

GLEIMAR BOTELHO BALEEIRO

MODELAGEM *NEURO-FUZZY* NA ESTIMATIVA DE VOLUME DE *EUCALYPTUS sp*

Monografia de graduação apresentada ao Departamento de Ciência da Computação da Universidade Federal de Lavras como parte das exigências do curso de Ciência da Computação para a obtenção do título de Bacharel em Ciência da Computação.

LAVRAS

MINAS GERAIS – BRASIL

2007

GLEIMAR BOTELHO BALEEIRO

MODELAGEM *NEURO-FUZZY* NA ESTIMATIVA DE VOLUME DE *EUCALYPTUS sp*

Monografia de graduação apresentada ao Departamento de Ciência da Computação da Universidade Federal de Lavras como parte das exigências do curso de Ciência da Computação para a obtenção do título de Bacharel em Ciência da Computação.

Área de concentração:

Inteligência Artificial

Orientador / Co-orientador

Prof. Dr. Ricardo Martins de Abreu Silva

Msc. Adriano Ribeiro de Mendonça

LAVRAS

MINAS GERAIS – BRASIL

2007

**Ficha Catalográfica preparada pela Divisão de Processo Técnico da Biblioteca Central da
UFLA**

Baleeiro, Gleimar Botelho

Modelagem *Neuro-Fuzzy* na estimativa do Volume de *Eucalyptus* sp /Gleimar Botelho
Baleeiro. Lavras – Minas Gerais, 2007.48p. :il.

Monografia de Graduação - Universidade Federal de Lavras. Departamento de Ciência
da Computação.

1. Inteligência Artificial. 2. Lógica *Fuzzy*.3.*Neuro-Fuzzy* BALEEIRO, G. B. . II.
Universidade Federal de Lavras. III. Título.

GLEIMAR BOTELHO BALEEIRO

MODELAGEM *NEURO-FUZZY* NA ESTIMATIVA DE VOLUME DE *EUCALYPTUS sp*

Monografia de graduação apresentada ao Departamento de Ciência da Computação da Universidade Federal de Lavras como parte das exigências do curso de Ciência da Computação para a obtenção do título de Bacharel em Ciência da Computação.

Aprovada em 6 de agosto de 2007

Prof. Thiago de Souza Rodrigues

Prof. Cláudio Fabiano Motta Toledo

Prof. Dr. Ricardo Martins de Abreu Silva
(Orientador)

Prof. Adriano Ribeiro de Mendonça
(Co-Orientador)

LAVRAS
MINAS GERAIS – BRASIL

2007

Dedico aos meus pais, Carlos Leal e Maria Sirlene, pelo amor, incentivo e apoio em todos os momentos da minha vida. Aos meus irmãos, Carla e Charles pelo incentivo. A minha família por sempre estarem presente. Aos meus orientadores, Ricardo e Adriano que me ajudaram na construção deste trabalho.

Agradecimentos

A Deus pela fé e perseverança concedidos em todos os momentos da vida.

Aos meus pais, Carlos Leal e Maria Sirlene que sempre mostraram o caminho certo a ser seguido e que sempre colocaram como prioridade a formação de seus filhos.

Aos meus irmãos Carla Gabriela e Charles pela amizade e incentivo.

Aos meus orientadores Ricardo e Adriano, pela atenção e disposição na construção deste trabalho.

Aos colegas que ajudaram na construção deste trabalho, Fillipe (Siriema), Danilo (Júnior), Felipe e Alexandre.

A galera do grupo Catingueiros, e ao pessoal do 209 e 210 do brejão, em especial ao amigo japonês Shigueto.

Aos Amigos, Emiliane, Michelle, Viviane, Rafael, Rodrigo e Fabrício pelo companheirismo.

Enfim, a todos aqueles que tenham contribuído, direta ou indiretamente, para a realização deste trabalho, deixo registrado os meus sinceros agradecimentos.

MODELAGEM *NEURO-FUZZY* NA ESTIMATIVA DE VOLUME DE *EUCALYPTUS sp*

RESUMO

A madeira proveniente do *Eucalyptus* possui uma grande influência na economia nacional. Por ser de grande importância, vários estudos foram realizados com o intuito de tirar melhor proveito das áreas plantadas. Uma das informações de maior importância para o conhecimento do potencial florestal disponível numa região é o volume total das árvores. Logo, vários estudos foram realizados com o intuito de solucionar esse problema, já que sua obtenção não é fácil. Este trabalho implementa um novo modelo de estimativa do volume usando o sistema híbrido *Neuro-Fuzzy*. Os resultados obtidos mostraram que o modelo proposto apresentou melhores resultados que os modelos clássicos.

Palavras-Chave: Inteligência Artificial, Lógica Fuzzy, Redes Neurais, Neuro-Fuzzy.

MODELING *NEURO-FUZZY* IN THE ESTIMATE OF VOLUME OF *EUCALYPTUS sp*

ABSTRACT

The wood proceeding from the *Eucalyptus* possess a great influence in the national economy. By being of great importance, some studies had been carried through with intention to take off advantage of the planted areas better. One of the information of bigger importance for the knowledge of the available forest potential in a region is the total volume of the trees. Soon, some studies had been carried through with intention to solve this problem, since its attainment is not easy. This work implements a new model of estimate of the volume using the hybrid system *Neuro-Fuzzy*. The gotten results had shown that the considered model presented better resulted that the classic models.

Key-Words: Artificial Intelligence, Fuzzy Logic, Neural Network, Neuro-Fuzzy.

SUMÁRIO

LISTA DE FIGURAS	xv
LISTA DE TABELAS	xvi
LISTA DE ABREVIATURAS	xvii
LISTA DE ABREVIATURAS	xvii
1. INTRODUÇÃO	1
2. REVISÃO DE LITERATURA	2
2.1. O gênero <i>Eucalyptus</i>	2
2.2. Volume.....	3
2.2.1. Cubagem rigorosa.....	4
2.2.2. Modelagem do volume total.....	5
2.3. Lógica Fuzzy.....	6
2.3.1. Conjuntos <i>Fuzzy</i>	7
2.3.2. Inferência.....	9
2.4. Redes Neurais	11
2.4.1. Características das Redes Neurais	12
2.4.2. Treinamento da Rede.....	14
2.5. <i>Neuro-Fuzzy</i>	16
2.5.1. Construção automática de Sistemas <i>Fuzzy</i>	16
2.5.2. Arquitetura ANFIS	17
3. MATERIAIS E MÉTODOS	19
3.1. Tipo de pesquisa	19
3.2. Obtenção dos dados	19
3.3. Procedimentos metodológicos	21
3.4. Modelos comparados	21
3.5. Modelo proposto	22
3.6. Avaliação dos modelos	24
4. RESULTADOS E DISCUSSÃO	26
4.1. Avaliação do ajuste dos modelos volumétricos e conjunto de treino do Neuro-Fuzzy ...	26
4.2. Avaliação da validação dos modelos avaliados	29
5. CONCLUSÕES.....	34

LISTA DE FIGURAS

Figura 2.1 - Esquema apresentando uma seção de uma árvore e suas dimensões.	5
Figura 2.2 - Conjuntos 'Crisps' versus <i>Fuzzy</i>	7
Figura 2.3 - Pertinência dos números iguais a 5.....	8
Figura 2.4 - Métodos de Inferência <i>Fuzzy</i>	9
Figura 2.5 - Sistema de Inferência <i>Fuzzy</i> . Fonte: Tanscheit (2000).	10
Figura 2.6 - Estrutura de um neurônio artificial. Fonte: Paiva (1999)	13
Figura 2.7 - Arquitetura ANFIS Fonte: BARVALHO (2001).	18
Figura 3.1- Distribuição de frequência das idades das árvores-amostras utilizadas para o ajuste dos modelos volumétricos e o treino do <i>neuro-fuzzy</i>	20
Figura 3.2 - Distribuição de frequência das idades das árvores-amostras utilizadas para a validação dos modelos avaliados.	20
Figura 3.3 - Conjuntos <i>fuzzy</i> para a idade	23
Figura 3.4 - Conjuntos <i>fuzzy</i> para o DAP.....	23
Figura 3.5- Conjuntos <i>fuzzy</i> para a altura.....	23
Figura 4.1 - Distribuição residual do volume em função do volume total para <i>neuro-fuzzy</i>	27
Figura 4.2 - Distribuição residual do volume em função do volume total para Schumacher e Hall.	27
Figura 4.3 - Distribuição residual do volume em função do volume total para Spurr.	28
Figura 4.4 - Distribuição residual do volume em função do volume total para <i>neuro-fuzzy</i> com o conjunto de checagem.	30
Figura 4.5 - Distribuição residual do volume em função do volume total para Schumacher e Hall com o conjunto de checagem.	31
Figura 4.6 - Distribuição residual do volume em função do volume total para Spurr com o conjunto de checagem.	31

LISTA DE TABELAS

Tabela 4.1 - Medidas de precisão para os modelos avaliados	26
Tabela 4.2 - Estatísticas “bias” (B), média das diferenças absolutas (MD) e desvio padrão das diferenças (DPD) para as estimativas do volume total.	28
Tabela 4.3 - Notas atribuídas, a partir das estatísticas da Tabela 4.2, para as estimativas do volume total.....	29
Tabela 4.4 - Medidas de precisão para o conjunto de validação	30
Tabela 4.5 - Estatísticas “bias” (B), média das diferenças absolutas (MD) e desvio padrão das diferenças (DPD) para as estimativas do volume total	32
Tabela 4.6 - Notas atribuídas, a partir das estatísticas da Tabela 4.5, para as estimativas do volume total.....	32

LISTA DE ABREVIATURAS

RNA – Redes Neurais Artificiais

FIS – Fuzzy Inference System

SNF – Sistema Neuro-Fuzzy

RBF – Radial Basis Function

1.INTRODUÇÃO

Na atualidade, o Brasil possui cerca de 6 milhões de hectares em área reflorestada, sendo 61% ocupada por várias espécies de *Eucalyptus* segundo a Embrapa. Em uma perspectiva mundial, estima-se que 40% da área plantada estejam no Brasil. A explicação pela vasta área plantada, vem do fato do *Eucalyptus* ter larga aplicação na indústria, e o clima favorável.

Por ser uma madeira que pode ser aproveitada no segmento de indústria de papel e celulose, siderurgia a carvão vegetal, lenha, serrado, compensados e lâminas, o *Eucalyptus* tem uma grande influência na economia nacional. Essa influência vai desde geração de empregos à contribuição no PIB à exportação (agronegócio).

Outro fator que impulsiona novos estudos é o fato de que as áreas de plantio de *Eucalyptus* sofrerão competição das áreas agrícolas, obrigando o setor a obter uma maior produtividade da área plantada.

Uma das informações de maior importância para o conhecimento do potencial florestal disponível em uma região é o volume. Devido à essa importância, vários estudos foram realizados para que se possa obter de forma satisfatória o volume.

Os métodos usados para cálculo do volume vão desde deslocamento de água pelo princípio de Arquimedes, cubagem rigorosa e o uso de equações de regressão.

No sentido de melhorar as estimativas do volume total de *Eucalyptus*, foi feita uma abordagem usando *Neuro-Fuzzy*, que é um modelo híbrido que combina redes neurais e lógica *fuzzy*. Essa nova abordagem se propõe a criar um modelo mais poderoso (em termos de poder de interpretação, de aprendizado, de estimativa de parâmetros, etc.) para a obtenção de melhores resultados. Isso é obtido através da junção do conhecimento explícito de um especialista e o conhecimento implícito inerente a um conjunto de dados.

2. REVISÃO DE LITERATURA

2.1. O gênero *Eucalyptus*

Originário da Austrália, o gênero *Eucalyptus*, pertencente à família Myrtaceae teve seu plantio intensificado no Brasil no início deste século, sendo usado durante algum tempo como dormentes nas ferrovias, lenha para as marias-fumaça e mais tarde como poste para edificação de linha.

Ao final dos anos 20, o *Eucalyptus* começou a ser aproveitado como carvão vegetal, passando a ser utilizado nas siderúrgicas mineiras na fabricação de ferro-gusa. Com isso, novas aplicações foram desenvolvidas.

Atualmente, verifica-se uma tendência de troca de madeiras oriundas de florestas naturais por madeiras de reflorestamento. O gênero *Eucalyptus* aparece como uma alternativa promissora devido principalmente ao seu rápido crescimento e às tecnologias já desenvolvidas para sua produção, fato incomum para outras espécies florestais (SERPA, 2003).

Atualmente o Brasil possui cerca de 6 milhões de hectares em área reflorestada, sendo 61% ocupada com *Eucalyptus* sp. (EMBRAPA, 2003). Devido ao clima tropical ou subtropical na maioria do território brasileiro, tem-se utilizado muito o gênero *Eucalyptus* em larga escala nas florestas industriais. Devido ao clima, o território brasileiro propicia um crescimento ininterrupto, e conseqüentemente, um rápido acúmulo de biomassa. Para exemplificar o quanto é propício o clima do território brasileiro, a idade de rotação de plantios de *Eucalyptus* no Brasil está entre 5 e 7 anos, enquanto que em países de clima temperado este tempo de rotação salta para aproximadamente 12 anos (EMBRAPA, 2003). Além disso, o Brasil ocupa uma posição de liderança mundial em silvicultura e melhoramento de *Eucalyptus* devido à atividade agroindustrial e o apoio de instituições governamentais de pesquisa e Universidades.

A indústria de base florestal é estratégica para o Brasil devido ao seu perfil fortemente exportador. Isso contribui para a realização do superávit da balança comercial, propiciando as condições econômicas necessárias à promoção do desenvolvimento social.

O setor florestal já responde pela segunda posição na balança comercial do agromercado brasileiro. No período de setembro de 2002 a setembro de 2003, celulose, papel e produtos sólidos de madeira acumularam exportações de US\$ 5,1 bilhões. A liderança desse ranking é ocupada pelo complexo agroindustrial da soja, que faturou US\$ 7,7 bilhões no mesmo período (Por dentro..., 2003).

Estima-se que o setor florestal no Brasil seja responsável pela existência de 500 mil empregos diretos e outros 2 milhões indiretos. Desse total, somente o segmento de celulose e papel responde por 150 mil empregos diretos. Em termos tributários, o setor também dá uma demonstração de força, pois a estimativa é de uma arrecadação anual de US\$ 4,6 bilhões em impostos.

Abaixo são listadas as utilidades do *Eucalyptus*:

- Óleos essenciais: fármacos, produtos de higiene, produtos de limpeza e alimentos;
- Produtos apícolas: mel, própolis e geléia real;
- Celulose: papéis diversos (impressão, cadernos, revistas), absorvente íntimo, papel higiênico, guardanapo, fralda descartável, viscose, tencel (roupas), papel celofane, filamento (pneu); acetato (filmes); ésteres (tintas); cápsulas para medicamentos, espessantes para alimentos e componentes eletrônicos;
- Madeira Serrada: móveis, construção civil e Brinquedos;
- Postes e moirões;
- Laminados, MDF, HDF, chapa de fibra e compensados;
- Carvão e lenha.

2.2. Volume

O volume de uma árvore constitui uma das informações de maior importância para o conhecimento do potencial florestal disponível em uma região, sendo que o volume individual fornece um ponto de partida para a avaliação do conteúdo de madeira dos povoamentos florestais (BARBALHO, 2001). O volume de uma árvore sofre influência de

vários fatores, dentre eles destacam-se o material genético (semente ou clone), características edafo-climáticas do sítio onde foi plantada e práticas de manejo adotadas.

A forma de determinar o volume é pelo método do deslocamento de água seguindo o Princípio de Arquimedes, ou seja, as toras são colocadas em tanques cheios de água e, a partir do deslocamento da água, obtém-se o volume das toras. Essa forma de obtenção do volume é de difícil aplicação em inventários florestais devido ao tempo gasto na obtenção tornando-a prática inviável economicamente e tecnicamente. Outras metodologias de obtenção de volume de madeira é a prática de cubagem rigorosa e estimativa de volume por meio de equações de regressão.

2.2.1. Cubagem rigorosa

Os troncos de muitas espécies de árvores apresentam formas semelhantes a algum sólido geométrico definido – os protótipos dendrométricos. Dentre estes, os mais conhecidos são: o cilindro, o neilóide, o parabolóide e o cone. Entretanto, na prática, observa-se que os troncos nunca se identificam com um único protótipo dendrométrico, pois num mesmo tronco podem ocorrer várias formas, além disso, a transição de uma forma para outra não pode ser exatamente determinada no tronco (LOETSCH et al, 1973).

Para contornar esse problema, o tronco da árvore é dividido em seções (toras) e fórmulas aproximativas são empregadas para obter o volume de cada seção. O volume do tronco da árvore, conseqüentemente, é dado pelo somatório dos volumes das seções (CAMPOS, 1993). Dessas expressões, três são as mais conhecidas: Huber, Smalian e Newton. O volume de uma seção do tronco, então, pode ser obtido por:

a) Huber

$$v_i = g_m \cdot L$$

b) Smalian

$$v_i = \left(\frac{g_i + g_s}{2} \right) \cdot L$$

c) Newton

$$v_i = \left(\frac{g_i + 4g_m + g_s}{6} \right) \cdot L$$

Em que:

g_i = área seccional da seção 1;

g_s = área seccional da seção 2;

g_m = área seccional na metade do comprimento da seção

L = comprimento da seção.

v_i = volume da i -ésima seção, com ou sem casca, em m^3 .

A Figura 2.1 apresenta a localização das variáveis no tronco:




Figura 2.1 - Esquema apresentando uma seção de uma árvore e suas dimensões.

Após o cálculo do volume das seções, faz-se o somatório das seções e obtém-se o volume total da árvore.

2.2.2. Modelagem do volume total

As maiorias dos modelos de regressão utilizadas para estimar volume total de árvores individual baseiam-se em medidas de diâmetro a 1,30 metros do solo (DAP) e altura total (H) como variáveis independentes.

Campos e Leite (2002) citam que o modelo de Schumacher e Hall (1939) tem sido o mais difundido, talvez por suas propriedades estatísticas, uma vez que resulta quase sempre em estimativas não-tendenciosas. Estes mesmos autores citam que a difusão do modelo de Spurr (1952) deve ser atribuída mais à facilidade do ajustamento, pois, com frequência, volumes de árvores menores são estimados com imprecisão.

Couto e Vetorazzo (1999) estudaram diferentes modelos para estimar volume e peso seco (com e sem casca) comercial de *Pinus taeda*. Com base nos resultados, pôde-se concluir que o modelo de Spurr (1952) foi o que apresentou os melhores resultados para estimar volume e peso comercial, com e sem casca, para árvores com 6 anos de idade e para o total das árvores das duas idades estudadas.

Veiga et al. (2000) estudando equações para estimar o volume de árvores de *Acacia mangium* Willd, concluiu que o melhor modelo foi o de Meyer seguido do modelo de Schumacher na forma logarítmica.

Machado et al. (2002) modelando o volume de árvores de *Pinus oocarpa* em diferentes idades e regimes de desbastes destacaram que o modelo de Schumacher e Hall (1939) embora não tenha obtido a melhor pontuação tanto com relação ao R^2 ajustado quanto ao erro padrão relativo, apresentou ótima distribuição gráfica dos resíduos. Este fato a caracteriza como um modelo também indicado para uso como equação de volume para todos os tratamentos da presente pesquisa.

2.3. Lógica Fuzzy

Proposta por ZADEH (1965), a lógica *fuzzy* mostra-se como o fundamento de qualquer outra lógica, independente de quão correto estejam os valores em questão. Sua concepção se deu em meio à dificuldade de classificação de conjuntos que não possuíam fronteiras bem definida, ou seja, a transição entre conjuntos é suave e não abrupta. Ao permitir a participação parcial dos elementos de um conjunto, transições suaves de uma regra para outra são possíveis. Tal propriedade é desejável para modelagem e controle de sistemas (YAGER & FILEV, 1994).

Para NAGAMINE (2001), a proposta de um modelo difuso é capturar o funcionamento de um sistema com sua construção podendo ser vista como um processo em

que uma coleção de objetos chamados variáveis ou parâmetros do modelo, que carregam as características do modelo, são relacionados a outros objetos ditos conectivos ou operadores do modelo. Dois grupos de modelo são distinguidos pelo tipo de conectivo que usam no seu processo de modelagem. O primeiro grupo representa os modelos matemáticos que fazem uso de operações aritméticas e são conhecidos como clássicos ou ‘crisp’¹. No segundo grupo estão os modelos lógicos que usam conectivos do tipo lógico booleano, tais como E, OU e SE-ENTÃO. A Figura 2.2 ilustra essa diferença entre os conjuntos clássicos e difusos.




Figura 2.2 - Conjuntos ‘Crisps’ versus Fuzzy.

Observa-se pela Figura 1 que para conjuntos clássicos as únicas possibilidades para um elemento são pertencer (elemento a) e não pertencer (elemento b) ao conjunto A . Já no caso de um conjunto difuso as fronteiras do conjunto A são mais amenas, o que permite incluir a idéia de se ter um elemento como parcialmente membro do conjunto A .

2.3.1. Conjuntos Fuzzy

Os conjuntos *fuzzy* são conjuntos que não possuem fronteiras bem definidas, e que foram introduzidos devido ao fato de os conjuntos clássicos apresentarem limitações para lidar com problemas onde as transições de uma classe para outra acontecem de forma suave.

Na teoria clássica dos conjuntos, o conceito de pertinência de um elemento a um conjunto fica bem definido. Dado um conjunto A em um universo X , os elementos deste

¹ Conjuntos clássicos

universo simplesmente pertencem ou não pertencem àquele conjunto. Isto pode ser expresso pela função característica f_A :

$$f_A(x) = \begin{cases} 1 & \text{se e somente se } x \in A \\ 0 & \text{se e somente se } x \notin A \end{cases}$$

A proposta de Zadeh (1965) foi flexibilizar a pertinência de elementos aos conjuntos criando a idéia de grau de pertinência. Dessa forma, um elemento poderia pertencer parcialmente a um dado conjunto, ou seja, um conjunto *fuzzy* A em um universo X é definido por uma função de pertinência $\mu_A(x): X \rightarrow [0,1]$, onde $\mu_A(x)$ indica o quanto x é compatível com o conjunto A. Com isso, um determinado elemento pode pertencer a mais de um conjunto *fuzzy* com diferentes graus de pertinência.

Se desejássemos construir, por exemplo, o conjunto dos números aproximadamente iguais a 5 no intervalo de 0 a 10 (somente os números naturais), teríamos como resultado o seguinte gráfico de pertinência:




Figura 2.3 - Pertinência dos números iguais a 5.

Nota-se pela Figura 2.3 que quanto mais próximo de 5, a pertinência do número é maior.

2.3.2. Inferência

Para a manipulação de bases de conhecimento, é utilizada expressão de linguagem do tipo “SE premissa (antecedente) ENTÃO conclusão (conseqüente)”, que formam um conjunto de regras de inferência. Esse tipo de expressão é o método mais comum para representar o conhecimento humano (ROSS, 1995). Os métodos de inferência *Fuzzy* são classificados como diretos ou indiretos. A Figura 2.4 apresenta os métodos de inferência *fuzzy*.

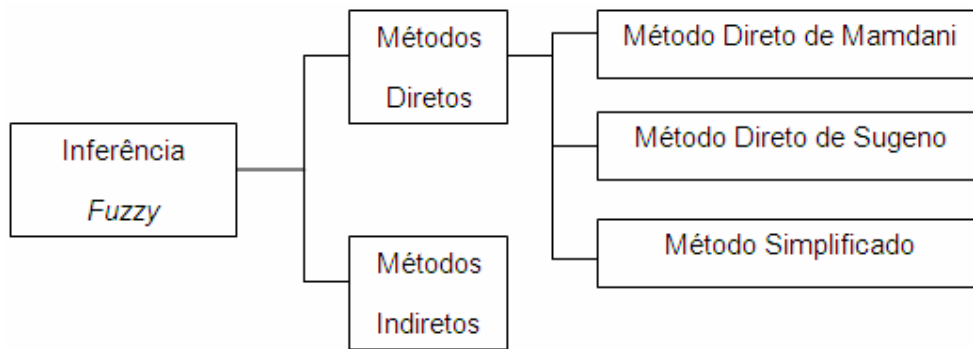


Figura 2.4 - Métodos de Inferência *Fuzzy*.

Os métodos diretos usam regras de inferência do seguinte tipo: SE x é A E y é B , ENTÃO z é C , onde A , B e C são conjuntos *Fuzzy*, os termos posteriores ao SE formam a premissa, os termos posteriores ao ENTÃO formam a parte conseqüente; x e y são as variáveis da premissa e z é a variável do conseqüente. O método direto mais popular é o de Mamdani, que tem uma estrutura simples de operações de mínimo e máximo e por isso é muito popular em aplicações. Outro método direto de inferência *Fuzzy* é o Sugeno que usa funções lineares na parte do conseqüente. As regras são da seguinte forma: SE x é A E y é B ENTÃO $z = ax + by + c$. Além desses, há outro método que utiliza uma parte do conseqüente simplificada. SE x é A E y é B ENTÃO $z = c$, onde c é um valor real (Tanaka, 1991).

Na inferência *Fuzzy*, de maneira geral, o primeiro passo é medir a adaptabilidade das premissas das regras para uma entrada de dados, depois inferir a conclusão para cada regra a partir da adaptabilidade obtida e por fim agregar as conclusões individuais das regras para obter a conclusão geral (OLIVEIRA, 2007).

Conclui-se então que um sistema de inferência *fuzzy* pode ser composto de cinco blocos:

- Base de Conhecimento ou Regras: Conjunto de proposições/regras geralmente propostas por um especialista onde as variáveis antecedentes/conseqüentes são variáveis lingüísticas;
- Base de dados: Define as funções de pertinência dos conjuntos e realiza operações de inferência a partir da base de regras montadas para o sistema;
- Fuzzificação: Utilizam-se funções de pertinência estabelecidas inicialmente para o mapeamento das entradas em graus de pertinência para os conjuntos *fuzzy* determinados para a variável;
- Defuzzificação: Retorna em valores o resultado difuso obtido;

A Figura 2.5 apresenta o Sistema de Inferência *Fuzzy*.

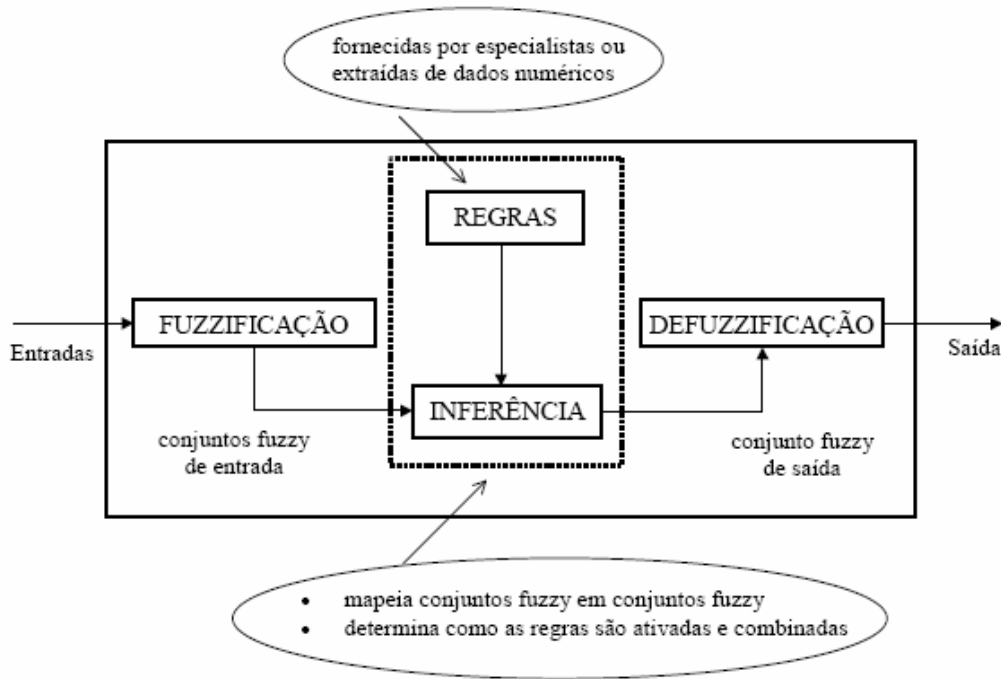


Figura 2.5 - Sistema de Inferência *Fuzzy*. Fonte: Tanscheit (2000).

2.4. Redes Neurais

Rede neural é um processador distribuído, massivamente paralelo, com uma propensão natural para armazenar conhecimento empírico e torná-lo acessível para uso (HAYKIN, 1994). Assemelha-se ao cérebro em dois aspectos:

1. O conhecimento é adquirido pela rede através de um processo de aprendizagem.
2. A intensidade das ligações entre neurônios, conhecidas por pesos sinápticos, é utilizada para armazenar conhecimento.

Segundo LIN (1995), redes neurais artificiais é uma geração nova e promissora de sistema de processamento de informação, as quais demonstram habilidade para aprender, reaprender e generalizar a partir de dados ou padrões treinados.

LOESCH (1996) informa que as RNA (Redes Neurais Artificiais) podem ser desenvolvidas em um tempo razoável e realizar tarefas de forma mais eficiente que outras tecnologias convencionais. Quando associadas em uma implementação de hardware, as RNA exibem alta tolerância a falhas no sistema e fornecem dados que estimam o processamento em paralelo.

Para NISHIDA (1998), com o intuito de simular o aprendizado humano, pesos são designados às conexões sinápticas entre neurônios artificiais, e representam o conhecimento armazenado em uma RNA. Através de um processo de aprendizagem, ou treinamento, os pesos sinápticos são ajustados e tornam a rede artificial apta a decidir com maior ou menor eficiência.

Percebe-se então que uma rede neural é constituída por um conjunto de elementos (neurônios), interligados massivamente e comunicando entre si pelo envio de sinais. A partir desses princípios, a RNA busca imitar os princípios organizacionais do cérebro humano, com isso demonstrando habilidade de aprendizagem e generalização.

Assim, os neurônios artificiais (elemento de processamento da RNA) são estruturas lógicas que tem o objetivo de simular o funcionamento de um neurônio biológico, fazendo com que a rede atue de forma indutiva (PACHECO, 1996).

2.4.1. Características das Redes Neurais

As redes neurais são compostas por elementos de processamento simples, massivamente interligados e comunicando entre si pelo envio de sinais sobre um número elevado de ligações. As principais entidades que compõem uma rede neural são (PAIVA, 1999):

- um conjunto de entradas, x_j , saídas desejadas, y_j , e saídas efetivas, z_j , da rede;
- um conjunto de unidades de processamento, neurônios ou células;
- um sinal de ativação, a_i , para cada unidade i , o qual determina a sua saída;
- ligações pesadas entre as unidades, definidas por um peso w_{ij} , o qual determina o efeito da unidade j na unidade i ;
- uma regra de propagação, que determina a entrada efetiva i_i de uma unidade com resultado de todas as suas entradas externas;
- uma função de ativação, F_i , que determina o nível de ativação da unidade em função da sua entrada efetiva;
- um termo de polarização ou viés, b_i , para cada unidade;
- um ambiente de operação, que forneça sinais de entrada e, eventualmente, sinais de erro.




Figura 2.6 - Estrutura de um neurônio artificial. Fonte: Paiva (1999)

Ainda, segundo LIN e LEE (1995), as características básicas de uma rede neural são:

- modelo matemático inspirado na neurologia;
- consiste em um grande número de elementos de processamento interconectados;
- suas conexões (pesos) representam o conhecimento;
- um elemento de processamento pode responder dinamicamente a seus estímulos de entrada, resposta que depende completamente do seu local da informação, isto é, o sinal de entrada chega a um elemento de processamento através dos pesos das conexões;
- tem habilidade de aprender, reaprender e generalizar a partir de dados treinados por designar ou ajustar a conexão de pesos;
- seu comportamento coletivo demonstra a força computacional e uma informação específica não resulta de um único neurônio (propriedade de representação distribuída).

Levando em consideração tais características, as redes neurais podem ser chamadas de modelos de processamento distribuído paralelo, auto-organizado, etc.

Em relação às características da arquitetura da rede, deve-se analisar primeiramente a forma como os neurônios arranjam-se nos grafos e as topologias criadas (PACHECO, 1996), ou seja, as arquiteturas das redes classificam-se em função do número de camadas de neurônios e de sua estruturação, além da forma como os sinais calculados são propagados (*feedforward* ou recorrentes).

Ainda em relação à arquitetura (estrutura), as redes neurais estão arranjadas em camadas, onde os neurônios têm comportamentos semelhantes nos quais as funções de ativação e o padrão de conexão dos pesos (onde passam os sinais de comunicação dos neurônios) são fatores importantes para determinar esse comportamento, isto é, dentro de uma mesma camada, os neurônios são fortemente conectados ou não. Logo, a arquitetura da rede é identificada pelo arranjo de neurônio dentro de uma camada e pelo padrão de conexão dentro e entre camadas (RÉ, 2000).

2.4.2. Treinamento da Rede

Treinamento é o processo na qual a rede “aprende” a relação contida num conjunto de dados, referindo geralmente a um conjunto de treinamento, que contém um conjunto de valores para as variáveis independentes (entradas) e os correspondentes valores das variáveis dependentes (saídas desejadas) (BARBALHO, 2001).

Por ser um modelo que imita um neurônio biológico, a RNA deve possuir a capacidade de armazenar novos conhecimentos a fim de torná-los úteis a tomada de decisão. Para o armazenamento desses conhecimentos são designados pesos sinápticos às conexões entre os neurônios. São eles os parâmetros que devem ser ajustados através do processo de treinamento, para que a rede habilite-se a responder o mais corretamente possível a quaisquer outros estímulos que lhe forem apresentados em uma fase posterior ao treinamento, denominada de teste (HAYKIN, 1994). Existem três formas de treinamento (FAUSETT, 1995):

- supervisionada: caracteriza-se pela utilização de um conjunto de treinamento composto por dados de entrada previamente classificados. O ajuste dos pesos ocorre através da apresentação de estímulos de entrada, disponíveis no conjunto de treinamento, para o cálculo da reposta, utilizando como parâmetros os valores dos pesos atuais. Faz-se então uma

comparação entre a resposta oferecida pela rede atual e a desejada àqueles estímulos e, com base na similaridade entre as duas respostas, os pesos são ajustados. Esse procedimento pendura até ocorrer a classificação o mais correto possível.

- não supervisionada: permite à rede aprender sem que exista um conjunto de “respostas desejadas” como referência para as saídas da rede. Os pesos são ajustados à medida que a rede vai sendo provida de padrões de entrada selecionados como representativos de cada classe, ou seja, de acordo com sua similaridade aos padrões de entrada apresentados à rede.
- híbrido: contempla o treinamento supervisionado e não supervisionado. Por exemplo, a rede RBF admite esse tipo de treinamento, cuja primeira camada da conexão é treinada de forma não supervisionada e a segunda, de forma supervisionada.

Os métodos híbridos usam conhecimento teórico de um domínio e um conjunto de exemplos classificados para desenvolver um método de exemplos classificados corretamente não vistos durante o treinamento (TOWELL e SHAVLIK, 1994). Com isso o aprendizado híbrido compensa a perda de informação proporcionada por uma fonte.

O poder real de uma RNA é o de generalização, devendo ser significativo após seus pesos terem sido ajustados na fase de treinamento, ou seja, a rede treinada é capaz de produzir bons resultados com dados que nunca lhe foram apresentados antes.

Após o treino, uma rede neural pode perder a sua capacidade de generalização quando ocorre o fenômeno de superajuste (*overfitting*) dos parâmetros, devido, em geral, a um treinamento excessivo, situação em que a rede memoriza os exemplos de treinamento (inclusive os ruídos). O maior segredo, portanto, para construir redes neurais bem sucedidas é saber quando parar o treinamento (BARBALHO, 2001).

Para evitar o superajuste dos parâmetros, deve-se utilizar um conjunto de dados que será utilizado como conjunto de checagem, em que os dados presentes não estejam presentes no conjunto de treinamento.

2.5. Neuro-Fuzzy

O sistema híbrido *neuro-fuzzy* apresenta-se como uma alternativa particularmente interessante na modelagem de sistemas, uma vez que consegue extrair o aprendizado das redes neurais com as vantagens do nível de interpretabilidade da lógica *fuzzy*.

Convencionalmente os modelos *fuzzy* são construídos com base no conhecimento e experiência de um especialista ou perito num determinado assunto, ajudando assim na construção do conjunto de regras lingüísticas. No entanto, essa abordagem apresenta algumas limitações. Essas limitações vão desde a disponibilidade de um especialista, e a parcialidade com que o mesmo irá tratar sobre o problema abordado, ou seja, seu conhecimento é subjetivo.

Devido a essas limitações, o modelo inicialmente proposto pelo especialista se torna apenas um protótipo, tornando-se necessário depurar e validá-lo. A partir daí torna-se necessário à automática seleção e configuração das funções de pertinência dos conjuntos *fuzzy* propostos.

2.5.1. Construção automática de Sistemas Fuzzy

A junção de sistemas *fuzzy* com redes neurais visa sanar as deficiências de cada modelo. Como exemplo, temos o fato de redes neurais (exceto redes de base radial) não aceitarem inclusão de conhecimento prévio na sua inicialização. Já os sistemas *fuzzy* se mostram ineficientes na determinação e composição das funções de pertinência, ou seja, se torna difícil determinar qual estrutura obtém o melhor modelo para determinado problema. Devido a essas deficiências, esses modelos (redes neurais e lógica *fuzzy*) se mostram complementares.

Para a construção do sistema *neuro-fuzzy*, temos dois problemas essenciais: a aprendizagem das regras e a aprendizagem dos parâmetros. Esses problemas podem ser abordados de três formas: aprendizagem de parâmetros pela rede e aprendizagem da estrutura segundo outro método; aprendizagem da estrutura da rede, e especificando os parâmetros iniciais; ou ainda aprendizagem tanto da estrutura quanto dos parâmetros pela rede.

Freqüentemente as redes *neuro-fuzzy* dedicam-se exclusivamente à tarefa de aprendizagem de parâmetros utilizando um algoritmo de treino supervisionado. Já as regras, são obtidas separadamente usando técnica de agrupamento (SUGENO et al. 1985). Outra característica é o uso do modelo de inferência Takagi-Sugeno.

2.5.2. Arquitetura ANFIS

Proposto por Jang (1993), o ANFIS (*Adaptive Neuro-Fuzzy Inference System*) consiste da implementação de um modelo híbrido capaz de transformar conhecimento ou experiência em base de regras, que através de um algoritmo de aprendizado adequado, é capaz de construir automaticamente um conjunto de regras difusas, a partir de um conjunto de informações. Os sistemas de regras resultantes utilizam regras difusas do tipo proposto por Takagi e Sugeno (1985).

Alem de gerar um conjunto de regras difusas, com funções de pertinência adequada, o modelo ainda ajusta automaticamente os parâmetros dessas funções de forma a maximizar o desempenho do modelo na representação da relação de entrada e saída desejada (BARBALHO et al, 2001). Segundo estes mesmos autores, as camadas que dividem o ANFIS são:

- 1ª Camada: Nesta camada, cada uma das unidades representa uma função de pertinência associada a uma das entradas, e tem como característica a adaptabilidade.
- 2ª Camada: Nesta camada, as unidades executam uma função fixa que é a multiplicação dos sinais que chegam a eles.
- 3ª Camada: Unidades não adaptativos, onde cada uma realiza a razão da aplicabilidade de um regra em relação a soma de todas as aplicabilidades do sistema de regra.
- 4ª Camada: Cada unidade nesta camada é adaptativa, e representam os parâmetros dos consequentes.
- 5ª Camada: Unidade de processamento não adaptativa que calcula a saída final como a soma de todos os sinais de entrada.

A Figura 2.7 apresenta a arquitetura descrita acima.

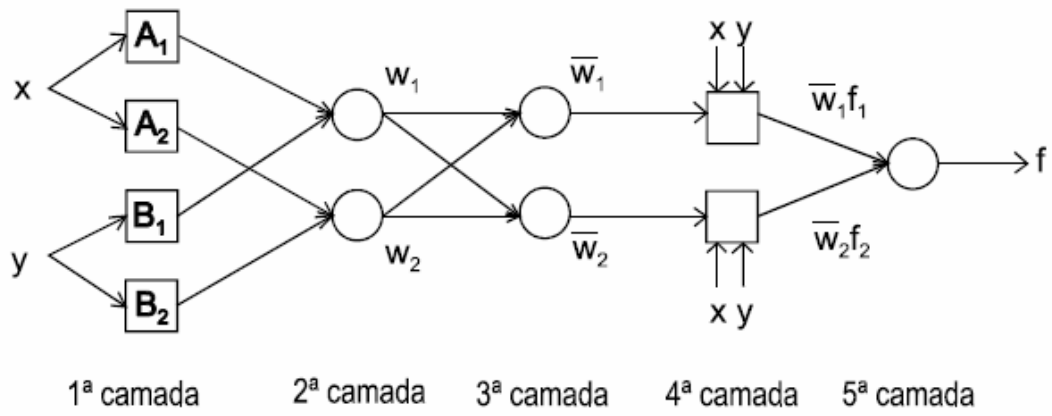


Figura 2.7 - Arquitetura ANFIS Fonte: BARVALHO (2001).

A partir da descrição acima, nota-se que a arquitetura descrita é equivalente a um sistema de inferência difusa do tipo Takagi e Sugeno (1985).

3. MATERIAIS E MÉTODOS

Neste capítulo é descrito o tipo de pesquisa utilizada para a fundamentação dos conceitos ilustrados anteriormente e a descrição de como o estudo de caso foi realizado.

Para a modelagem do sistema *neuro-fuzzy*, foi necessário a aquisição de dados sobre o problema. Esses dados ajudaram no treinamento e validação do sistema gerado.

3.1. Tipo de pesquisa

De acordo com Jung (2004) pode-se definir pesquisa básica como aquela que objetiva a obtenção de conhecimentos elementares, como por exemplo: novas propriedades de materiais e fenômenos associados a estes, novas fontes de energia, descoberta de elementos físico-químicos, reações químicas, efeitos eletromagnéticos, etc. O conhecimento resultante deste tipo de pesquisa pode em um primeiro momento apresentar-se desagregado do contexto cotidiano, mas, posteriormente, tornar-se-á vital para a aplicação em pesquisas tecnológicas.

Ainda conforme Jung (2004) diz que a pesquisa exploratória visa o aprimoramento de idéias ou a descoberta de intuições, ou seja, fornecer ao pesquisador um maior conhecimento sobre o tema ou problema de pesquisa em questão.

A partir destas definições pode-se classificar este trabalho como sendo de pesquisa básica e exploratória, levando em conta a sua natureza e os seus procedimentos, pois com a construção do modelo *neuro-fuzzy* objetiva-se gerar conhecimentos básicos ou fundamentais para o entendimento ou descoberta de novos fenômenos físicos e propor alternativas ou teorias que poderão modificar as existentes.

3.2. Obtenção dos dados

Os dados coletados correspondem à área plantada situada em Mogi das Cruzes-SP. Utilizou-se um talhão com área de 4.31 hectares com 16 anos, com espaçamento inicial usado foi de 3x3 m com desbaste seletivo em 8,6 anos.

Para fins deste trabalho, foi feita a cubagem de 132 árvores para o ajuste do modelo. Foram obtidas duas medidas ortogonais, utilizando uma suta², do diâmetro na altura de 1,30 m e de diâmetros em diversas seções do tronco. O cálculo do volume com casca das seções foi feito empregando-se o método de Smalian (conforme seção 2.2.1).

As Figuras 3.1 e 3.2 respectivamente mostram a distribuição de freqüência das idades das árvores-amostra usadas no treinamento e validação dos modelos utilizados.




Figura 3.1 - Distribuição de freqüência das idades das árvores-amostras utilizadas para o ajuste dos modelos volumétricos e o treino do *neuro-fuzzy*.

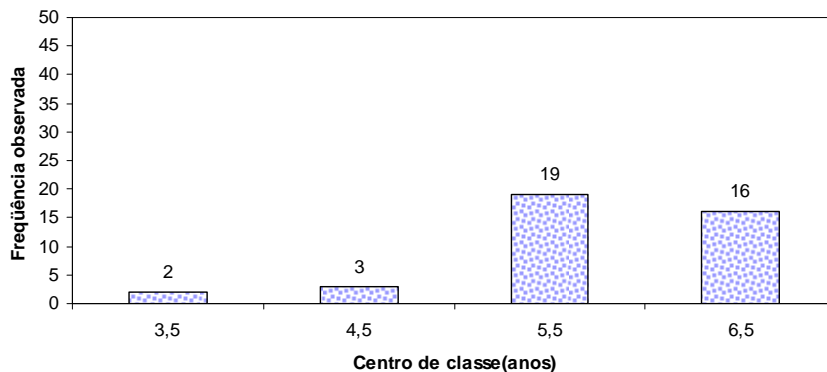


Figura 3.2 - Distribuição de freqüência das idades das árvores-amostras utilizadas para a validação dos modelos avaliados.

² Instrumento utilizado na medida de diâmetro de árvores

3.3. Procedimentos metodológicos

A pesquisa foi realizada no período de fevereiro a julho de 2007.

Inicialmente, foi realizada uma revisão bibliográfica sobre os modelos convencionais de medição do volume de Eucalyptus, sobre modelo híbrido *neuro-fuzzy* e técnicas computacionais para o desenvolvimento e implementação do modelo proposto. Foram consultados livros, monografias, teses e dissertações disponibilizadas na Internet e na literatura de modo geral.

Posteriormente foi implementado o modelo *neuro-fuzzy* e realizado comparações com os modelos de Spurr e Schumacher.

Como ferramenta para implementação, foi usado o MatLab 6.5 Release 13 com o módulo denominado ANFIS (*Adaptive Neuro-Fuzzy Inference System*), integrante do utilitário de lógica difusa *Fuzzy Logic Toolbox*, que consiste em uma implementação do método proposto por Roger Jang (JANG, 1993). O computador utilizado foi um Intel Centrino Duo 1.66GHz com 2GB de memória, HD de 100GB, como sistema operacional Windows XP Service Pack 2.

3.4. Modelos comparados

Na literatura encontram-se diversos modelos que expressam volume total das árvores. Para este trabalho foram comparados dois modelos volumétricos clássicos que são bem difundidos no meio florestal. Esses modelos são descritos abaixo:

- Schumacher e Hall: $V = \beta_0 \cdot DAP^{\beta_1} \cdot H^{\beta_2} \cdot \varepsilon$
- Spurr: $V = \beta_0 + \beta_1 DAP^2 H + \varepsilon$

Estes modelos serão usados para medir a viabilidade do novo modelo proposto.

3.5. Modelo proposto

O modelo proposto utiliza o sistema híbrido *neuro-fuzzy* idealizado por Roger Jang (JANG, 1993).

Em sua implementação na ferramenta MatLab, foi fornecido uma matriz de dados em que sua última coluna representa a saída desejada do sistema. Após o carregamento dos dados de treinamento, deve-se gerar o sistema *fuzzy* de inferência que será ajustado pela rede.

O conjunto de dados carregado possui três entradas e uma saída. Sendo a entrada 1 a idade do *Eucalyptus*, a entrada 2 o DAP (diâmetro na altura do peito), a entrada 3 a altura total e a saída o volume total com casca.

Após o carregamento dos dados, é gerado o FIS (*Fuzzy Inference System*). Neste trabalho foi escolhido o método *Grid Partition*, com 4 funções de pertinência para a primeira variável (idade), 5 funções de pertinência para a segunda (DAP) e terceira variável (altura total).

Como parâmetro para o treinamento, foi escolhido o método de treinamento híbrido, que consiste pela combinação do método de *backpropagation* e o dos mínimos quadrados, sendo o primeiro associado às estimativas dos parâmetros das funções de pertinência de entrada, e o segundo, associado às estimativas dos parâmetros de saída das funções de pertinência. Outros parâmetros usados foi o erro igual a zero e o número de épocas igual a 50.

O aprendizado da estrutura é dividido em duas etapas:

- ETAPA 1: Os parâmetros dos antecedentes ficam fixos e os consequentes são ajustados pelo método MQD- estimacão por Mínimos Quadrados Ordinários.
- ETAPA 2: Os parâmetros dos consequentes ficam fixos e os antecedentes são ajustados pelo algoritmo Gradiente Descendente.

Após treinar a rede, as seguintes funções de pertinência foram obtidas:




Figura 3.3 - Conjuntos *fuzzy* para a idade




Figura 3.4 - Conjuntos *fuzzy* para o DAP

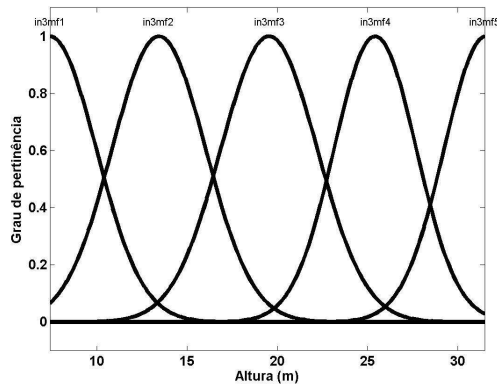


Figura 3.5- Conjuntos *fuzzy* parara a altura

3.6. Avaliação dos modelos

Foram utilizadas 91 árvores-amostra para o ajuste dos modelos de regressão e treinamento da rede e 40 árvores-amostra para realizar a validação. As equações foram comparadas tomando em conta o coeficiente de correlação (r) entre os valores observados e estimados pelas equações ajustadas e o erro padrão relativo (S_{YX} (%)).

$$S_{yx} = \sqrt{\frac{\left(Y - \hat{Y}\right)^2}{n - p}}$$

$$S_{yx} (\%) = \frac{S_{yx}}{\bar{Y}} \cdot 100$$

Em que

S_{YX} = erro padrão da estimativa (m^3);

S_{YX} (%) = erro padrão relativo;

\hat{Y} = volume total (m^3) estimado pela equação ou neuro-fuzzy;

Y = volume total (m^3) observado;

\bar{Y} = média do volume total (m^3);

n = número de observações;

p = número de parâmetros (considerado 0 (zero) para *neuro-fuzzy*).

Foram feitas as análises gráficas dos resíduos. Os valores residuais utilizados na construção dos gráficos são expressos por:

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

Foram, também, feitos testes complementares, por meio das seguintes estatísticas: bias (B); média das diferenças absolutas (MD); e desvio padrão das diferenças (DPD).

Bias (B):

$$B = \frac{\sum_{i=1}^n Y_i - \sum_{i=1}^n \hat{Y}_i}{n}$$

Média das diferenças absolutas (MD):

$$MD = \frac{\sum_{i=1}^n |Y_i - \hat{Y}_i|}{n}$$

Desvio padrão das diferenças (DPD):

$$DPD = \sqrt{\frac{\sum_{i=1}^n d_i^2 - \left(\sum_{i=1}^n d_i\right)^2 / n}{n - p}}$$

Em que: $d_i = \left(Y_i - \hat{Y}_i\right)$.

A partir da análise das estatísticas B, MD e DPD, procedeu-se a ordenação das funções segundo o maior ou menor grau de precisão, sendo atribuídos pesos de 1 a 3 de acordo com os resultados das estatísticas obtidas para cada equação e com o diâmetro mínimo comercial em questão (Lima, 1986 e Mendonça et al., 2007). Foi considerado o modelo mais preciso, aquele que resulta em menor somatório nas notas para o volume total (Lima, 1986 e Mendonça et al., 2007).

Os valores positivos e negativos da estatística B indicam subestimativa e superestimativa, respectivamente. Os menores valores das três estatísticas testadas indicam que a equação apresenta maior precisão para o objetivo em pauta.

4.RESULTADOS E DISCUSSÃO

Na avaliação dos modelos, foi usado um conjunto de dados para treinar o modelo *Neuro-Fuzzy* e estimar os betas dos modelos de Schumacher e Spurr. No subtópico 4.1 será apresentado os resultados para o conjunto de dados de treinamento e no subtópico 4.2 será apresentando os resultados para o conjunto de checagem/validação, conjunto este que não é conhecido por nenhum dos modelos.

4.1. Avaliação do ajuste dos modelos volumétricos e conjunto de treino do Neuro-Fuzzy

As equações estimadas para os modelos de Spurr (1) e Schumacher e Hall (2) com o conjunto de 91 árvores-amostra são:

- $V = 0.006584 + 0,0000343.DAP^2 H$ (1)
- $V = 0,000057.DAP^{1,8224} .H^{1,0134}$ (2)

As medidas de precisão para as equações testadas são apresentadas na Tabela 4.1. Analisando as medidas de precisão, verifica-se um melhor grau de ajuste para o modelo *Neuro-Fuzzy*, pois apresentou valore de r superior e de erro padrão relativo ($S_{Y.X}$ (%)) mais baixo, seguido dos modelos de Schumacher e Hall e Spurr.

Tabela 4.1 - Medidas de precisão para os modelos avaliados

Modelo	r	S_{yx} (%)
Spurr	0,9946	8,21
Schumacher e Hall	0,9955	7,63
Neuro-Fuzzy	0,9999	1,16

As figuras 4.1, 4.2 e 4.3 apresentam graficamente a distribuição residual na estimativa do volume total para os modelos avaliados.




Figura 4.1 - Distribuição residual do volume em função do volume total para *neuro-fuzzy*




Figura 4.2 - Distribuição residual do volume em função do volume total para Schumacher e Hall

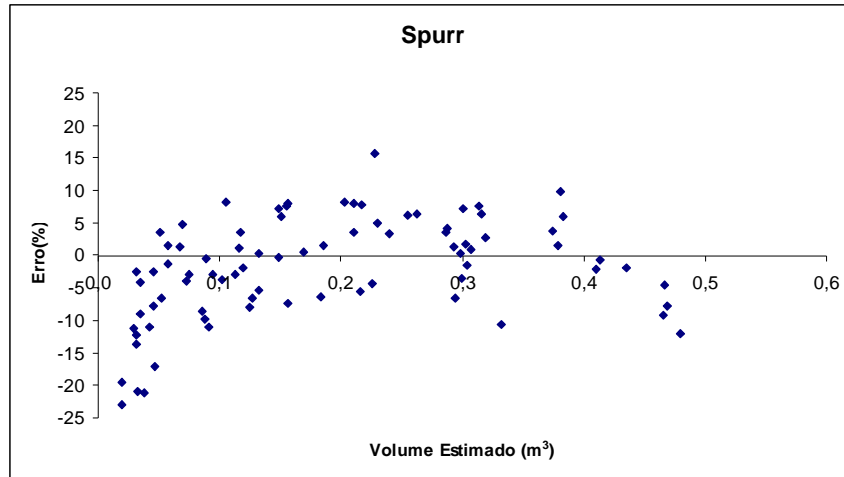


Figura 4.3 - Distribuição residual do volume em função do volume total para Spurr.

Analisando a Figura 4.3, nota-se que o modelo de Spurr apresenta tendência de superestimativa em árvores menores, principalmente nas com volume total abaixo de 0,1 m³. A distribuição dos resíduos apresentou na faixa de -25% a + 15%. Percebe-se, também a presença de *outliers* no modelo. Já o modelo de Schumacher, a faixa de variação dos erros, ficou entre -20% a + 25% (Figura 4.2). A variação dos resíduos do *Neuro-Fuzzy* apresentou a melhor distribuição residual, com valores aproximando-se de zero (Figura 4.1).

A Tabela 4.2 apresenta as estatísticas “bias” (B), média das diferenças absolutas (MD) e desvio padrão das diferenças (DPD) para estimativa do volume total.

Tabela 4.2 - Estatísticas “bias” (B), média das diferenças absolutas (MD) e desvio padrão das diferenças (DPD) para as estimativas do volume total.

Modelo	B	MD	DPD
1	$7,26 \times 10^{-17}$	0,0095	0,1330
2	-0,0023	0,0089	0,1236
3	-0,0003	0,0006	0,0189

1 = Spurr, 2 = Schumacher e Hall, 3 = *Neuro-Fuzzy*

A Tabela 4.3 mostra as notas atribuídas para as estimativas do volume total baseadas nas estatísticas da Tabela 4.2.

Tabela 4.3 - Notas atribuídas, a partir das estatísticas da Tabela 4.2, para as estimativas do volume total.

Modelo	B	MD	DPD	Total
1	1	3	3	7
2	3	2	2	7
3	2	1	1	4

Modelo: 1 = Spurr, 2 = Schumacher e Hall, 3 = *Neuro-Fuzzy*

Como exemplo, a equação de Spurr tem para a bias (B) o valor $7,26 \times 10^{-17}$ (Tabela 4.2). Quando este valor é comparado com a B associada aos outros modelos, a nota atribuída a essa equação foi 1 (Tabela 4.3). Esse valor significa que, considerando o B , a equação de Spurr obteve a melhor estimativa em relação aos outros modelos avaliados, seguida, pela ordem, pelos modelos de *Neuro-Fuzzy* (Nota 2) e Schumacher e Hall (Nota 3). Seguindo o raciocínio apresentado e analisando os dados das Tabelas 4.3 e 4.2, verifica-se que o modelo *Neuro-Fuzzy* apresentou os melhores resultados para estimativa do volume total, seguidos dos modelos de Schumacher e Hall (1939) e Spurr.

Estes resultados, de maneira geral, corroboram os anteriormente encontrados, ou seja, r , S_{yx} (%) e as análises gráficas de resíduos (Figuras 4.1, 4.2 e 4.3).

4.2. Avaliação da validação dos modelos avaliados

Na avaliação dos modelos com o conjunto de checagem, busca-se validar os modelos com dados que não fizeram parte do ajuste das equações volumétricas e treino do *Neuro-Fuzzy*. É nesta avaliação que o modelo proposto mostrará uma de suas características desejáveis, que é a capacidade de generalização.

O conjunto de dados de checagem contém 40 árvores como descrito anteriormente. Nesta avaliação, apenas usaremos os modelos ajustados anteriormente, ou seja, usaremos as equações de Spurr e Schumacher citadas anteriormente e o sistema fuzzy gerado pelo treino da rede. Para a avaliação dos resultados obtidos, foram usados os mesmos critérios

utilizados na avaliação do ajuste dos modelos volumétricos e conjunto treino do *Neuro-Fuzzy*. A Tabela 4.4 apresenta as medidas de precisão para o conjunto de validação.

Tabela 4.4 - Medidas de precisão para o conjunto de validação

Modelo	r	S _{yx} (%)
Spurr	0,9975	6,83
Schumacher e Hall	0,9974	6,67
<i>Neuro-Fuzzy</i>	0,9994	2,99

Os resultados encontrados confirmam o melhor desempenho no modelo *Neuro-Fuzzy*, seguido pelo modelo de Schumacher e Hall, conforme encontrado para os dados de ajuste e treinamento dos modelos.

As Figuras 4.3, 4.4 e 4.5 apresentam graficamente a distribuição residual na estimativa do volume total para os modelos com o conjunto de validação.

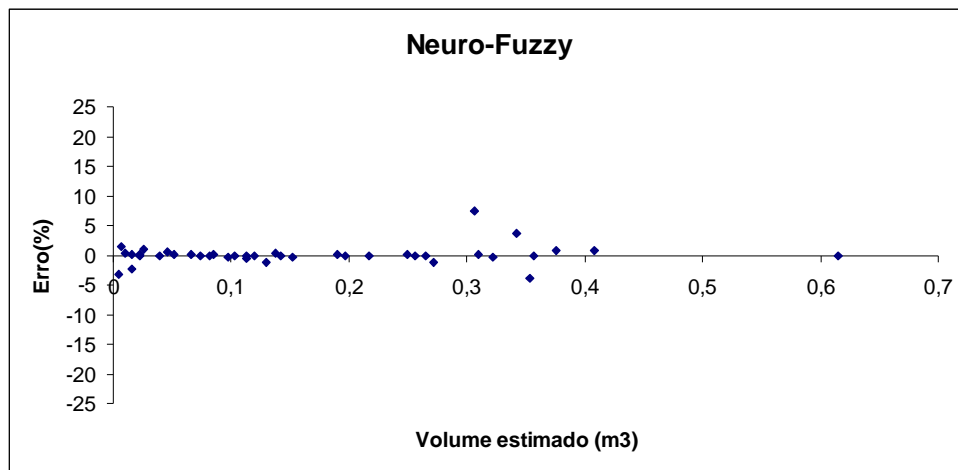


Figura 4.4 - Distribuição residual do volume em função do volume total para *neuro-fuzzy* com o conjunto de checagem.

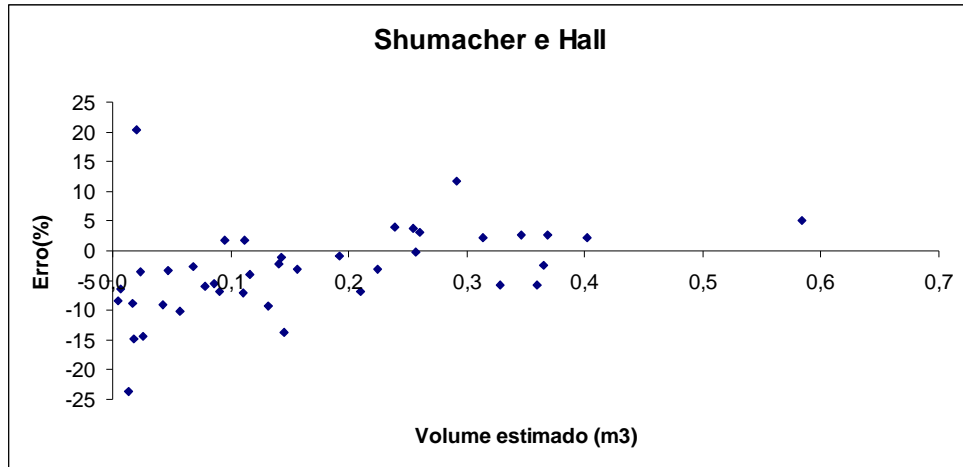


Figura 4.5 - Distribuição residual do volume em função do volume total para Schumacher e Hall com o conjunto de checagem.

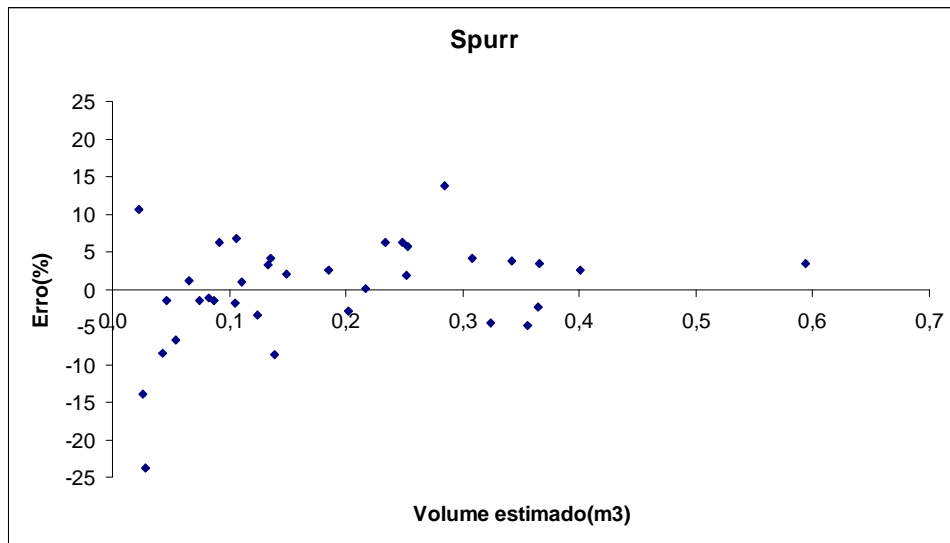


Figura 4.6 - Distribuição residual do volume em função do volume total para Spurr com o conjunto de checagem.

Analisando a Figura 4.6, nota-se que o modelo de Spurr continua apresentando estimativas tendenciosas para volumes inferiores a $0,1\text{cm}^3$. A distribuição dos resíduos apresentou na faixa de -25% a + 15%. Este modelo ainda continua apresentando valores *outlier*. Já o modelo de Schumacher e Hall (Figura 4.5), a faixa de variação dos erros ficando entre -25% a + 20%, mas apresentou tendência de superestimativa do volume total para árvores menores. Nota-se que os modelos de Spurr e Schumacher e Hall apresentam

melhoria na estimação do volume total, uma vez que apresentaram menor variação dos valores residuais.

A variação dos resíduos do *Neuro-Fuzzy* (Figura 4.4) continua apresentando melhor distribuição residual, com valores aproximando-se de zero (0).

A Tabela 4.5 apresenta as estatísticas “bias” (B), média das diferenças absolutas (MD) e desvio padrão das diferenças (DPD) para estimativa do volume total para o conjunto de árvores amostra da validação.

Tabela 4.5 - Estatísticas “bias” (B), média das diferenças absolutas (MD) e desvio padrão das diferenças (DPD) para as estimativas do volume total

Modelo	B	MD	DPD
1	0,0024	0,0078	0,0708
2	-0,0003	0,0075	0,0692
3	0,0006	0,0016	0,0310

1 = Spurr, 2 = Schumacher e Hall, 3 = *Neuro-Fuzzy*

A Tabela 4.7 mostra as notas atribuídas para as estimativas do volume total baseadas nas estatísticas da Tabela 4.5.

Tabela 4.6 - Notas atribuídas, a partir das estatísticas da Tabela 4.5, para as estimativas do volume total.

Modelo	B	MD	DPD	Total
1	3	3	3	9
2	1	2	2	5
3	2	1	1	4

Modelo: 1 = Spurr, 2 = Schumacher e Hall, 3 = *Neuro-Fuzzy*

Assim como na comparação com os dados de treinamento, o modelo *Neuro-Fuzzy* apresentou o melhor resultado seguido do modelo de Schumacher e Hall (1939) e Spurr, respectivamente.

5. CONCLUSÕES

Neste trabalho foi estudado o funcionamento e características do modelo híbrido *Neuro-Fuzzy* e sua aplicação na estimativa do volume total do *Eucalyptus sp.* Na validação do modelo proposto notou-se que tanto para o conjunto de treinamento quanto para o conjunto de checagem, o modelo *Neuro-Fuzzy* mostrou-se eficiente na comparação com os modelos tradicionais (Schumacher e Hall (1939) e Spurr (1952)). Com isso, percebe-se a importância de trabalhos envolvendo técnicas de inteligência artificial na área florestal.

Visto a eficiência do modelo *Neuro-fuzzy* proposto, como trabalho futuro espera-se a implementação efetiva do modelo proposto em problemas de estimativa de volume total de espécies florestais. Para isso seria desenvolvido um software com a implementação do modelo obtido, levando em conta os fatores que influenciam a estimativa do volume total de cada espécie.

6. REFERÊNCIAS BIBLIOGRÁFICAS

ALATA, M. **Control of Nonlinear Systems Using Sugeno Fuzzy Approximators**. [Rio de Janeiro] 2001. IX, 94 p., 29,7 cm (Concordia University, D.Sc., Filosofia, 2001) Tese - Universidade Federal do Rio de Janeiro, COPPE.

BARBALHO, V. M. DE S. **Sistemas baseados em conhecimento e lógica difusa para simulação do processo chuva-vazão**. [Rio de Janeiro] 2001. IX, 94 p., 29,7 cm (COPPE/UFRJ, D.Sc., Engenharia Civil, 2001) Tese - Universidade Federal do Rio de Janeiro, COPPE.

CAMPOS, J. C. C.; LEITE, H. G.. **Mensuração florestal: perguntas e respostas**. Viçosa: UFV, 2002. 407p.

CAMPOS, J.C.C. **Dendrometria - Parte I**. Viçosa: UFV. Imprensa Universitária. 1993. 43p.

CLUTTER, J.L., FORTSON, J.C., PIENAAR, L.V., BRISTER, G.H., BAILEY, R.L., 1983. **Timber Management: A Quantitative Approach**. Krieger, Malabar, FL, p. 333.

COUTO, H. T. Z. do; VETTORAZZO, S. C.. Seleção de equações de volume e peso seco comercial para *Pinus taeda*. **Cerne**. Lavras, v.5, n.1, p.69-80, 1999.

ELDRIDGE, K.; DAVISON, J.; HARWOOD, C.; VAN WYK, C. **Eucalypt: domestication and breeding**. New York, Oxford University Press, 288 p., 1993.

EMBRAPA. O cultivo do Eucalipto em: http://sistemasdeproducao.cnptia.embrapa.br/FontesHTML/Eucalipto/CultivodoEucalipto/01_Importancia_economica.htm. acessado em 29/01/2007.

GUIMARÃES, D.; LEITE, H. G.. Influência no número de árvore na determinação da equação volumétrica para *Eucalyptus grandis*. **Scientia forestalis**, n. 50, p. 37-42. 1996.

FAUSETT L. V. "Analysis of Dynamics of Clustering Neural Networks," *Proceedings of the Fifth International Colloquium on Differential Equations*, D. Bainov and V. Covachev (eds.), Zeist, The Netherlands: VSP, International Science Publishers, 1995, pp. 103-112.

HAYKIN S. (1994). **Neural Networks: A Comprehensive Foundation**, Macmillan College Publishing Company.

JANG, J. S. R.; SUN, C. T. *Neuro-Fuzzy modeling and control*. **Proceedings of the IEEE**, New York, v. 83, n. 3, p. 378-406, Mar. 1995.

JANG, J. S. R. ANFIS: Adaptive-Network-Based *Fuzzy Inference System*. **IEEE Transactions on Systems, Man, and Cybernetics**, New York, v. 23, n. 3, p. 665-685, May 1993.

JUNG, C. F. **Metodologia para Pesquisa & Desenvolvimento** – Rio de Janeiro, RJ : Axcel Books do Brasil Editora, 2004.

LIMA, F. S. **Análise de funções de “taper” destinadas à avaliação de multiprodutos de árvores de *Pinus elliottii***. 1986. 79 f. Dissertação (Mestrado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa, 1986.

LIN Y. e CUNNINGHAM III G. A. (1995). “A new approach to fuzzy-neural modelling”, **IEEE Transactions on Fuzzy Systems**, Vol. 3, No.2, pp. 190-198.

LIN,C.;LEE,C,S,G. **Neural fuzzy systems a neuro-fuzzy synergism to intelligent systems**. USA, Prentice-hall Simon & Schuster Company, Upper Saddle River, New Jersey, 1995

LOESCH,C.; SARI,S.T. **Redes neurais artificiais fundamentos e modelos**,Blumenau: Ed. Da FURB,1996.

LOETSCH, F.; ZÖHRER, F.; HALLER, K. E. **Forest inventory**. München: BLV, 1973. v.2. 469 p.

MACHADO, S. A., CONCEIÇÃO, M. B., FIGUEIREDO, D. J. Modelagem do volume individual para diferentes idades e regimes de desbaste em plantações de *Pinus oocarpa*. **Revista Ciências Exatas e Naturais**. Guarapuava, v.4, n.2, p.185 - 197, 2002.

MEDLER,D.A. **A brief history of connectionism**. *Neural Computing Surveys*, v. 1, <http://www.icsi.berkeley.edu/jagota/NCS>. ISSN 1093-7609, 1997.

MENDONÇA, A. R. de; SILVA, G. F. da; OLIVEIRA, J. T. da S.; NOGUEIRA, G. S.. Avaliação de funções de afilamento visando a otimização de fustes de *Eucalyptus sp.* para multiprodutos. **Cerne**, v.13, n.1, p.71-82, 2007.

MCTAGUE, J. P.; BATISTA, J. L. F.; STEIN, L.. Equações de volume total, volume comercial e forma do tronco para plantações de *Eucalyptus* nos Estados de São Paulo e Rio de Janeiro. **IPEF**, n. 41/42, p. 56-63, 1989.

NISHIDA, W. **Uma rede neural artificial para classificação de imagens multiespectrais de sensoriamento remoto**. Florianópolis, 1998. Dissertação (Mestrado em PPGE) - Universidade Federal de Santa Catarina – UFSC.

NAGAMINE, R. K. (2001). **Lógica Difusa para Controle Não Convencional de uma Viga Inteligente**. São Carlos, 2001. 117p. Dissertação (Mestrado) – Escola de Engenharia de São Carlos, Universidade de São Paulo.

OLIVEIRA, A.A.S . **Modelagem Fuzzy e Neuro-Fuzzy do processo monocíclico da ferrugem asiática da soja** / Alexandre Arduini da Silva e Oliveira. Universidade Federal de Lavras.Lavras – Minas Gerais, 2007. 29p

PACHECO, R.C.S. *Hybrid intelligent system for prediction and solving financial problems of small retail firma*. Florianópolis, 1996. Ph.D, Tese (Doutorado em Engenharia de Produção)- Universidade Federal de Santa Catarina – UFSC.

PAIVA, Rui Pedro Pinto de Carvalho e. **Identificação neuro-difusa: aspectos de interpretabilidade**. Coimbra, 1999. Tese de mestrado. Engenharia Informática, Univ. de Coimbra, 1999.

POR dentro do eucalipto aspectos sociais, ambientais e econômicos de seu cultivo. Brasil: **Cartilha**, 2003, 7p.

RÉ, A. M. De. **Um método para identificar aracterísticas predominantes em empreendedores que obtiveram sucesso utilizando um sistema neurodifuso**. Florianópolis, 2000. Dissertação (Doutorado em Engenharia de produção). Universidade Federal de Santa Catarina - UFSC.

ROSS, T.J. (1995). *Fuzzy Logic with Engineering Applications*. McGraw-Hill International Edition, New York.

SERPA, P. N.; VITAL, B. R.; DELLA LUCIA, R. M; PIMENTA, A. S.. Avaliação de algumas propriedades da madeira de *Eucalyptus grandis*, *Eucalyptus saligna* e *Pinus elliottii*. **Revista Árvore**, v.27, n. 5, p.723-733, 2003.

SCHUMACHER, F.X.; HALL, F.dos. S. Logarithmic expression of timber-tree volume. **Journal of Agricultural Research**, Washington, v.47, n.9, p.719-734, 1933.

SPURR, S. H. **Forest inventory**. New York: The Ronald Press, 1952. 476p.

SUGENO, M. Industrial applications of fuzzy control. **Elsevier Science Pub. Co.**, 1985.

TAKAGI T. e SUGENO M. (1985). “Fuzzy identification of systems and its applications to modeling and control”, *IEEE Transactions on Systems, Man and Cybernetics*, Vol. 15, No. 1, pp.116-132.

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

TANSCHKEIT, R. **Sistemas Fuzzy**. Rio de Janeiro: DEE-PUC, 2000 35p. Apostila.

TOWELL, G.; SHAVLIK, J. Knowledge-based artificial neural networks, **Artificial Intelligence**, v.70, n.1-2., p.119-165, 1994.

THIERSCH C. R., SCOLFORO J. R., OLIVEIRA A. D. DE, MAESTRI R., DEHON G. **Acurácia dos métodos para estimativa do volume comercial de clones de *Eucalyptus sp.*** *Cerne*, Lavras, v. 12, n. 2, p. 167-181, abr./jun. 2006.

VEIGA, R. A. de A.; CARVALHO, C. M. de; BRASIL, M. A. M.. Determinação de equações de volume para árvores de *Acacia mangium* Willd. **Cerne**. Lavras, v.6, n.1, p.103-107, 2000.

YAGER, R.R.; FILEV, D.P. (1994). *Essentials of Fuzzy Modeling and Control*, John Wiley & Sons.

ZADEH, L. A. 1965. *Fuzzy sets. Information And Control* 8; 338-353