

RODRIGO DUARTE ARAUJO PEREIRA

**MODELAGEM NEURO-FUZZY NA ESTIMATIVA DO
PERFIL 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 obtenção do título de Bacharel em Ciência da Computação.

**LAVRAS
MINAS GERAIS – BRASIL
2008**

RODRIGO DUARTE ARAUJO PEREIRA

**MODELAGEM NEURO-FUZZY NA ESTIMATIVA DO
PERFIL 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 obtenção do título de Bacharel em Ciência da Computação.

Área de Concentração:
Inteligência Artificial

Orientador:

Msc. Adriano Ribeiro de Mendonça

**LAVRAS
MINAS GERAIS – BRASIL
2008**

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

Pereira, Rodrigo Duarte Araújo

Modelagem *Neuro-Fuzzy* na estimativa do Perfil de *Eucalyptos* sp / Rodrigo Duarte Araújo Pereira. Lavras – Minas Gerais, 2008. 47p. :il.

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

1. Inteligência Artificial. 2. *Neuro-Fuzzy*. 3. *Eucalyptus*. 4. Perfil. PEREIRA, R. D. A.. II Universidade Federal de Lavras. III. Título.

RODRIGO DUARTE ARAUJO PEREIRA

**MODELAGEM NEURO-FUZZY NA ESTIMATIVA DO
PERFIL 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 obtenção do título de Bacharel em Ciência da Computação.

Aprovada em (16/01/2008)

Prof. Thiago de Souza Rodrigues

Prof. Cláudio Fabiano Motta Toledo

Adriano Ribeiro de Mendonça
(Orientador)

**LAVRAS
MINAS GERAIS – BRASIL
2008**

Dedico à minha família e aos meus amigos.

MODELAGEM *NEURO-FUZZY* NA ESTIMATIVA DO PERFIL DE *Eucalyptus SP*

RESUMO

Os produtos obtidos do cultivo do *Eucalyptus* possuem destaque cada vez maior na economia nacional, seja a madeira, celulose ou como fonte de energia. Devido sua grande importância, vários estudos foram realizados com o intuito de tirar melhor proveito das áreas plantadas. Dentre as variáveis de maior importância destaca-se o perfil da árvore, que permite saber o diâmetro a qualquer altura bem como seu volume. Neste contexto, o presente trabalho visa propor uma nova alternativa para obtenção do perfil utilizando para isto a modelagem *Neuro-Fuzzy*. Métodos estatísticos foram usados pra comparar o novo modelo com outros já tradicionais, dessa forma confirmando a sua eficiência e viabilidade.

Palavras-chave: Inteligência Artificial, *Neuro-Fuzzy*, *Eucalyptus*, Perfil.

***NEURO-FUZZY* MODELING IN THE ESTIMATE OF THE *Eucalyptus SP'S* TAPER**

ABSTRACT

The gotten products of de culture *Eucalyptus* possess growing prominence in the national economy, as the wood, cellulose or as a power source. Had its great importance, lots of studies had been carried through with intention to take off better advantage or the planted areas. Amongst the most important variables, distinguishes the tree's taper that allows to know the diameter to any height as well as its volume. In this context, the present work aims at to consider a new alternative for attainment of the profile using for this the *Neuro-Fuzzy* modeling. Statistical methods has been used to compare the new model with the traditional others, therefore confirming its efficiency and viability.

Key-Words: Artificial Inteligence, *Neuro-Fuzzy*, *Eucalyptus*, taper.

SUMÁRIO

1	INTRODUÇÃO	1
2	REVISÃO DE LITERATURA	2
2.1	O Gênero <i>Eucalyptus</i>	2
2.2	Modelagem do perfil de árvores.....	3
2.2.1	Modelos que representam o perfil de árvores	5
2.2.1.1	Modelo de Schöepfer (1966)	5
2.2.1.2	Modelo de Kozak et al. (1969).....	6
2.2.1.3	Modelo de Demaerschalk (1972)	6
2.2.1.4	Modelo de Ormerod (1973).....	6
2.2.1.5	Modelo de HRADETZKY (1976).....	7
2.3	Lógica Fuzzy	7
2.3.1	Conjuntos <i>Fuzzy</i>	10
2.3.2	Tipos de Funções de Pertinência.....	11
2.4	Redes Neurais Artificiais.....	12
2.4.1	Treinamento da Rede	16
2.5	Neuro-Fuzzy	17
3	MATERIAIS E MÉTODOS	19
3.1	Tipo de Pesquisa.....	19
3.2	Obtenção dos dados.....	19
3.3	Procedimentos Metodológicos	20
3.4	Modelos Avaliados.....	21
3.5	Modelo Proposto	22
3.6	Avaliação dos Modelos	23
4	RESULTADOS E DISCUSSÃO	25
4.1	Avaliação do ajuste das equações e treinamento da rede Neuro-Fuzzy.....	25
4.2	Avaliação com dados para validação	29
5	CONCLUSÃO	33
6	REFERÊNCIAS BIBLIOGRÁFICAS.....	34

LISTA DE FIGURAS

Figura 2.1: Exemplo de uma árvore do Gênero <i>Eucalyptus</i>	2
Figura 2.2: Perfil de um tronco de <i>Eucalyptus</i>	4
Figura 2.3: Hierarquia de teorias matemáticas.....	8
Figura 2.4: Conjunto e grau de pertinência <i>Fuzzy</i>	10
Figura 2.5: Representação gráfica das funções de pertinência.....	12
Figura 2.6: Neurônio Biológico.....	13
Figura 2.7: Neurônio Artificial.....	14
Figura 2.8: Diagrama esquemático de um sistema <i>Neuro-Fuzzy</i>	18
Figura 3.1: Distribuição de frequência, por classe de DAP, das árvores-amostra utilizadas para o ajuste dos modelos de perfil e o treinamento do <i>Neuro-Fuzzy</i>	20
Figura 3.2: Distribuição de frequência, por classe de DAP, das árvores-amostra utilizadas para a validação dos modelos.....	20
Figura 3.3: Sistema <i>Fuzzy</i> gerado pelo treinamento da rede neural.....	22
Figura 4.1: Diâmetros Observados x Estimados pelo modelo de Demaerschalk com dados de treinamento.....	26
Figura 4.2: Diâmetros Observados x Estimados pelo modelo de Ormerod com dados de treinamento.....	26
Figura 4.3: Diâmetros Observados x Estimados pelo modelo de Schöepfer com dados de treinamento.....	27
Figura 4.4: Diâmetros Observados x Estimados pelo modelo <i>Neuro-Fuzzy</i> com os dados de treinamento.....	27
Figura 4.5: Diâmetros Observados x Estimados pelo modelo de Demaerschalk com dados de validação.....	29
Figura 4.6: Diâmetros Observados x Estimados pelo modelo de Ormerod com dados de validação.....	30
Figura 4.7: Diâmetros Observados x Estimados pelo modelo de Schöepfer com dados de validação.....	30
Figura 4.8: Diâmetros Observados x Estimados pelo modelo <i>Neuro-Fuzzy</i> com os dados de validação.....	31

LISTA DE TABELAS

Tabela 4.1: Medidas de precisão r e $Syx(\%)$ para os dados de treinamento.....	25
Tabela 4.2: Estatísticas Bias, MD e DPD para o perfil estimado pelos dados de treinamento.....	28
Tabela 4.3: Notas atribuídas em função das estatísticas da Tabela 4.2.....	28
Tabela 4.4: Medidas de precisão r e $Syx(\%)$ para os dados de validação.....	29
Tabela 4.5: Estatísticas Bias, MD e DPD para o perfil com os dados de validação.....	31
Tabela 4.6: Notas atribuídas em função das estatísticas da Tabela 4.5.....	32

1 INTRODUÇÃO

A atividade florestal brasileira possui um crescente destaque na economia nacional. Este fato é evidenciado pelos expressivos números do setor, tais como: PIB florestal de 21 bilhões de dólares e exportações por volta de U\$ 4 bilhões. Segundo a SBS (2007), são recolhidos impostos acima de US\$ 3 bilhões e estima-se que o setor emprega diretamente e indiretamente 6,5 milhões de pessoas em todos os seguimentos.

Nesse cenário o gênero *Eucalyptus* possui grande destaque já, que, dos 5,6 milhões de hectares de área florestal plantada existente no Brasil, 3,4 milhões de hectares são *Eucalyptus*. O gênero pode ser utilizado na indústria de papel e celulose, siderurgia como carvão vegetal, lenha, cerrado, compensados, lâminas, entre outros.

A área de plantio florestal sofre cada vez mais competição com áreas agrícolas, obrigando o setor a obter uma maior produtividade na área plantada. E uma das informações de maior importância para o conhecimento do potencial florestal de uma região é o estudo do perfil da árvore, que permite saber o diâmetro em qualquer altura bem como o seu volume. Devido a essa importância, vários estudos foram realizados onde propõem modelos para que se possa obter de forma satisfatória o perfil como: polinômio do 5º grau (SCHOEPFER, 1966); o polinômio de potência fracionária (HRADETZKY, 1976); os modelos sigmoidais (OMEROD, 1973); os modelos segmentados (MAX E BURKHART, 1976); modelos definidos através de análise multivariada (AHRENS E HOLBERT, 1981).

O principal método utilizado para o estudo do perfil da árvore é o uso de funções matemáticas que expressam o decréscimo de diâmetro na direção base-topo de uma árvore. Neste contexto, o presente trabalho visa propor uma nova alternativa para obtenção do perfil utilizando para isto a modelagem *Neuro-Fuzzy*. A técnica de *Neuro-Fuzzy* permite criar um modelo 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 a uma base de dados.

2 REVISÃO DE LITERATURA

2.1 O Gênero *Eucalyptus*

A primeira descrição botânica do gênero, que é chamado vulgarmente de eucalipto, foi feita em 1788 pelo botânico francês Charles-Louis L'Héritier de Brutelle. O nome genérico é derivado do grego, “eu” que significa “boa”, “calyptus” que significa “cobertura”, logo “boa cobertura”. São, geralmente, árvores nativas da Oceania, onde constituem, o gênero dominante da flora. O gênero inclui mais de 650 espécies, quase todas da Austrália. Adaptados praticamente a todas as condições climáticas, os eucaliptos caracterizam a paisagem da Oceania de uma forma que não é comparável a qualquer outra espécie em outro continente.



Figura 2.1: Exemplar de uma árvore do gênero *Eucalyptus*.

Devido ao seu rápido crescimento e sua utilização como matéria prima de vários produtos, grande número de espécies do gênero *Eucalyptus* foram exportadas para outros continentes onde tem ganhado uma importância econômica relevante. Sua fibra é utilizada como matéria-prima para a fabricação de papel e celulose. O tronco fornece madeira para sarrafos, lambris, ripas, vigas, postes, varas, esteios para minas, mastros para barco, tábuas

para embalagens e móveis. Das folhas, extraem-se óleos essenciais empregados em produtos de limpeza e alimentícios, em perfumes e até em remédios.

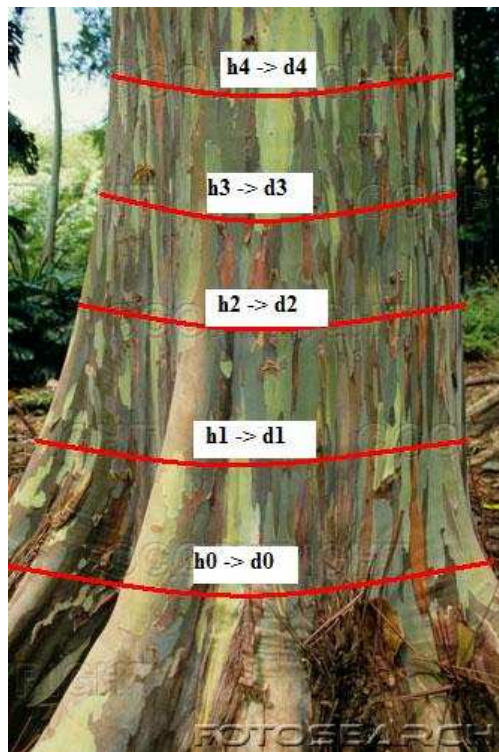
O eucalipto chegou ao Brasil em 1825, como planta ornamental. E, sua utilização para fins econômicos só teve início em 1903, quando passou a ser empregado na produção de dormentes ferroviários e lenha para alimentar as locomotivas da época. Segundo Schumacher *et al.* (2005), encontra-se no Brasil 110 das 650 espécies *Eucalyptus* existentes, onde aproximadamente 50 espécies são empregadas em plantios comerciais de larga escala. De acordo com Veiga *et al.* (2000), o papel do Brasil como produtor madeireiro e pólo de pesquisa florestal vem sendo concretizado a alguns anos. Devido à celulose de alta qualidade colocada no mercado internacional, as exportações de papel e de madeira como matéria prima para indústrias, o Brasil possui respeitável colocação frente a outros produtores e consumidores de madeira na escala mundial.

Atualmente o Brasil possui 6 milhões de hectares em área reflorestada, sendo 61% ocupada com *Eucalyptus sp.* (EMBRAPA, 2003). Devido ao clima tropical ou sub-tropical na maioria do território brasileiro, tem-se utilizado muito o gênero *Eucalyptus* em larga escala de florestas industriais. Devido ao clima, o território brasileiro propicia 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 é de aproximadamente 12 anos. Com a exploração de áreas de florestas nativas e florestas plantadas gera-se mais de 2 milhões de empregos, com uma contribuição de mais de US \$ 20 bilhões para o PIB, exporta mais de US\$ 4 bilhões (8% do agronegócio) e contribui com 3 bilhões de dólares em impostos, ao ano, arrecadados de 60.000 empresas. As florestas plantadas estão distribuídas estrategicamente, em sua maioria, nos estados do Paraná, Rio Grande do Sul, Santa Catarina, São Paulo, Minas Gerais e Espírito Santo (EMBRAPA, 2003).

2.2 Modelagem do perfil de árvores

O planejamento e a otimização das atividades de exploração de florestas plantadas são influenciados pela precisão das estimativas volumétricas para uma determinada área. Dentre os vários métodos para viabilizar a estimativa dos volumes, pode-se citar as equações de volume de simples entrada ou locais, as equações de volume de dupla entrada

ou regionais, as equações de volume associadas à relação hipsométrica, os fatores de forma, as funções *spline* e as funções de afilamento ou modelos de perfil. A Figura 2.2 ilustra o perfil de um tronco de *Eucalyptus*.



**Figura 2.2 – Perfil de um tronco de *Eucalyptus*.
Fonte: elaborada pelo autor.**

Segundo Husch *et al.* (1972), há grandes variações na forma dos troncos, ocorrendo um decréscimo em diâmetro da base para o topo. Este decréscimo em diâmetro, conhecido como afilamento ou perfil, tem efeito fundamental no volume das árvores, devido a este fator o seu conhecimento é de fundamental importância no inventário florestal. Para se estudar esse decréscimo são utilizadas técnicas de modelagem. As funções de afilamento, também conhecidas como, funções de *taper*, funções de adelgaçamento, modelos de perfil ou, ainda, funções de forma, são uma maneira de descrever matematicamente o perfil de um fuste (SCOLFORO, 2005). Estas funções são consideradas flexíveis por possibilitarem estimar: o diâmetro a uma determinada altura do tronco, a altura comercial relativa a um diâmetro mínimo de uso, bem como o volume parcial ou total do fuste, via integração da área das seções do tronco (HUSCH *et al.*, 1972). Propicia, assim, elementos para que se possa estimar a quantidade de produtos madeireiros que a árvore pode produzir, assim como seus volumes (FIGUEIREDO *et al.*, 2006).

O primeiro trabalho objetivando descrever o perfil do tronco foi feito por Hojer em 1903 e, após este, muitos outros modelos foram propostos. No Brasil há vários estudos sobre o perfil de árvores, como o de Couto & Bastos (1987) onde fizeram uma revisão das equações de volume feitas no Estado de São Paulo com espécies de *Eucalyptus*. Queiroz *et al.* (2006) desenvolveu um trabalho como propósito de avaliar a acurácia de funções de perfil para estimar diâmetros e volume do fuste de *Mimosa scabrella*, na região metropolitana de Curitiba/PR. Assis *et al.* (2001) utilizou modelos de perfil para verificar qual o melhor modelo para estimar diâmetros e volumes ao longo do fuste de *Pinus taeda*.

2.2.1 Modelos que representam o perfil de árvores

2.2.1.1 Modelo de Schöepfer (1966)

Segundo Figueiredo *et al.* (2006) o Polinômio de 5º Grau, proposto por Schöepfer (1966), é um dos modelos de perfil mais difundidos no meio florestal. E é expresso por:

$$\frac{d_{ij}}{DAP_j} = \beta_0 + \beta_1 \left(\frac{h_i}{H_j} \right) + \beta_2 \left(\frac{h_i}{H_j} \right)^2 + \beta_3 \left(\frac{h_i}{H_j} \right)^3 + \beta_4 \left(\frac{h_i}{H_j} \right)^4 + \beta_5 \left(\frac{h_i}{H_j} \right)^5 + \varepsilon_i$$

Em que:

- d = diâmetro na altura h;
- DAP = diâmetro a 1,30 m do solo (cm);
- h_i = altura ao longo do tronco da árvore (m);
- H_j = altura total (m);
- β_i = parâmetros do modelo;
- ε = erro aleatório.

O Polinômio de 5º Grau tem sido o mais utilizado para descrever o perfil de *Pinus taeda* e *Pinus elliottii* na região sul do Brasil (FIGUEIREDO FILHO *et al.*, 1996).

Segundo Scolforo *et al.* (1998), o Polinômio de 5º Grau propicia estimativas acuradas do diâmetro na base das árvores.

2.2.1.2 **Modelo de Kozak et al. (1969)**

Segundo Mendonça (2006) o modelo proposto por Kozak *et al.* (1969) é também de grande aceitação no ramo florestal. E pode ser definido por:

$$\left(\frac{d_{ij}}{DAP_j}\right)^2 = \beta_0 + \beta_1 \left(\frac{h_{ij}}{H_j}\right) + \beta_2 \left(\frac{h_{ij}}{H_j}\right)^2 + \varepsilon$$

No trabalho de Figueiredo Filho *et al.* (1996), a equação de Kozak *et al.* (1969) apresentou bons resultados acima de 30% da altura total, sendo apresentadas tendências de estimação na base do fuste.

2.2.1.3 **Modelo de Demaerschalk (1972)**

Outro modelo matemático para o perfil foi desenvolvido por Demaerschalk (1972). Expresso como se segue:

$$\left(\frac{d_{ij}}{DAP_j}\right)^2 = 10^{2\beta_0} \cdot DAP_j^{2\beta_1-2} \cdot L^{2\beta_2} \cdot H_j^{2\beta_3} + \varepsilon$$

Em que:

- $L = H_j - h_i$, correspondendo à distância do topo da árvore até um ponto qualquer no tronco.

2.2.1.4 **Modelo de Ormerod (1973)**

Ormerod (1973) propôs o seguinte modelo:

$$\left(\frac{d_{ij}}{DAP_j}\right)^2 = \left[\left(\frac{H_j - h_{ij}}{(H_j - 1,3)}\right)\right]^{2\beta_1} + \varepsilon$$

Soares *et al.* (2004) propuseram um modelo de perfil a partir do modelo de Ormerod (1973), e concluíram que o modelo proposto permite obter estimativas precisas do afilamento de árvores de eucalipto.

2.2.1.5 Modelo de HRADETZKY (1976)

Foi proposto por Hradetzky (1976) o modelo chamado de Polinômio de Potências Inteiras e Fracionárias:

$$\left(\frac{d_{ij}}{DAP_j} \right) = \beta_0 + \beta_1 \left(\frac{h_{ij}}{H_j} \right)^{p_1} + \beta_2 \left(\frac{h_{ij}}{H_j} \right)^{p_2} + \dots + \beta_n \left(\frac{h_{ij}}{H_j} \right)^{p_n} + \varepsilon$$

Em que:

- p_i = expoentes inteiros e fracionários.

Segundo Ferreira (2004), o modelo de Hradetzky (1976) se diferencia do modelo de Schöepfer (1966) por apresentar expoentes fracionários. Para Scolforo (2005), Hradetzky (1976) sugeriu potências inteiras para representar o topo da árvore e as potências fracionárias a porção inferior da árvore.

2.3 Lógica Fuzzy

A lógica difusa ou lógica *Fuzzy* é uma generalização da lógica booleana que admite valores intermediários entre falsidade e a verdade. Foi proposta por Lotfi A. Zadeh em 1965 com o trabalho titulado “Fuzzy Sets” (ZADEH, 1965) e publicado no jornal *Information and Control*. Sua concepção se deu em meio à dificuldade de classificação de conjuntos que não possuíam fronteiras bem definidas, ou seja, a transição entre os conjuntos é suave e não abrupta. Ao permitir a participação parcial dos elementos de um conjunto, transições suaves de uma regra para a outra são possíveis. Tal propriedade é desejável para modelagem de sistemas (YAGER & FILEV, 1994).

Fuzzy, em inglês, significa incerto, duvidoso. Segundo Zanon (2005) a lógica *Fuzzy* expressa exatamente os valores com que lida. Com Lógica *Fuzzy*, não se trata uma variável como tendo apenas um estado atual, mas sim com 'n' estados, cada um com um grau de associação. Em outras palavras, não afirmamos que uma casa é grande, mas sim que ela é 0,8 grande, 0,2 média e 0,0 pequena. Isto faz com que se definam conjuntos em que um dado valor pode ser enquadrado. Neste exemplo da casa têm-se três conjuntos: casas

grandes, médias e pequenas. Mas, isso não impede que tenha cinco conjuntos: casas enormes, grandes, médias, pequenas e minúsculas. O número de conjuntos nos diz quanto precisamente estamos lidando com uma variável.

A lógica *Fuzzy* foi proposta para lidar com incerteza, com a qual convivemos diariamente. Expressões vagas e incertas, comuns à maneira humana de pensar e se comunicar, não são aceitas pela lógica tradicional. Lenke (2005) reafirma esse fato quando cita que a lógica *Fuzzy* deriva da sua habilidade em inferir conclusões e gerar respostas baseadas em informações vagas, ambíguas e qualitativamente incompletas e imprecisas. Neste aspecto, os sistemas *Fuzzy* têm habilidade de raciocinar de forma semelhante à dos humanos. Seu comportamento é representado de maneira muito simples e natural, levando à construção de sistemas compreensíveis e de fácil manutenção.

De acordo com Souza (2004), a diferença entre lógica *Fuzzy* e a binária está no fato de que a lógica *Fuzzy* pode assumir mais de dois resultados distintos, também chamados de valores verdade, o que não ocorre com a teoria clássica (binária). Esses resultados não são expressos de forma bem definida e sim, lingüisticamente como: “correto, muito correto, incorreto, muito incorreto”. Tais valores estão contidos dentro de um subconjunto *Fuzzy* e expressos numericamente pelo intervalo fechado dos números reais $[0, 1]$. A Figura 2.2 apresenta a hierarquia de teorias matemáticas e onde a lógica *Fuzzy* se situa:




Figura 2.3 – Hierarquia de Teorias Matemáticas.
Fonte: Bittencourt & Osório (2002)

Particularmente, a lógica *Fuzzy* tem sido apresentada na literatura como uma das tecnologias de inteligência artificial (IA) que efetivamente resolve com sucesso certa classe de problemas, devido à propriedade de extração (representação) de informações vagas e a capacidade de realizar inferências, fatos esses que fazem com que a Lógica

Difusa tenha encontrado grandes aplicações nas seguintes áreas (PIRES, 2007):

- Sistemas Especialistas;
- Computação com Palavras;
- Raciocínio Aproximado;
- Linguagem Natural;
- Controle de Processos;
- Robótica;
- Modelagem de Sistemas Parcialmente Abertos;
- Reconhecimento de Padrões;
- Processos de Tomada de Decisão (*decision making*)

De acordo com Jafelice *et al.* (2005), os sistemas baseados na lógica *Fuzzy* têm mostrado grande utilidade em uma variedade de operações de controle industrial e em tarefas de reconhecimento de padrões que se estendem desde reconhecimento de texto manuscrito, até a avaliação de crédito financeiro. Existe, também, um interesse crescente em se utilizar a Lógica *Fuzzy* em sistemas especialistas para torná-los mais flexíveis.

A baixo alguns exemplos de aplicação que utilizam Lógica *Fuzzy* desenvolvidas pelas empresas em parênteses:

- Controle:
 - Controle de Aeronave (Rockwell Corp.);
 - Operação do Metrô de Sendai (Hitachi);
 - Transmissão Automática (Nissan, Subaru, BMW);
 - Space Shuttle Docking (NASA);
 - Estação de Tratamento de Água Nbg;
- Otimização e Planejamento:
 - Elevadores (Hitachi, Fujitech, Mitsubishi);
 - Análise do Mercado de Ações (Yamaichi);

- Análise de Sinais:
 - Ajuste de Imagem de TV (Sony);
 - Autofocus para Câmera de Vídeo (Cânon);
 - Estabilizador de Imagens de Vídeo (Panasonic).

2.3.1 Conjuntos *Fuzzy*

Os conjuntos *Fuzzy* são conjuntos que não possuem fronteiras bem definidas e que foram introduzidas devido ao fato de os conjuntos clássicos apresentarem limitações para lidar com problemas onde a transição de uma classe para a outra deve acontecer de forma suave (TANAKA, 1997).

Cada conjunto *Fuzzy*, A , é definido em termos de relevância a um conjunto universal, X , por uma função denominada de função de pertinência, associando a cada elemento x um número, $\mu_A(x)$, no intervalo fechado $[0, 1]$ que caracteriza o grau de pertinência de x em A . A função de pertinência tem a forma (KLIR *et al.*, 1997):

$$\mu_A : X \rightarrow [0,1]$$

Se desejássemos construir, por exemplo, o conjunto dos dias do “fim-de-semana” *Fuzzy* e não-*Fuzzy*. A Figura 2.3 ilustra tal situação:

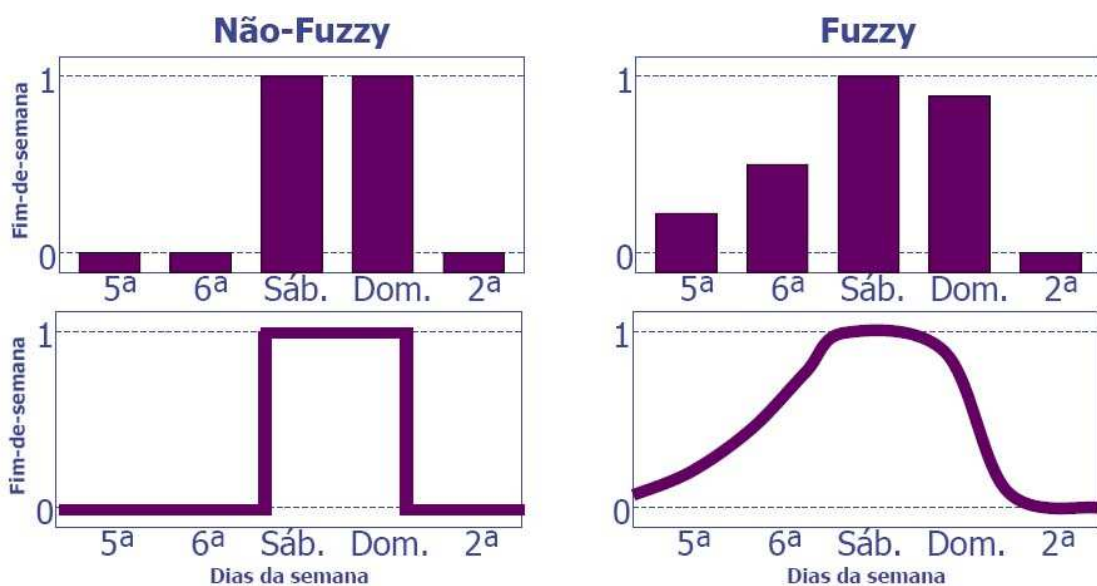


Figura 2.4 – Conjunto e Grau de Pertinência *Fuzzy*.

Nota-se pela Figura 2.3 que, ao se aproximar de sábado, a pertinência do dia é maior e que após Domingo a pertinência diminui. Enquanto que no modelo não-*Fuzzy* nota-se claramente a transição abrupta entre “fim-de-semana” ou não.

2.3.2 Tipos de Funções de Pertinência

Segundo Pedrycz & Gomide (1998), qualquer função do tipo $\mu_A : X \rightarrow [0,1]$ descreve uma função de pertinência *fuzzy*. Entre as principais estão a triangular, função- Γ , função-S, trapezoidal, gaussiana e exponencial. Veja abaixo a fórmula básica e a representação gráfica de cada uma delas:

- Função Triangular (a):

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

- Função- Γ (b):

$$\mu_A(x) = \begin{cases} 0, & \text{se } x \leq a \\ 1 - e^{-k(x-a)^2}, & \text{se } x > a \end{cases}$$

- Função-S (c):

$$\mu_A(x) = \begin{cases} 0, & \text{se } x \leq a \\ 2 \left((x-a)/(b-a) \right)^2, & \text{se } x \in [a,m] \\ 1 - 2 \left((b-x)/(b-m) \right)^2, & \text{se } x \in [m,b] \\ 1, & \text{se } x > b. \end{cases}$$

- Função Trapezoidal (d):

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

- Gaussiana (e):

$$\mu_A(x) = \begin{cases} e^{-k(x-m)^2}, & \text{se } k > 0 \end{cases}$$

- Função Exponencial (f):

$$\mu_A(x) = \begin{cases} 1/(1+k(x-m)^2), & \text{se } k > 1 \end{cases}$$




Figura 2.5 – Representação Gráfica das Funções de Pertinência.

2.4 Redes Neurais Artificiais

Cientificamente, o cérebro humano é o processador de carbono mais fascinante que existe, sendo constituído por cerca de 10 bilhões de neurônios (BRAGA *et al.*, 1998).

O neurônio biológico pode ser dividido em três partes denominadas dendritos, soma e axônio. Os dendritos são responsáveis pela recepção dos estímulos nervosos. Soma é o corpo da célula, responsável por seus processos metabólicos. Também no corpo celular (soma) o impulso é processado e novos impulsos são gerados, com destino ao exterior da célula, sendo então enviados através do axônio (KOVÁCS, 1996). Os neurônios se conectam um ao outro por meio de sinapses formando uma grande rede.




Figura 2.6 – Neurônio Biológico.

Fonte: Brown e Benchmark, Introductory Psychology Electronic Image Bank (1995)

Dessa forma as redes neurais artificiais imitam, ou tentam imitar, o funcionamento das redes neurais biológicas. A rede neural artificial 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 os neurônios, conhecidas como pesos sinápticos, é utilizada para armazenar conhecimento.

Em uma rede neural artificial, cada neurônio é uma unidade de processamento composto por uma função de ativação que gera um valor de saída para o neurônio a partir do somatório dos valores que chegam a ele.




Figura 2.7 – Neurônio Artificial.

Fonte: Paiva (1999).

Assim, os neurônios artificiais, elemento de processamento da rede neural artificial, 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).

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

Loesch (1996) diz que as 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 redes neurais artificiais exibem alta tolerância às falhas no sistema e fornecem dados que estima o processamento paralelo.

Paiva (1999) cita algumas das principais características das redes neurais, que segundo ele são:

- Um conjunto de entradas, x_j , saídas desejadas, y_j , e saídas efetivas, y , da rede;
- Um conjunto de unidades de processamento, neurônios ou células;
- Um sinal de ativação, a_i , para cada unidade i , o qual determina 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 , de uma unidade em 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;

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, re-aprender 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).

Em relação às características da arquitetura da rede, deve-se analisar primeiramente a forma como os neurônios arranjam-se nos grafos e a topologia 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 *recorrenres*).

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).

2.4.1 Treinamento da Rede

A propriedade mais importante das redes neurais é a capacidade de aprender, isto é feito através do treinamento. O treinamento de uma rede neural consiste no processo de ajuste do peso multiplicador da entrada de cada neurônio para que a rede possa realizar uma computação útil. O aprendizado ocorre quando a rede neural atinge uma solução generalizada para uma classe de problemas

Treinamento é o processo na qual “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).

O processo de treinamento, também conhecido como aprendizado, consiste na modificação ordenada dos pesos, visando a minimização de uma medida de erro, também conhecida como função de custo. O processo de treinamento pode ser dividido em três partes bem distintas. Inicialmente, a rede neural é estimulada pelo ambiente. Como resultado deste estímulo, no segundo estágio, ocorre a alteração dos seus parâmetros livres. Por fim, a rede neural passa a responder de uma nova maneira ao ambiente que está estimulado (HAYKIN, 2001).

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 resposta, utilizando como parâmetros os valores dos pesos atuais. Faz-se então uma comparação entre a resposta oferecida pela rede atual e a desejada e, com

base na similaridade entre as duas respostas, os pesos são ajustados. Esse procedimento perdura até ocorrer a classificação o mais correto possível.

- Não supervisionada: permite à rede aprender sem que exista um conjunto de “respostas desejadas” como referencia para as saídas da rede. Os pesos são ajustados à medida que a rede vai sendo provida de padrões de entrada selecionados como representativos da 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 e treina de forma não supervisionada e a segunda, de forma supervisionada.

2.5 Neuro-Fuzzy

Redes Neurais e Sistemas *Fuzzy* tem sido aplicados em muitos problemas incluindo predição, classificação e controle. Contudo ambas as abordagens possuem limitações, por exemplo o fato de redes neurais (exceto redes de base radial) não aceitarem inclusão de conhecimento prévio na sua inicialização, e 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. Com a utilização do sistema híbrido Neuro-Fuzzy, tais limitações podem ser superadas. Um sistema Neuro-Fuzzy é um sistema que usa de Redes Neurais Artificiais para determinar parâmetros, conjuntos e regras *Fuzzy*, através do processamento de exemplo de dados.

Um neurônio convencional, não “*fuzzy*”, possui N entradas, N pesos e uma saída. De acordo com Kwan & Cai (1994) um neurônio “*fuzzy*” possui N entradas com seus N pesos, e M saídas. Todas as entradas e pesos são valores reais e as saídas são valores reais no intervalo [0, 1]. Cada saída expressa o grau com que um dado pertence ao conjunto “*fuzzy*”.

Um sistema Neuro-Fuzzy pode ser representado por três camadas (HIGGINS & GOODMAN, 1994):

- Camada de entrada (“fuzzificação”): esta camada implementa a função de

pertinência gerando valores entre 0 e 1 para cada dado de entrada.

- Camada de regras (AND/OR ou MIN/MAX): esta camada contém um nó para cada regra, aplicando as operações “fuzzy” de AND e OR. As AND/OR podem ser implementadas em camadas diferentes (LEE, KWAK & KWANG, 1996 e LIN & LU, 1995) ou na mesma camada (HIGGINS & GOODMAN, 1994). As operações AND e OR podem, também, ser implementadas na mesma regra (HIGGINS & GOODMAN, 1994).
- Camada de saída (“defuzzificação”): esta camada transforma o sinal nebuloso em sua entrada em um sinal definido utilizando algumas das estratégias de “defuzzificação”.

A Figura 2.6 ilustra a arquitetura de camadas de um sistema *Neuro-Fuzzy* descrita à cima:




Figura 2.8 – Diagrama Esquemático de um sistema *Neuro-Fuzzy*.

Dentre as principais vantagens de um sistema *Neuro-Fuzzy* estão:

- Tratamento de qualquer tipo de informação (numérica, lingüística, lógica, etc.).
- Capacidade de auto-aprendizado.
- Imitação humana do processo de tomada de decisão.
- Habilidade de lidar com incertezas.
- Rápida computação usando operações de números *Fuzzy*.

Poucas são as desvantagens encontradas na utilização de sistemas *Neuro-Fuzzy*. Isto se deve ao fato que a técnica combina somente as vantagens das Redes Neurais às vantagens da Lógica *Fuzzy*, eliminando as desvantagens de ambas as técnicas.

3 MATERIAIS E MÉTODOS

3.1 *Tipo de Pesquisa*

De acordo com JUNG (2004) pode-se definir pesquisa básica 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 pesquisa exploratória visa o aprimoramento de idéias ou 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 em Mogi das Cruzes-SP, pertencente à empresa International Paper.

Para fins deste trabalho, foi feita a cubagem de 131 árvores para o ajuste dos modelos e validação dos mesmos. Para construção de um modelo adequado à realidade foram descartadas as árvores nas quais o diâmetro à altura de 1,3 m (DAP) fosse menor que 9 cm, pois as mesmas, depois de processadas, não resultariam em toras com valor comercial para serraria ou celulose, obtendo um total de 96 árvores. De modo que, foram utilizadas 76 árvores para o ajuste dos modelos de perfil e treinamento da rede, e 20 árvores para a validação dos modelos de perfil e do modelo *Neuro-Fuzzy* proposto. As

Figuras 3.1 e 3.2 mostram, respectivamente, a distribuição diamétrica das árvores usadas no treinamento e validação dos modelos utilizados.




Figura 3.1 – Distribuição de freqüência, por classe de DAP, das árvores-amostra utilizadas para o ajuste dos modelos de perfil e o treinamento do *Neuro-Fuzzy*.




Figura 3.2 – Distribuição de freqüência, por classe de DAP, das árvores-amostra utilizadas para a validação dos modelos.

3.3 Procedimentos Metodológicos

Foi desenvolvido o modelo *Neuro-Fuzzy* para a estimativa do perfil e este foi comparado com modelos clássicos. Foram escolhidos para a comparação os modelos de Demarschalk (1972), Ormerod (1973) e Schöpfer (1966).

Como ferramenta de 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 possui a seguinte configuração:

- Processador: Intel Centrino Duo 1.66 GHz;
- Memória Ram: 2 Gb.
- Disco rígido: 100 Gb.
- Sistema Operacional: Microsoft Windows XP Service Pack 2.

3.4 Modelos Avaliados

Na literatura há diversos modelos para estimativa do perfil de uma árvore. Para este trabalho foram avaliados modelos de perfil clássicos que são bem difundidos no meio florestal. Estes modelos estão descritos abaixo:

1. Modelo de Demaerscalk (1972):

$$\left(\frac{d_{ij}}{DAP_j} \right)^2 = 10^{2\beta_0} \cdot DAP_j^{2\beta_1-2} \cdot L^{2\beta_2} \cdot H_j^{2\beta_3} + \epsilon$$

Em que:

- d_{ij} = diâmetro na altura h ;
- DAP = diâmetro a 1,30 m do solo (cm);
- h_{ij} = altura ao longo do tronco da árvore (m);
- H_j = altura total da árvore (m);
- β_i = parâmetros do modelo;
- ϵ = erro aleatório.

2. Modelo de Schöepfer (1966)

$$\frac{d_{ij}}{DAP_j} = \beta_0 + \beta_1 \left(\frac{h_{ij}}{H_j} \right) + \beta_2 \left(\frac{h_{ij}}{H_j} \right)^2 + \beta_3 \left(\frac{h_{ij}}{H_j} \right)^3 + \beta_4 \left(\frac{h_{ij}}{H_j} \right)^4 + \beta_5 \left(\frac{h_{ij}}{H_j} \right)^5 + \epsilon_i$$

3. Modelo de Ormerod (1973):

$$\left(\frac{d_{ij}}{DAP_j}\right)^2 = \left[\left(\frac{H_j - h_{ij}}{(H_j - 1,3)}\right)\right]^{2\beta_1} + \varepsilon$$

3.5 Modelo Proposto

Para desenvolver o modelo *Neuro-Fuzzy* foi necessário um conjunto de dados, representado na forma matricial. As entradas para o sistema foram altura total da árvore (H_j), diâmetro a 1,3 m (DAP_j), uma relação entre a altura relativa e altura total $\left(\frac{h_{ij}}{H_j}\right)$, também usada nas maiorias dos modelos clássicos, e a altura relativa (h_{ij}) com seu respectivo diâmetro como a variável de saída.

A rede foi treinada com o método híbrido que combina o método de “backpropagation” e o método dos mínimos quadrados. Sendo, o primeiro associado às estimativas dos parâmetros das funções membro de entrada e o segundo, associado às estimativas dos parâmetros de saída das funções membro.

O sistema utilizou o operador de implicação “Sugeno” (SUGENO, 1985), por possibilitar adaptar a técnica de redes neurais na construção de Sistemas de Lógica *Fuzzy* (KLIR & YUAN, 1997). Após concluir o desenvolvimento do sistema *Neuro-Fuzzy* foram realizados testes para confirmar o seu pleno funcionamento, com o objetivo de avaliar sua precisão e consistência utilizando os conjuntos de dados de treinamento e validação e de acordo com os resultados dos outros modelos utilizados para descrever o perfil do tronco de *Eucalyptus*.

A figura a seguir ilustra o sistema *Fuzzy* gerado após o treinamento da rede.




Figura 3.3 – Sistema *Fuzzy* gerado pelo treinamento da rede neural.

3.6 Avaliação dos Modelos

Foram utilizadas 76 árvores para o ajuste dos modelos e 20 árvores 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} (%)).

$$S_{yx} = \sqrt{\frac{\sum_{i=1}^n (Y - \hat{Y})^2}{n - p}}$$

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

Em que:

- S_{yx} = erro padrão da estimativa (cm);
- S_{yx} (%) = erro padrão relativo;
- \hat{Y} = diâmetro ao longo do fuste (cm) estimado pela equação ou *neuro-fuzzy*;
- Y = diâmetro ao longo do fuste (cm) observado;
- \bar{Y} = média dos diâmetros (cm);
- n = número de observações;
- p = números de parâmetros, considerando 0 (zero) para *neuro-fuzzy*.

Os valores observados e estimados dos diâmetros de cada modelo foram confrontados em gráficos de diâmetro observado x diâmetro estimado.

Foram, também, feitos testes complementares, por meio das seguintes estatísticas: *bias* (B), médias 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*): onde $d_i = Y_i - \hat{Y}_i$.

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

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 4 de acordo com os resultados das estatísticas obtidas para cada equação. Foi considerado o modelo mais preciso aquele que resulta em menor somatório nas notas (LIMA, 1986).

4 RESULTADOS E DISCUSSÃO

4.1 Avaliação do ajuste das equações e treinamento da rede Neuro-Fuzzy

As equações estimadas para os modelos de perfil com o conjunto de 76 árvores estão apresentadas a seguir na forma de obtenção do diâmetro (d). Os parâmetros foram estimados utilizando-se o software de estatística R, o método utilizado para a estimativa foi o Método dos Mínimos Quadrados (MQD). Estas mesmas equações foram também usadas para estimar o perfil da base de dados para validação:

- Demaerschalk

$$d = \sqrt{DAP^2 (10^{2*0,1004451} * DAP^{2*0,9859005-2} * L^{2*0,9117016} * H^{2*(-0,9330205)})}$$

- Ormerod: $d = \sqrt{DAP^2 * \left(\frac{H-h}{H-1,3}\right)^{2*0,7438013}}$

- Shöepfer:

$$d = DAP \left(1,2199 - 3,9614 \left(\frac{h}{H}\right) + 16,3967 \left(\frac{h}{H}\right)^2 - 35,3852 \left(\frac{h}{H}\right)^3 + 34,3377 \left(\frac{h}{H}\right)^4 - 12,6249 \left(\frac{h}{H}\right)^5 \right)$$

Pela Tabela 4.1, pode-se observar que o modelo *Neuro-Fuzzy* apresenta ser mais acurado, pois possui o valor do teste r superior (mais próximo de 1) e de erro padrão relativo ($S_{yx}(\%)$) mais baixo, em comparação aos modelos de Demaerschalk, Ormerod e Schöepfer.

Tabela 4.1 – Medidas de precisão r e Syx(%) para os dados de treinamento.

Modelos	r	Syx(%)
Demaerschalk	0,9833	11,97
Ormerod	0,9845	11,99
Schöepfer	0,9935	6,91
<i>Neuro-Fuzzy</i>	0,9975	4,19

As Figuras 4.1 a 4.4 apresentam, graficamente, os diâmetros observados *versus* diâmetros estimados com os dados de treinamento.

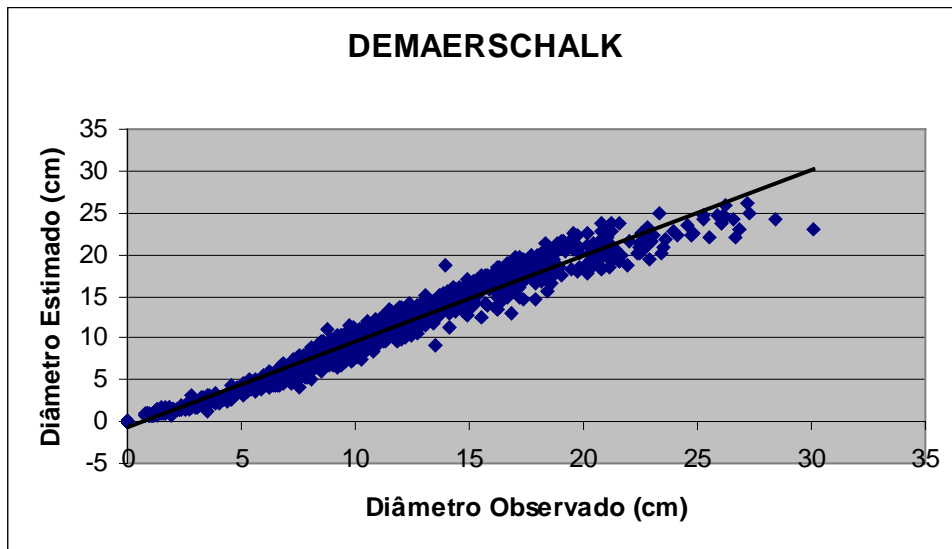


Figura 4.1 – Diâmetros Observados x Estimados pelo modelo de Demaerschalk com dados de treinamento.




Figura 4.2 – Diâmetros Observados x Estimados pelo modelo de Ormerod com dados de treinamento.

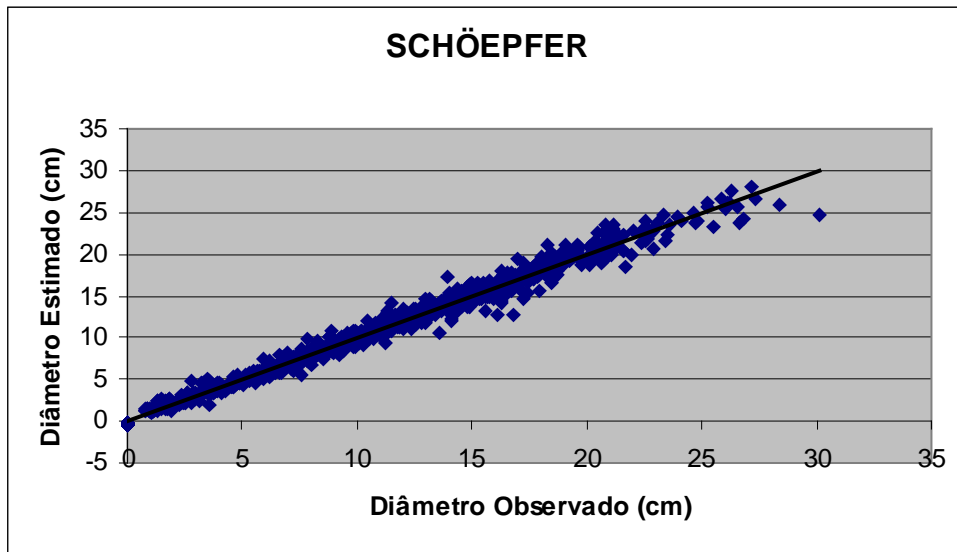


Figura 4.3 – Diâmetros Observados x Estimados pelo modelo de Schöpfer com dados de treinamento.




Figura 4.4 – Diâmetros Observados x Estimados pelo modelo *Neuro-Fuzzy* com os dados de treinamento.

Analisando as Figuras 4.1, 4.2, 4.3 e 4.4, observa-se uma melhor distribuição dos dados ao longo da reta de referência do modelo Schöpfer, pode-se também observar que todos os modelos apresentaram subestimativa para os diâmetros maiores.

A Tabela 4.2 apresenta as estatísticas “bias” (B), média das diferenças absolutas (MD) e desvio padrão das diferenças (DPD) para a estimativa do perfil de *Eucalyptus* com os dados de treinamento.

Tabela 4.2 – Estatísticas B, MD e DPD para o perfil estimado pelos dados de treinamento.

Modelos	B	MD	DPD
Demaerschalk	0,31	0,98	1,20
Ormerod	0,51	0,78	1,14
Schöpfer	-0,03	0,50	0,72
<i>Neuro-Fuzzy</i>	$1,24 \times 10^{-6}$	0,28	0,43

Os valores positivos e negativos da estatística B indicam subestimativa e superestimativa, respectivamente. Os valores mais próximos de 0 (zero) indicam que o modelo apresenta maior precisão. A Tabela 4.3 mostra as notas atribuídas para as estimativas do perfil, obtidas em função da Tabela 4.2. Como exemplo o modelo *Neuro-Fuzzy*, tem para a estatística DPD o valor 0,43 (Tabela 4.2). Ao comparar este valor com o DPD dos outros modelos, a nota atribuída a ele foi 1 (Tabela 4.3). Esse valor indica que considerando o DPD, o modelo *Neuro-Fuzzy* obteve a melhor estimativa em relação aos outros modelos.

Tabela 4.3 – Notas atribuídas em função das estatísticas da Tabela 4.2

Modelos	B	MD	DPD	Total
Demaerschalk	3	4	4	11
Ormerod	4	3	3	10
Schöpfer.	2	2	2	6
<i>Neuro-Fuzzy</i>	1	1	1	3

Analisando os resultados das Tabelas 4.2 e 4.3, verifica-se que o modelo *Neuro-Fuzzy* apresenta melhor resultado para estimativa do perfil, e através do r e Syx(%) (Tabela 4.1), seguido pelos modelos Schöpfer, Ormerod e Demaerschalk.

Levando em contas os gráficos o modelo de Shcöpfer apresentou melhor distribuição dos dados ao longo da reta de referencia, porem de forma geral o modelo *Neuro-Fuzzy* apresentou-se mais preciso para estimar o perfil de *Eucalyptus* para os dados de treinamento.

4.2 Avaliação com dados para validação

É na avaliação com os dados da validação que os modelos mostram sua capacidade de generalização, ou seja, eles devem possuir o máximo de acuracidade e conseguir estimar dados não conhecidos que correspondem aos valores de outras árvores medidas no inventário florestal.

Os dados de validação contêm 20% da base de dados. Nessa etapa não há obtenção dos parâmetros (modelos clássicos) e treinamento (*Neuro-Fuzzy*), os dados apenas são processados com o que já foi obtido na fase anterior.

Tabela 4.4 - Medidas de precisão para os dados de validação

Modelos	r	Syx(%)
Demaerschalk	0,9816	12,35
Ormerod	0,9834	12,68
Schöpfer.	0,9933	6,89
<i>Neuro-Fuzzy</i>	0,9833	9,91

O modelo de Schöpfer apreseta melhor valores paras as duas estatísticas, seguido pelo modelo *Neuro-Fuzzy*, Ormerod e Demaerschalk.

As Figuras 4.5, 4.6, 4.7 e 4.8 apresentam, graficamente, os diâmetros observados x estimados obtidos pelos modelos avaliados com os dados de validação.




Figura 4.5 – Diâmetros Observados x Estimados pelo modelo de Demaerschalk com dados de validação.




Figura 4.6 – Diâmetros Observados x Estimados pelo modelo de Ormerod com dados de validação.




Figura 4.7 – Diâmetros Observados x Estimados pelo modelo de Schöpfer com dados de validação.




Figura 4.8 – Diâmetros Observados x Estimados pelo modelo *Neuro-Fuzzy* com os dados de validação

O modelo de Schöepfer apresentou melhor distribuição dos dados ao longo da reta de referência, cabe ressaltar que em todos os modelos houve subestimativa nos diâmetros maiores, da mesma forma que na fase de treinamento e ajuste.

A Tabela 4.5 apresenta as estatísticas B, MD e DPD para a estimativa do perfil de *Eucalyptus* com os dados de validação.

Tabela 4.5 – Estatísticas B, MD e DPD para o perfil com os dados de validação.

Modelos	Bias	MD	DPD
Demaerschalk	0,45	0,99	1,21
Ormerod	0,64	0,79	1,16
Schöepfer.	0,11	0,49	0,71
<i>Neuro-Fuzzy</i>	0,06	0,62	0,78

A Tabela 4.6 apresenta as notas atribuídas, a partir das estatísticas da Tabela 4.5, aos modelos pelas estimativas com os dados de validação.

Tabela 4.6 – Notas atribuídas em função das estatísticas da Tabela 4.5.

Modelos	B	MD	DPD	Total
Demaerschalk	3	4	4	11
Ormerod	4	3	3	10
Schöpfer.	2	1	1	4
<i>Neuro-Fuzzy</i>	1	2	2	5

Analisando as tabelas 4.5 e 4.6, percebe-se que o modelo de Schöpfer apresentou maior acuracidade, seguido pelos modelos *Neuro-Fuzzy*, Ormerod e Demaerschalk.

Diferentemente dos resultados obtidos com os dados de treinamento, onde o modelo *Neuro-Fuzzy* apresenta-se como o melhor na estimativa do perfil, nos dados de validação foi superado pelo modelo de Schöpfer por uma pequena diferença nas estatísticas MD e DPD. Porém manteve-se superior em relação aos modelos de Demaerschalk e Ormerod.

Embora o modelo *Neuro-Fuzzy* proposto não apresente ser o com maior acuracidade nos dados de validação, este, ainda, se apresenta como uma boa alternativa para a estimativa do perfil. Tal afirmativa pode ser comprovada pelas estatísticas de precisão (Tabela 4.4) e os gráficos de diâmetros observados x estimados, onde o modelo *Neuro-Fuzzy* obteve resultados satisfatórios.

5 CONCLUSÃO

A partir das avaliações dos modelos com os dados de treinamento e validação, onde na primeira avaliação, o modelo *Neuro-Fuzzy* apresentou-se melhor que os demais. E na segunda, ficou atrás apenas do modelo de Schöepfer, pode-se concluir que o modelo proposto apresenta-se como uma alternativa acurada para estimativa do perfil de tronco de árvores de *Eucalyptus*.

6 REFERÊNCIAS BIBLIOGRÁFICAS

AHRENS, S.; HOLBERT, D. Uma função para a forma de tronco e volume de *Pinus taeda* L. **Boletim de Pesquisa Florestal**, Curitiba, n.3, p. 37-68, 1981.

ASSIS, A. L. de; SCOLFORO, J. R. S.; MELLO, J. M. de; ACERBI JÚNIOR, J. W.; OLIVEIRA, A. D. de.. Comparação de modelos polinomiais segmentados e não-segmentados na estimativa de diâmetros e volumes ao longo do fuste de *Pinus taeda*. **Cerne**, v. 7, n. 1, p. 20-40, 2001.

BRAGA, A. de P.; CARVALHO, A. P. de L. F. de; LUDEMIR, T. B. **Fundamentos de redes neurais artificiais**. Rio de Janeiro: DCC/I, COPPE/Sistemas, NCE/UFRJ, 1998. 246p.

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.

COUTO, H.T.Z. & BASTOS, N.L.M. Modelos de equações de volume e relações hipsométricas para plantações de **Eucalyptus** no estado de São Paulo. **IPEF**, Piracicaba (37): 33-44, 1987.

DEMAERSCHALK, J. P.. Converting volume equations to compatible taper equations. **Forest Science**, v. 18, n. 3, p. 241-245, 1972.

EMBRAPA. O cultivo de Eucalipto em: <http://sistemasdeprodução.cnptia.embrapa.br/FontesHTML/Eucalipto/CultivodoEucalipto/01_Importancia_economica.htm>. Acessado em 20 de Novembro de 2007.

FERREIRA, M. Z.. **Estudo de funções de afilamento para representar o perfil e o volume do fuste de *Pinus taeda***. Dissertação de Mestrado, Universidade Federal de Lavras, Lavras, Minas Gerais. 200pp, 2004.

FIGUEIREDO, Evandro Orfanó; SCOLFORO, José Roberto Soares; OLIVEIRA, Antonio Donizette de. **Seleção de modelos polinomiais para representar o perfil e volume do fuste de *Tectona grandis* L.f.** *Acta Amazonica*, 2006.

FIGUEIREDO FILHO, A.; BORGES, B. E.; HITCH, K. L.. Taper equations for *Pinus taeda* plantations in southern Brazil. *Florest Ecology and Management*, n.83, p.39-46, 1996.

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

HRADETZKY, J. *Analyse und interpretation statistischer abränger keiten. (Biometrische Beiträge zu aktuellen forschung projekten)*. Baden: Württemberg Mitteilung der FVA, Helf 76, 1976. 146. (Abt Biometric und Informatik, 21).

HUSCH, B.; MILLER, C. I.; BERRS, T. W. *Florest mensuration*. New York: The Ronal Press, 1972. 410p.

JAFELICE, R. S. M.; BARROS, L. C.; BASSANEZI, R. C.. **Teoria dos Conjuntos Fuzzy com Aplicações** – São Carlos, SP – Sociedade Brasileira de Matemática Aplicada e Computacional, 2005.

JANG, J. R. ANFIS: Adaptative-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.

KLIR, G. J.; CLAIR, U. H. S.; YUAM, B.. *Fuzzy Set Theory – Foundations and Applications* – New Jersey, EUA: Prentice-Hall, 1997.

KOZAK, A.; MUNRO, D. D.; SMITH, J. H. G.. Taper Functions and their Application in Forest Inventory. *The Forestry Chronicle*, v. 45, n. 4, p. 278-283, 1969.

KOVÁCS, Z. L. **Redes neurais artificiais: fundamento e aplicações**. 2. ed. Ver. E amp. São Paulo: Colledium cognitio, 1996. 174p.

KWAN, H. K.; CAI, Y.. A fuzzy neural network and its application to pattern recognition. *Fuzzy Systems, IEEE Transactions*, v.2, n.3, p. 185-193, Agosto 1994.

LIMA, F. S. **Análise de funções de “taper” destinadas à variação de multiprodutos de árvores de Pinnus elliottii**. 1986. 79p. Dissertação (mestrado em Engenharia Florestal) – Universidade Federal de Viçosa, Viçosa.

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.

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.

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

MAX, T. A.; BURKHART, H. E.. Segmented polynomial regression applied to taper equations. *Forest Science*, v. 22, n.3, p. 283-289, 1976.

MEDRADO, M. **Embrapa**. O cultivo do Eucalipto em: http://sistemasdeproducao.cnptia.embrapa.br/FontesHTML/Eucalipto/CultivodoEucalipto/01_Importancia_economica.htm. Acessado em 15/11/2007.

MENDONÇA, A. R. de. **Avaliação de uma metodologia para otimização do volume de toras comerciais de *Eucalyptus sp.* em função da qualidade do fuste**. 2006.109f. Dissertação (Mestrado em Ciência Florestal) – Universidade Federal do Espírito Santo, Alegre. 2006.

ORMEROD, D. W.. A simple bole model. *The Forestry Chronicle*, v. 49, n. 3, p. 136-138, 1973.

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.

PEDRYCZ, W.; GOMIDE, F. **An Introduction to Fuzzy Sets Analysis and Desing** – London, England: The MIT Press, 1998.

PIRES, Danilo Machado. **Modelagem Neuro-Fuzzy na estimativa do volume de *Eucalyptus sp.***/ Danilo Machado Pires. Lavras – Minas Gerais, 2007. 48p. (monografia)

QUEIROZ, D. MACHADO, S. do A. FILHO, A. F. ARCE, J. E. KOEHLER, H. S. Avaliação e Validação de Funções de Afilamento para Mimosa sacbrella Bentham em Povoamentos da Região Metropolitana de Curitiba/PR. **FLORESTA**, Curitiba, PR, v. 36, n. 2, mai/ago. 2006.

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

SCHÖEPFER, W. *Automatisierung des Massen, Sorten und Wertberechnung stender Waldbestände Schriftenreihe Bad.* [S.I.]: Wurt-Forstl., 1966. n.p.

SCOLFORO, José Roberto Soares. **Biometria Florestal: Parte I: modelos de regressão linear e não-linear; Parte II: modelos para relação hipsométrica, volume, afilamento, e peso de matéria seca.** Lavras: UFLA/FAEPE, 282p, 2005.

SCOLFORO, J. R. S.; RIOS, M. S.; OLIVEIRA, A. D. de; MELLO, J. M. de; MAESTRI, R.. **Acuracidade de equações de afilamento para representar o perfil do fuste de *Pinus elliotti*.** Cerne, v.4, n.1, p.100-122, 1998.

SHUMACHER, M. V.; CALIL, F. N.; VOGEL, H. L. M. **Silvicultura Aplicada.** Santa Maria: UFSM, 2005. 120p.

SOARES, T. S.; LEITE, H. G.; VALE, A. B.. Um modelo alternativo para a quantificação de multiprodutos em árvores individuais. **Revista Árvore**, v. 28, n. 6, p. 875-882, 2004.

SOCIEDADE BRASILEIRA DE SILVICULTURA – SBS. Setor Florestal Brasileiro. Disponível em: <http://www.sbs.org.br/estatisticas.htm>. Acesso em: 20 de Novembro de 2007.

SOUZA, O. T. L.. **Desenvolvimento de um Modelo Fuzzy para Determinação do Latente com Aplicação em Sistemas de Irrigação** – Dissertação de Mestrado, UNESP, 2004.

SUGENO, M.. Industrial applications of *Fuzzy* control. New York: **Elsevier Science**, 1985.

TANAKA, K. *An Introduction to Fuzzy for Practical Applications* – New York, EUA: Springer, 1997.

VEIGA, R. A. de A.; CARVALHO, C. M. de; BRASIL, M. A. M.. **Determinação de equações de volume para árvores de Acácia mangium Willd. Cerne**. Lavras, v.6, n.1, p.103-107, 200.

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

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