bar{x})(y_i - \bar{y})}{\sqrt{(\sum(x_i - \bar{x}))^2 (\sum(y_i - \bar{y}))^2}} \quad (8)$$

Em que r_{xy} é o coeficiente de correlação entre x e y , x_i e y_i são os valores observados na amostra e \bar{x} e \bar{y} são as médias de x e y respectivamente.

Foi utilizado o teste t de *Student*, com 5% de probabilidade, para testar a significância do coeficiente de correlação, adotando como hipótese nula (H_0): $\rho_{xy} = 0$, e como hipótese alternativa (H_1): $\rho_{xy} \neq 0$. A estatística do teste é dada por:

$$t_{n-1} = r \sqrt{\frac{n-2}{1-r^2}} \quad (9)$$

Em que t : estatística t ; r : coeficiente de correlação de Pearson; n : tamanho da amostra.

4.4. REDES NEURAIS ARTIFICIAIS

Para o treinamento das redes, foram testadas 100 redes para cada arquitetura *MultiLayer Perceptron* – MP com uma camada intermediária. Foram testadas arquiteturas de redes com neurônios variando de 3 á 30 neurônios na camada intermediária. Foram avaliadas duas funções de ativação na camada intermediária, a logarítmica sigmoide e a tangente sigmoide. Na camada de saída a função utilizada foi a linear. As funções são apresentadas na Tabela 3:

Tabela 3 – Funções de ativação utilizadas

Função de ativação	Equação
Logarítmica sigmoide	$f(x) = \frac{1}{1 + e^{-x}}$
Tangente sigmoide	$f(x) = \frac{2}{1 + e^{-2x}} - 1$
Linear	$f(x) = ax$

Foram treinadas 100 redes para cada configuração do tipo *feedforward*, pelo método supervisionado, utilizando o algoritmo de treinamento Levenberg-Marquardt. Foi empregado como critério de parada duas regras; 1.000 épocas para cada combinação de configuração ou parada antecipada pelo método de validação cruzada. As variáveis de entrada e saída foram padronizadas entre [0, 1] para a função de ativação logarítmica sigmoide e [-1, 1] para a função de ativação tangente sigmoide. As variáveis de entrada utilizadas na rede estão localizadas na Tabela 4.

Tabela 4 – Variáveis utilizadas na configuração das redes neurais artificiais

Entradas		Saídas
	DAP	
DAP ₁ , I ₁ , I ₂ , IID _i , S, Mg		DAP ₂
DAP ₁ , I ₁ , I ₂ , IID _i , S		DAP ₂
	H	
H ₁ , S, I ₁ , I ₂ , IID _i , Mg		H ₂
H ₁ , I ₁ , I ₂ , IID _i , S		H ₂

Em que, I₁: idade atual (meses); I₂: idade futura (meses); DAP₁: diâmetro a 1,30 m de altura atual (cm), DAP₂: diâmetro a 1,30 de altura futura (cm); H₁: Altura total atual (m); H₂: Altura total futura (m); S: índice de sitio; IID_i: índice de competição independente da distância; Mg: material genético.

4.5. SISTEMA NEURO-FUZZY

O método *neuro-fuzzy* utilizado foi o *Adaptive Neuro-Fuzzy Inference System - ANFIS*, proposto por Jang (1993), em que, com base no conjunto de entradas e saídas desejadas, a ferramenta elabora um modelo de inferência *fuzzy*. Foi utilizado 3

funções de pertinência para as variáveis DAP_1 e H_1 ; 2 para cada I_1 , I_2 e IID_i ; e, 1 função de pertinência para cada classe de sítio e clone. As funções de pertinência da entrada foram todas gaussianas, e a função de saída foi a linear.

Os algoritmos utilizados foram o *grid partition* e *subtractive clustering*, o número de épocas para o treinamento variou de 1 a 50, sendo empregado o número de épocas que apresentou o menor erro nos dados de validação.

O método de treinamento foi o híbrido composto do método *backpropagation* e do método dos mínimos quadrados. O método *backpropagation* está relacionado com as estimativas dos parâmetros das funções de pertinência de entrada, enquanto o método dos mínimos quadrados com as estimativas dos parâmetros de saída das funções de pertinência. As entradas utilizadas estão na tabela 5.

Tabela 5 – Variáveis utilizadas na configuração do sistema *neuro-fuzzy*

Sistema <i>Neuro-fuzzy</i>	Método	Entradas	Saídas
DAP			
1	<i>Subtractive clustering</i>	$DAP_1, I_1, I_2, IID_i, S, Mg$	DAP_2
2	<i>Subtractive clustering</i>	$DAP_1, I_1, I_2, IID_i, S$	DAP_2
3	<i>Grid partition</i>	DAP_1, I_1, I_2, IID_i	DAP_2
H			
1	<i>Subtractive clustering</i>	$H_1, I_1, I_2, IID_i, S, Mg$	H_2
2	<i>Subtractive clustering</i>	H_1, I_1, I_2, IID_i, S	H_2
3	<i>Grid partition</i>	H_1, I_1, I_2, IID_i	H_2

Em que, I_1 : idade atual (meses); I_2 : idade futura (meses); DAP_1 : diâmetro a 1,30 m de altura atual (cm), DAP_2 : diâmetro a 1,30 de altura futura (cm); H_1 : Altura total atual (m); H_2 : Altura total futura (m); S: índice de sítio; IID_i : índice de competição independente da distância; Mg: material genético.

4.6. AVALIAÇÃO DO AJUSTE E VALIDAÇÃO DOS MODELOS DE CRESCIMENTO EM NÍVEL DE ÁRVORE INDIVIDUAL

Para avaliação do desempenho dos modelos foram analisados os gráficos das variáveis observadas *versus* variáveis estimadas, gráfico dos resíduos *versus* valores estimados, o coeficiente de determinação (R^2) (Tabela 6), o viés (V), a média das diferenças absolutas (MD) e a raiz do quadrado médio do erro (RQME).

Tabela 6 – Indicadores estatísticos utilizados para avaliar o desempenho dos modelos ajustados

Estatística	Fórmula
Coeficiente de determinação	$R^2 = 1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y})^2}$
Viés (V)	$V = \frac{\sum_{i=1}^n (\hat{y}_i - y_i)}{n}$
Médias das diferenças absolutas (MD)	$MD = \frac{\sum_{i=1}^n y_i - \hat{y}_i }{n}$
Raiz do quadrado médio do erro (RQME)	$RQME = \sqrt{\frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{n}}$

R²: coeficiente de determinação; y_i: valor observado da i-ésima variável dependente; \hat{y} : valor estimado da i-ésima variável dependente; \bar{y} : média dos valores observados da variável dependente; n: tamanho da amostra; V: Viés; MD: médias das diferenças absolutas; RQME: raiz do quadrado médio do erro.

5. RESULTADOS E DISCUSSÃO

5.1. CLASSIFICAÇÃO DO SÍTIO

O modelo de Schumacher apresentou todos os parâmetros significativos a 1% de probabilidade. A equação ajustada foi:

$$\text{Ln}(\overline{\text{HDC}}) = 3,74397 - 26,921316 \cdot \left(\frac{1}{I}\right) \quad (10)$$

O modelo ajustado apresentou um coeficiente de determinação de 0,7955 e raiz do quadrado médio do erro (RQME) de 2,57 m. As classes de sítio foram: 22m (baixa produtividade), 30m (média produtividade) e 38m (alta produtividade).

5.2. ÍNDICES DE COMPETIÇÃO

Com base no teste de Shapiro-Wilk, a 5% de probabilidade, foi possível constatar que a amostra provém de uma população com distribuição normal. Observou-se, em geral, correlação significativa pelo teste t, com 5% de probabilidade, entre os índices de competição e a idade, crescimento em DAP, H e G (Tabela 7). O índice de competição que obteve maior correlação com as variáveis em estudo foi o IID₅, com exceção do crescimento em DAP para o sítio 22, em que o IID₂ teve maior correlação. Martins et al. (2011) encontraram maiores correlações para os índices IID₃ e IID₁, respectivamente.

A idade obteve correlação negativa com o crescimento em DAP, H e G. Isso se deve ao fato de com o aumento da idade, a taxa de crescimento tende a diminuir. Resultados encontrados por Martins et al. (2011) corroboram com a tendência observada. Verificou-se que a correlação é menor no sítio de baixa produtividade.

Tabela 7 – Matriz de correlação simples entre os índices de competição - IID_i, idade e o crescimento em diâmetro à 1,30m (DAP), altura total (H) e área basal (G)

Alta Produtividade (S=38)

	Idade	IID ₁	IID ₂	IID ₃	IID ₄	IID ₅	ΔDAP	ΔH	ΔG
Idade	1	*0,06	*0,48	*-0,49	*-0,17	*-0,64	*-0,58	*-0,44	*-0,60
IID ₁		1	*-0,71	*0,72	*0,88	*0,60	*0,29	*0,05	*-0,03
IID ₂			1	*-0,77	*-0,73	*-0,76	*-0,54	*-0,28	*-0,26
IID ₃				1	*0,74	*0,95	*0,60	*0,17	*0,36
IID ₄					1	*0,66	*0,37	*0,12	*0,08
IID ₅						1	*0,66	*0,37	*0,47
ΔDAP							1	*0,42	*0,75
ΔH								1	*0,35
ΔG									1

Média Produtividade (S=30)

	Idade	IID ₁	IID ₂	IID ₃	IID ₄	IID ₅	ΔDAP	ΔHt	ΔG
Idade	1	*0,03	*0,43	*-0,49	*-0,11	*-0,63	*-0,63	*-0,43	*-0,68
IID ₁		1	*-0,74	*0,72	*0,87	*0,60	*0,26	*0,04	*-0,02
IID ₂			1	*-0,76	*-0,71	*-0,74	*-0,52	*-0,23	*-0,29
IID ₃				1	*0,67	*0,95	*0,61	*0,15	*0,42
IID ₄					1	*0,59	*0,30	*0,07	*0,05
IID ₅						1	*0,67	*0,34	*0,54
ΔDAP							1	*0,41	*0,78
ΔHt								1	*0,37
ΔG									1

Baixa Produtividade (S=22)

	Idade	IID ₁	IID ₂	IID ₃	IID ₄	IID ₅	ΔDAP	ΔH	ΔG
Idade	1	0,063	*0,23	*-0,22	-0,03	*-0,33	*-0,57	*-0,27	*-0,50
IID ₁		1	*-0,73	*0,87	*0,88	*0,80	*0,08	-0,04	-0,01
IID ₂			1	*-0,68	*-0,64	*-0,65	*-0,41	*-0,08	*-0,30
IID ₃				1	*0,72	*0,97	*0,29	-0,06	*0,25
IID ₄					1	*0,69	*0,12	-0,06	0,03
IID ₅						1	*0,34	*-0,08	*0,35
ΔDAP							1	*0,10	*0,68
ΔH								1	*-0,18
ΔG									1

Em que: IID₁: STAGE, 1973; IID₂: Índice BAL_i; IID₃: GLOVER & HOOL, 1979; IID₄: TOMÉ & BURKART, 1989; IID₅: GLOVER & HOOL, 1979; ΔDAP: Crescimento em DAP; ΔH: Crescimento em altura total.

A competição é diretamente proporcional ao índice de local, sendo que em sítios com menor produtividade as plantas usam seus recursos escassos para a sobrevivência, enquanto que em locais mais produtivos as plantas crescem e competem (WATKINSON ET AL., 1983; WEINER; THOMAS, 1986).

A correlação dos índices de competição e crescimento em DAP variou de |0,29| a |0,66| para a classe de alta produtividade, de |0,26| a |0,67| para a classe de média produtividade e de |0,08| a |0,41| para o sítio de baixa produtividade. Martins et al. (2011) encontraram valores de correlação linear variando de |0,52| a |0,74| para híbridos de eucalipto. Daniels et al. (1986) obteve valores de correlações entre os índices de competição e DAP entre |0,23| a |0,31| para *Pinus taeda*.

Já em relação a correlação entre os índices de competição e a altura, observa-se variação de |0,05| a |0,37| para a classe de alta produtividade, de |0,04| a |0,34| para o sítio de média produtividade, e |0,04| a |0,08| para o sítio de baixa produtividade. O índice de competição que teve maior correlação foi o IID₅, seguido pelo IID₂. No geral, a correlação entre a altura e o índice de competição foi inferior a correlação entre o índice de competição e o DAP. Também notou-se, que semelhante ao que ocorreu com o DAP, a correlação entre o índice de competição e a altura foi menor nas classes menos produtivas. Martins et al. (2011) encontraram valores variando de |0,39| a |0,69| para um híbrido de eucalipto. Chassot et al. (2011) notaram, para a espécie *Araucaria angustifolia*, correlações inferiores a |0,64|.


No que tange a correlação entre o índice de competição e a área basal, foi observado que o índice IID₅ apresentou maior correlação em todas as classes produtivas. Já o índice que teve menor correlação com a área basal foi o IID₁, com valores inferiores a |0,03|. Martins et al. (2011) encontraram maior correlação para o índice de competição IID₃.

5.3. CRESCIMENTO EM DAP E ALTURA TOTAL

5.3.1. Redes neurais artificiais para estimar o crescimento em DAP e altura total.


Com base nas simulações foram selecionadas as redes com configurações (número de neurônios na camada intermediária) que apresentaram menor RQME para o DAP e altura total. Na configuração para o DAP, o número de neurônios da camada intermediária foram 8 para a rede 1, 23 para a rede 2, 6 para a rede 3 e 5 para a rede 4 (Figura 6).

Figura 6 – Determinação do número de neurônios da camada intermediária que apresenta menor erro das redes neurais para estimar o DAP



A configuração de rede para a altura total que obteve menor RQME para a rede 1 foi 8 neurônios para a camada intermediária e para a rede 2, 3 e 4 foram 4 neurônios na camada intermediária (Figura 7). No geral, nota-se que não ocorreram diferenças na precisão devido as funções de ativação, sendo importante salientar que as configurações que apresentaram o menor erro podem ser diferentes devido os valores iniciais dos pesos serem gerados aleatoriamente.

Figura 7 – Determinação do número de neurônios da camada intermediária que apresenta menor erro das redes neurais para estimar altura total



Analisando as estatísticas para avaliar o desempenho das redes neurais artificiais (Tabela 8), nota-se que o coeficiente de determinação para o DAP, variou de 0,9870 a 0,9883 para o DAP e de 0,9572 a 0,9587 para a altura total. Adame et al. (2008) utilizando modelos de regressão, obteve estimativas na faixa de 0,5090 a 0,5400 para crescimento em diâmetro de *Eucalyptus globulus*. Martins (2014) obteve por meio de modelos de regressão valores na faixa de 0,9586 a 0,9875 para o crescimento em DAP e 0,9429 a 0,9886 para a altura de híbridos de eucaliptos. Castro et al. (2013) utilizando redes neurais artificiais, obteve coeficientes de determinação variando de 0,9776 a 0,9860 para o crescimento em DAP e 0,9839 a 0,9889 para o crescimento em altura total.

O viés para o DAP variou de -0,0294 a -0,0177 para o DAP e -0,1058 a -0,0276 para a altura total. Martins (2014) e Castro (2013) também obtiveram pequenos viés, tanto para modelos de regressão quanto para redes neurais artificiais. Com relação a médias dos desvios absolutos, a variação foi de 0,4031 a 0,4177 para o crescimento em DAP e de 1,0700 a 1,0899 para o crescimento em altura. Castro et al. (2013) encontrou valores variando de 0,3821 a 0,5049 para MD de estimativas de crescimento de DAP e 0,0693 a 0,1668 para estimativas de crescimento de altura total.

Tabela 8 – Indicadores estatísticos utilizados para avaliar as configurações de redes neurais artificiais para estimar o crescimento em DAP e altura total

Tipo	Função de ativação	Configuração o	R ²	V	MD	RQME
DAP						
Rede 1	Logaritmo sigmoide	08-1	0,9870	-0,0227	0,4155	0,5785
Rede 2	Tangente sigmoide	23-1	0,9871	-0,0209	0,4177	0,5789
Rede 3	Logaritmo sigmoide	06-1	0,9883	-0,0177	0,4031	0,5496
Rede 4	Tangente sigmoide	05-1	0,9883	-0,0294	0,4069	0,5535
H						
Rede 1	Logaritmo sigmoide	08-1	0,9572	-0,0445	1,0899	1,4256
Rede 2	Tangente sigmoide	04-1	0,9587	-0,1058	1,0700	1,4078
Rede 3	Logaritmo sigmoide	04-1	0,9573	-0,0967	1,0747	1,4315
Rede 4	Tangente sigmoide	04-1	0,9572	-0,0276	1,0819	1,4278

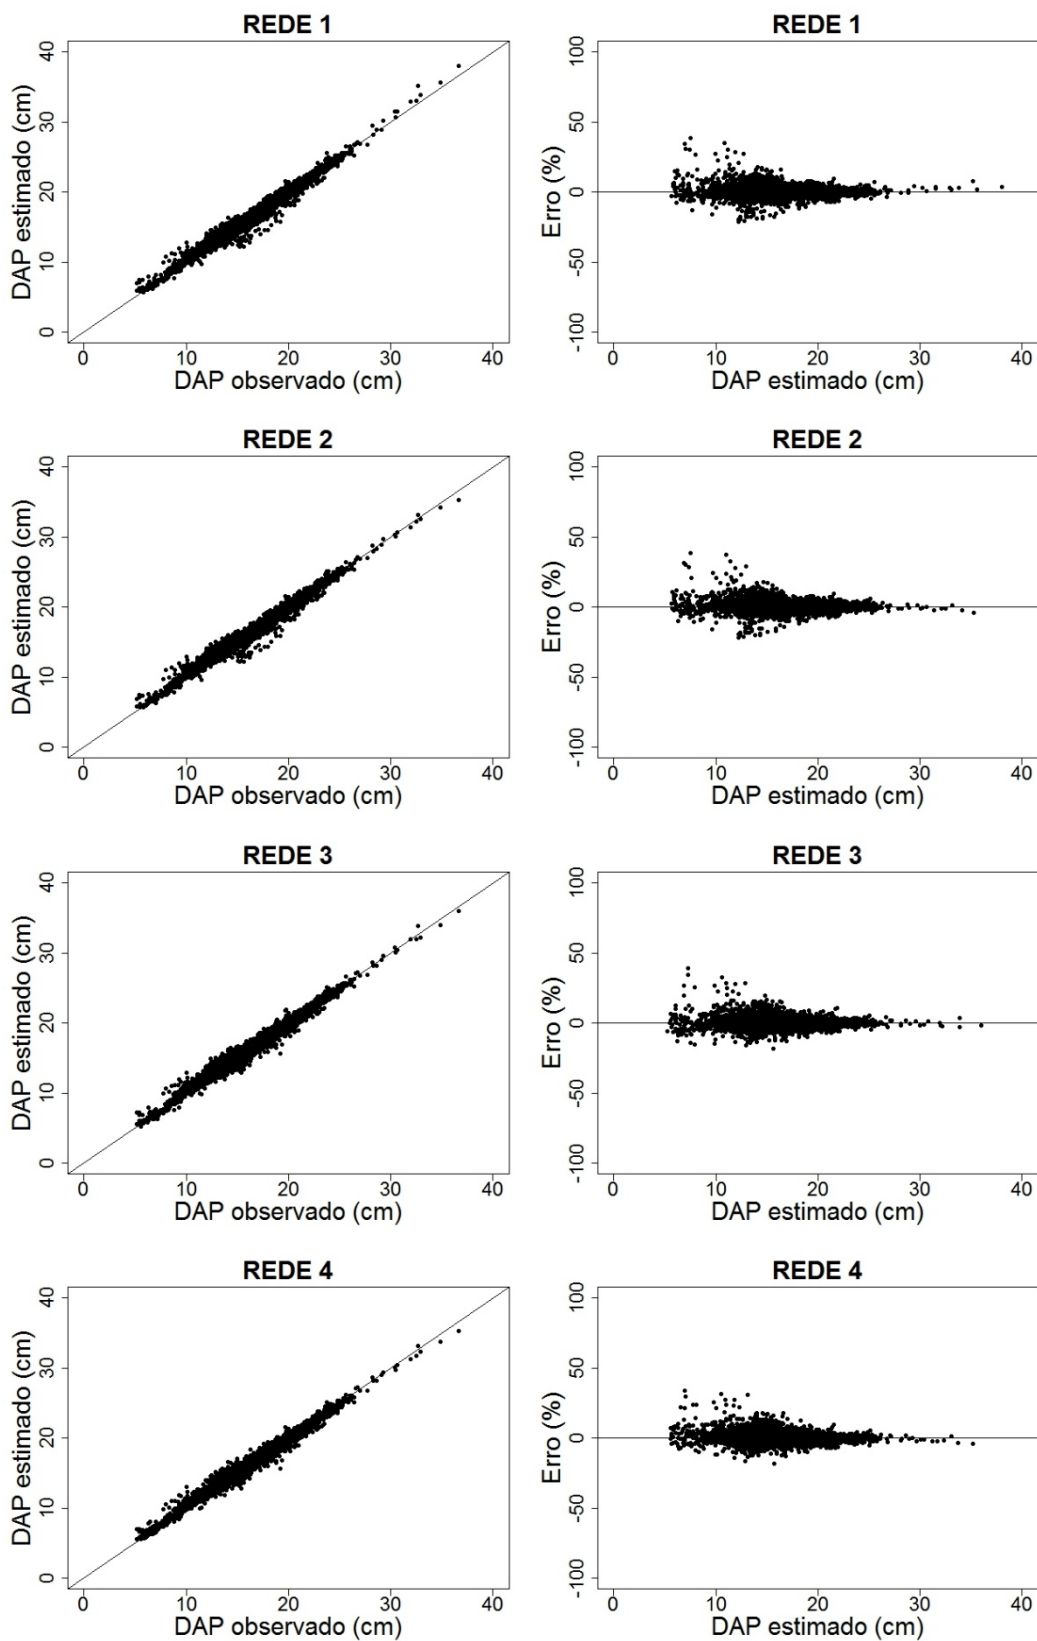
Em que: R² = coeficiente de determinação; V = Viés; MD = médias das diferenças absolutas; RQME = raiz do quadrado médio do erro.

O RQME variou de $\pm 0,5496$ a $\pm 0,5789$ para a projeção do crescimento em DAP e de $\pm 1,4078$ a $\pm 1,4315$ para a projeção do crescimento em altura. Castro et al. (2013) obteve RQME variando de $\pm 0,51$ a $\pm 0,67$ para o crescimento em DAP e $\pm 0,53$ a $\pm 0,64$ para crescimento em altura total.

Em geral, não houve muita variação com relação as configurações de redes para o crescimento em DAP e o crescimento em altura. O acréscimo da variável categórica material genético não aumentou de forma considerável a precisão das redes na estimativa para essa base de dados. No entanto, é uma variável que deve ser sempre avaliada devido ao fato de o crescimento variar de um material genético para outro.

Com base na análise gráfica do DAP estimado *versus* o DAP observado e gráfico dos resíduos *versus* valores estimados (Figura 8), é possível observar que a rede 4 teve um melhor ajuste e distribuição dos resíduos, sendo observado uma maior dispersão para valores abaixo de 15 cm.

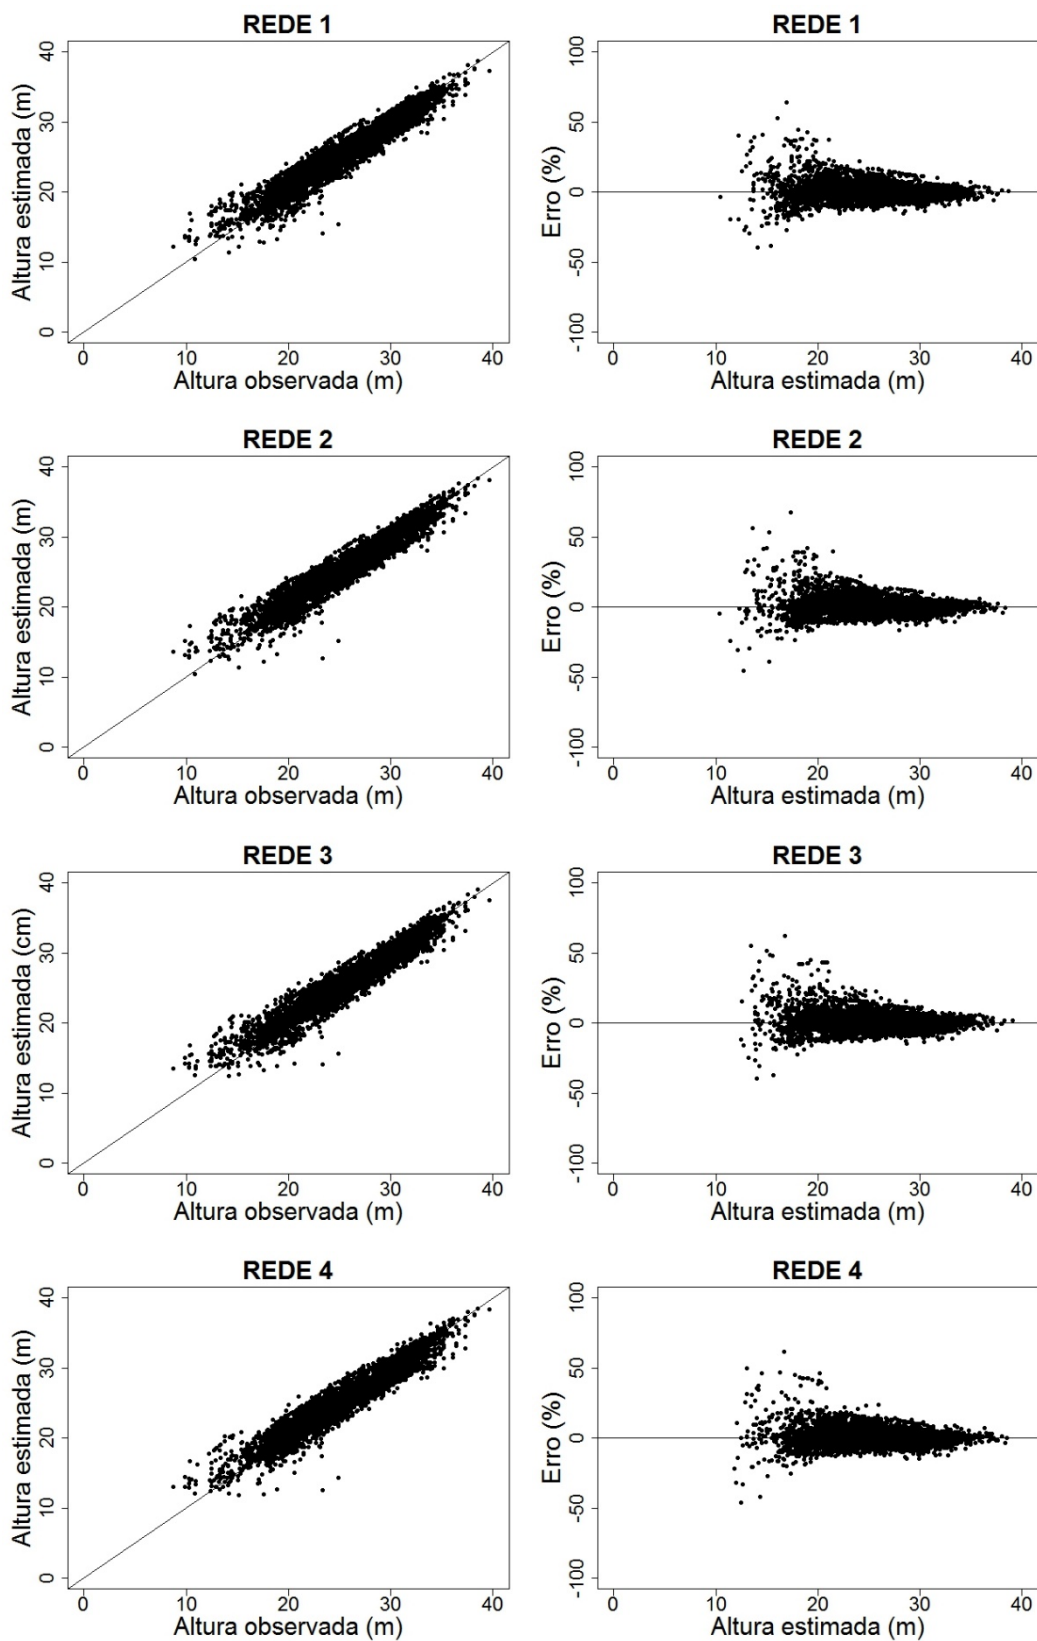
Figura 8 – Análise gráfica do DAP estimado *versus* o DAP observado e gráfico dos resíduos *versus* valores estimados.



Para a projeção do crescimento em altura (Figura 9), nota-se que a rede 2 e 4 foram as que tiveram melhor distribuição do resíduo. No geral, observa-se que os dados estão muito dispersos em relação a linha de tendência 1:1, obtida com os dados estimados *versus* observados. Foi observado uma maior dispersão dos dados para as árvores com alturas menores que 20 m.

Vospernick et al. (2010), estudando o crescimento em nível de árvore individual, afirma que tendências de sub ou superestimava ocorrem com frequência e são difíceis encontrar explicação para elas, sendo que geralmente ocorre superestimava para povoamentos com baixa densidade e subestimativa para povoamentos com alta densidade.

Figura 9 – Análise gráfica da altura total estimada versus a altura observada e gráfico dos resíduos *versus* valores estimados.



5.3.2. Sistema *Neuro-fuzzy* para estimar o crescimento em DAP e altura total.

Com relação às estatísticas utilizadas para avaliar o sistema *neuro-fuzzy* (Tabela 9), obteve-se coeficiente de determinação em torno de 0,98 para o crescimento em DAP e de 0,95 para o crescimento em altura total. O Viés variou de 0,0255 a 0,0430 para o crescimento em DAP e de 0,0718 a 0,1430 para o crescimento em altura. De uma forma geral o RQME foi maior que a técnica de redes neurais artificiais. Semelhante ao que ocorreu com as redes neurais artificiais, não foi observado maior precisão com a utilização da variável categórica material genético, assim como a classe de sítio. Não foi observado diferenças na precisão para os dois métodos analisados, o *Subtractive clustering* e o *Grid partition*. Para problemas com poucas variáveis o método *Grid partition* pode ser utilizado com desempenho satisfatório. Já para problemas maiores, esse método tem dificuldade em obter uma solução devido ao o número de regras de pertinência crescer exponencialmente. Para problemas em que o número de variáveis é maior, uma alternativa viável é o método *Subtractive clustering* em que é agrupado dados similares para facilitar o processamento (WEI, 2007).

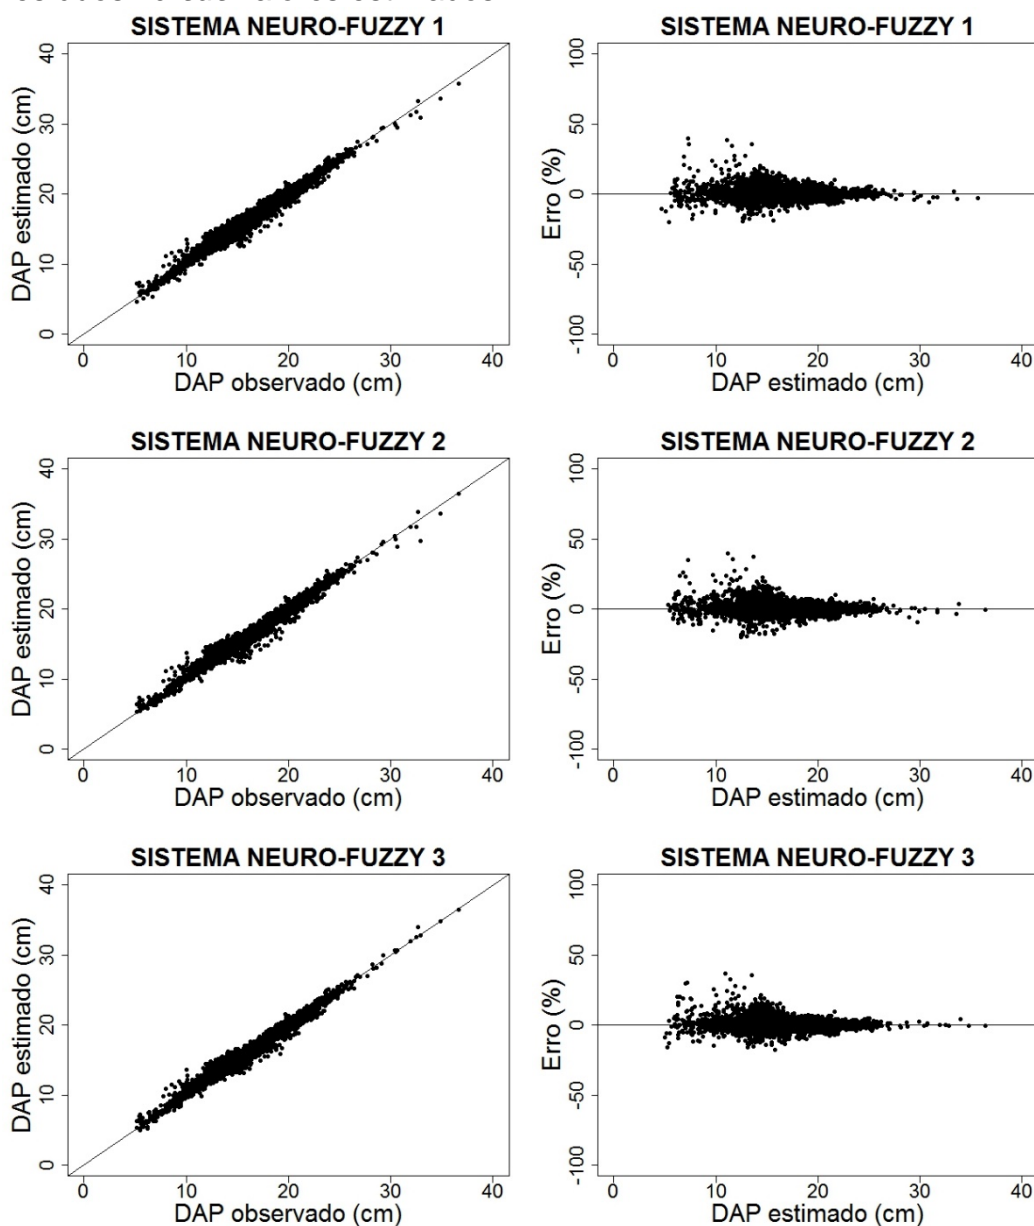
Tabela 9 – Indicadores estatísticos utilizados para avaliar as configurações dos sistemas *neuro-fuzzy* para estimar o crescimento em DAP e altura total

Sistema <i>Neuro-fuzzy</i>	Método	R ²	V	MD	RQME
DAP					
1	<i>Subtractive clustering</i>	0,9872	-0,0255	0,4115	0,5756
2	<i>Subtractive clustering</i>	0,9867	-0,0360	0,4218	0,5880
3	<i>Grid partition</i>	0,9873	-0,0430	0,4222	0,5742
H					
1	<i>Subtractive clustering</i>	0,9447	0,0718	1,2676	1,8988
2	<i>Subtractive clustering</i>	0,9502	-0,1142	1,1732	1,5431
3	<i>Grid partition</i>	0,9498	-0,1432	1,1731	1,5523

Em que: R² = coeficiente de determinação; V = Viés; MD = médias das diferenças absolutas; RQME = raiz do quadrado médio do erro.


Analisando o gráfico do DAP estimado *versus* o DAP observado e o gráfico dos resíduos *versus* valores estimados para o sistema *neuro-fuzzy* (Figura 10), observa-se que todos os três sistemas apresentaram uma maior dispersão dos dados para as árvores com DAP menor que 15 cm.

Figura 10 – Análise gráfica do DAP estimado *versus* o DAP observado e gráfico dos resíduos *versus* valores estimados



Com relação à análise gráfica da altura estimada *versus* a altura observada para o sistema *neuro-fuzzy* (Figura 11), nota-se que os dados estão mais dispersos com relação a linha de tendência 1:1 que as redes neurais artificiais. Com base no gráfico dos resíduos *versus* valores estimados é possível observar maior dispersão do resíduo para as árvores menores que 23 m de altura. No geral, o sistema *neuro-fuzzy* 1 foi o que apresentou pior desempenho, com tendências em superestimar e subestimar os dados. Esse problema pode ter ocorrido devido o método *Subtractive clustering* não ter criado os grupos adequados para a base de dados.

Figura 11 – Análise gráfica da altura total estimada versus a altura observada e gráfico dos resíduos *versus* valores estimados.



6. CONCLUSÕES

De acordo com os resultados obtidos, pôde-se concluir que:

- Com relação à competição, notou-se que o índice de competição independente da distância 5 – IID₅, proposto por Glover; Hool (1979), foi o que obteve a maior correlação com as variáveis idade, crescimento em DAP e altura.

- As técnicas de redes neurais artificiais e o sistema *neuro-fuzzy* tiveram boa precisão para estimar o crescimento em DAP e altura total de árvores de eucalipto.

- As técnicas abordadas podem ser utilizadas para a prognose do DAP e altura total de árvores de eucalipto.

7. REFERÊNCIAS BIBLIOGRÁFICAS

ADAME, P.; HYNYNEN, J.; CAÑELLAS, I.; RÍO, M. del. Individual-tree diameter growth model for rebollo oak (*Quercus pyrenaica* Willd.) coppices. **Forest Ecology and Management**, Amsterdam, v. 255, n. 3-4, p. 1011-1022, Mar. 2008.

ARTERO, A. O. **Inteligência artificial: teórica e prática**. São Paulo: Livraria da Física, 2009. 230p.

ASSMANN, E. **The principles of forest yield study**. New York: Pergamon, 1970. 506p.

AVERY, T. E.; BURKHATR, H. E. **Forest measurements**. 4. ed. New York: McGraw-Hill Book, 1994. 408p.

BARBALHO, V. M. de S. **Sistemas baseados em conhecimento e Lógica Difusa para simulação do Processo Chuva-Vazão**. 2001. 94 f. Tese (Doutorado em Engenharia Civil) – Faculdade de Engenharia Civil, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2001.

BIGING, G. S.; DOBBERTIN, M. A comparison of distance-dependent competition measures for height and basal area growth of individual conifer trees. **Forest Science**, Bethesda, v. 38, n. 3, p. 695-720, Aug. 1992.

BRAGA, A. P.; CARVALHO, A. P. L. F.; LUDEMIR, T. B. **Redes neurais artificiais: teoria e aplicações**. Rio de Janeiro: Editora LTC, 2007. 262p.

BUFORD, M. A.; HAFLEY, W. L. Probability distributions as models for mortality. **Forest Science**, Bethesda, v. 31, n. 2, p. 331-341, June 1985.

CALOBA, G. M.; CALOBA, L. P.; SALIBY, E. Cooperação entre redes neurais artificiais e técnicas "clássicas" para previsão de demanda de uma série de vendas de cerveja na Austrália. **Pesquisa Operacional**, Rio de Janeiro, v. 22, n. 3, p. 345-358, jul.-dez. 2002.

CAMPOS, J. C. C; LEITE, H. G. **Mensuração florestal: perguntas e respostas**. 4. ed. Viçosa: UFV, 2013. 548 p.

CAO, Q. V. A method to distribute mortality in diameter distribution models. **Forest Science**, Bethesda, v. 43, n. 3, p. 435-442, Aug. 1997.

CASTRO, R. V. O. et al. Individual growth model for *Eucalyptus* stands in Brazil using artificial neural network. **ISRN Forestry**, [S.l.], v. 2013, p. 1-12, 2013.

CHASSOT, T. **Modelos de crescimento em diâmetro de árvores individuais de *Araucaria angustifolia* (Bertol.) Kuntze na floresta ombrófila mista.** 2009, 48 f. Dissertação (Mestrado em Engenharia Florestal) – Universidade Federal de Santa Maria, Santa Maria, 2009.

CHASSOT, T. et al. Modelos de crescimento em diâmetro de árvores individuais de *Araucaria angustifolia* (Bertol.) Kuntze na Floresta Ombrófila Mista. **Ciência Florestal**, Santa Maria, v. 21, n. 2, p. 303-313, abr.-jun. 2011.

CRECENTE-CAMPO, F.; MARSHALL, P.; SOALLEIRO, R. R. Modeling non-catastrophic individual-tree mortality for *Pinus radiata* plantations in northwestern Spain. **Forest Ecology and Management**, Amsterdam, v. 257, n. 6, p. 1542-1550, Mar. 2009.

CRIMMINS, F. **A genetic algorithm for clustering point sets.** Medford: Tufts University, 2001. Technical Report

DANIELS, R. F. Simple competition indices and their correlation with annual *Loblolly pine* tree growth. **Forest Science**, Bethesda, v. 22, n. 4, p. 454-456, Dec.1976.

DANIELS, R. F.; BURKHART, H. E.; CLASON, T. R. An comparison of competition measures for predicting growth of *Loblolly pine* trees. **Canadian Journal of Forest Research**, Ottawa, v. 16, n. 6, p. 1230-1237, Dec. 1986.

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

FAUSETT L. V. Analysis of Dynamics of Clustering Neural Networks. In: BAINOV, D.; COVACHEV, V. (eds.). INTERNATIONAL COLLOQUIUM ON DIFFERENTIAL EQUATIONS, 5th. **Proceedings...**, Zeist, The Netherlands: VSP, International Science Publishers, 1995, p. 103-112.

FOX, J. C.; BI, H.; ADES, P. K. Spatial dependence and individual-tree growth models: I. Characterising spatial dependence. **Forest Ecology and Management**, Amsterdam, v. 245, n. 1-3, p. 10-19, June 2007.

GLOVER, G. R.; HOOL, J. N. A basal area ratio predictor of loblolly pine plantation mortality. **Forest Science**, Bethesda, v. 25, n. 2, p. 275-282, June 1979.

GONZÁLEZ, M. S.; RÍO, M. del; CAÑELLAS, I.; MONTERO, G. Distance independent tree diameter growth model for cork oak stands. **Forest Ecology and Management**, Amsterdam, v. 225, n. 1-3, p. 262-270, Apr. 2006.

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

HAGAN, M. T, MENHAJ, M. B. Training feedforward networks with the marquardt algorithm. **IEEE Transactions on Neural Networks**, [S.l.], v. 5, n. 6, Nov. 1994.

HAMILTON JR., D. A. A logistic model for mortality in thinned and unthinned mixed conifer stands of northern Idaho. **Forest Science**, Bethesda, v. 32, n. 4, p. 989-1000, Dec.1986.

HASENAUER, H. Princípios para a modelagem de ecossistemas florestais. **Ciência e Ambiente**, Santa Maria, v. 20, n. 1, p. 53-69, 2000.

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

INDÚSTRIA BRASILEIRA DE ÁRVORES – IBÁ. **IBÁ 2014: ano base 2013**. Brasília: IBÁ, 2014. 100p.

JANG, J.-S. R. Anfis: Adaptive-network-based fuzzy inference systems. **IEEE Transactions on Systems, Man, and Cybernetics**, [S.l.], v. 23, p. 714-723, May-June 1993.

JUNQUEIRA, L. C.; CARNEIRO, J. **Histologia básica**. 12. ed. Rio de Janeiro: Guanabara Koogan, 2013. 556p.

LEITE, L. DA C. M. **Geração e simplificação da base de conhecimento de um sistema híbrido fuzzy-genético**. 2009. 110 f. Dissertação (Mestrado em Ciência Florestal) – Universidade do Estado do Rio de Janeiro, Rio de Janeiro, 2009.

LENKE, A. P. **Solução computacional para um sistema de avaliação da qualidade dos serviços em instituições de ensino superior, baseado nos parâmetros do PQSP**. 2005. 94 f. Monografia (Bacharelado em Ciência da Computação) – Universidade Federal de Pelotas, Pelotas, 2005.

LIMA, A. M. N. et al. Frações da matéria orgânica do solo após três décadas de cultivo de eucalipto no Vale do Rio Doce-MG. **Revista Brasileira de Ciência do Solo**, Viçosa, v. 32, n. 3, p. 1053-1063, maio.-jun. 2008.

LIPPNANN, R. An introduction to computing with neural nets. **IEEE ASSP Magazine**, [S.l.], v. 4, n. 2, p. 4-22, Apr. 1987.

MAMDANI, E. H. Applications of fuzzy algorithms for control of a simple dynamic plant. **Proceedings of the IEEE**, [S.l.], v. 121, n. 12; p. 1585-1588, 1974.

MARTINS, F. B.; SOARES, C. P. B.; LEITE, H. G.; SOUZA, A. L.; CASTRO, R. V. O.

Índices de competição em árvores individuais de eucalipto. **Pesquisa Agropecuária Brasileira**, Brasília, v. 46, n. 9, p. 1089-1098, set. 2011.

MARTINS, F. B.; SOARES, C. P. B.; SILVA, G. F. DA. Individual tree growth models for eucalyptus in northern Brazil. **Scientia Agricola**, Piracicaba, v. 71, n. 3, p. 212-225, jun. 2014.

MARTINS, F. B. **Modelagem de crescimento em nível de árvore individual para plantios comerciais de eucalipto**. 2011. 143 f. Tese (Doutorado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa, 2011.

MONSERUD, R. A.; STERBA, H. Modeling individual tree mortality for Austrian forest species. **Forest Ecology and Management**, Amsterdam, v. 113, n. 2, p. 109-123, Jan. 1999.

MORAVIE, M.-A.; DURAND, M.; HOULLIER, F. Ecological meaning and predictive ability of social status vigour and competition indices in a tropical rainforest (India). **Forest Ecology and Management**, Amsterdam, v.117, n. 1-3, p.221-240, May 1999.

PAGLIOSA, A. L. **Obtenção das funções de pertinência de um sistema neurofuzzy modificado pela rede de Kohonen**. 2003. 182 f. Dissertação (Mestrado em Automação Industrial) – Universidade do Estado de Santa Catarina, Joinville, 2003.

PAL, S., MITRA, P. **Case Generation: A Rough-fuzzy Approach**, Workshop em Soft Computing in Case-Based Reasoning, International Conference on Case-Based Reasoning, ICCBR'01 Vancouver, British Columbia, Canada. 1992.

RÉ, A. M. **Um método para identificar características predominantes em empreendedores que obtiveram sucesso utilizando um sistema neurodifuso**. 2000. 260 f. Tese (Doutorado em Engenharia da Produção) – Universidade Federal de Santa Catarina, Florianópolis, 2000.

SCOLFORO, J. R. S. **Biometria Florestal: modelos de crescimento e produção florestal**. Lavras: UFLA/FAEPE, 2006. 393 p.

SHAO, G.; SHUGART, H. H. A compatible growth-density stand model derived from a distance-dependent individual tree model. **Forest Science**, Bethesda, v. 43, n. 3, p. 443-446, Aug. 1997.

SHAW, I. S.; SIMÕES, M. G. **Controle e modelagem fuzzy**. 2. ed. São Paulo: Editora Edgard Blücher, 2007. 200p.

SILVA, I. A. F. **Aplicações de redes neurais e neuro fuzzy em engenharia biomédica e agronomia**. 2014. 80 f. Tese (Doutorado em Engenharia Elétrica) –

Faculdade De Engenharia de Ilha Solteira, Universidade Estadual Paulista “Júlio de Mesquita Filho”, Ilha Solteira, 2014.

SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. **Redes Neurais Artificiais:** para engenharia e ciências aplicadas. São Paulo: Artliber, 2010. 393p.

SOMERS, G. L. et al. Predicting mortality with a weibull distribution. **Forest Science**, Bethesda, v. 26, n. 2, p. 291-300, June 1980.

STAGE, A. R. **Prognosis model for stand development.** Research Paper INT-137. Ogden: USDA Forest Service 1973. 32 p. (Intermountain Forest & Range Experiment Station, Ogden, Utah 84401.)

SUGENO, M.; KANG, G. T. Structure identification of fuzzy model. **Fuzzy Sets and Systems**, [S.I.], v. 28, n. 1, p. 15-33, Oct. 1988.

TANAKA, K. **An introduction to fuzzy for practical application.** New York, EUA: Springer, 1997. 148p.

TANAKA, K. **An Introduction to Fuzzy Logic for Practical Applications.** Kanazawa, Japão: Kanazawa University, 1991.

TOMÉ, M.; BURKHART, H. E. Distance-dependent competition measures for predicting growth of individual tree. **Forest Science**, Bethesda, v. 35, n. 3, p. 816-831, Sept. 1989.

VOSPERNIK, S.; MONSERUD, R. A.; STERBA, H. Do individual-tree growth models correctly represent height: diameter ratios of Norway spruce and Scots pine? **Forest Ecology and Management**, Amsterdam, v. 260, n. 10, p. 1735- 1753, Oct. 2010.

WARING, R. H. Characteristics of trees predisposed to die. **BioScience**, Amsterdam, v. 37, n. 8, p. 569-574, Sept. 1987.

WATKINSON, A. R.; LONDSDALE, W. M.; FIRBANK, L. G. A neighborhood approach to self-thinning. **Oecologia**, Berlin, v. 56, n. 2-3, p. 381-384, Feb. 1983.

WEI, M. et al. Predicting injection profiles using ANFIS. **Information Sciences**, [S.I.], v. 177, n. 20, p. 4445-4461, Out. 2007.

WEINER, J.; THOMAS, S. C. Size variability and competition in plant monocultures. **Oikos**, Copenhagen, v. 47, n. 2, p. 211-222, Sept. 1986.

WEST, P. W. Simulation of diameter growth and mortality in regrowth eucalypt forest of southern Tasmania. **Forest Science**, Bethesda, v. 27, n. 3, p. 603-616, Sept. 1981.

WUERGES, A. F. E.; BORBA, J. A. Redes neurais, lógica nebulosa e algoritmos genéticos: aplicações e possibilidades em finanças e contabilidade. **JISTEM Journal of Information Systems and Technology Management**, São Paulo, v. 7, n. 1, p. 163-182, abr. 2010.

YANG, Y.; TITUS, S. J.; HUANG, S. Modeling individual tree mortality for white spruce in Alberta. **Ecological Modeling**, Amsterdam, v. 163, n. 3, p. 209-222, May 2003.

ZADEH L. A. Fuzzy sets as a basis for a theory of possibility. **Fuzzy Sets and Systems**, [S.I.], v. 1, n. 1, p. 3-28, Jan. 1978.

ZADEH, L. A. Fuzzy Sets. **Information and Control**, v. 8; n. 3, p. 338-353, June 1965.

ZHANG, S.; AMATEIS, R. L.; BURKHART, H. E. Constraining individual tree diameter increment and survival models for loblolly pine plantations. **Forest Science**, Bathesda, v. 43, n. 3, p. 414-423, Aug, 1997.