

FILLIPE GUSTAVO BRANDÃO

**ESTIMATIVA DA ALTURA TOTAL DE EUCALYPTUS SP.
UTILIZANDO LÓGICA FUZZY E NEURO FUZZY**

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
2007

FILLIPE GUSTAVO BRANDÃO

**ESTIMATIVA DA ALTURA TOTAL DE EUCALYPTUS SP.
UTILIZANDO LÓGICA FUZZY E NEURO FUZZY**

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 / Otimização

Orientador / Co-orientador:

Prof. Dr. Ricardo Martins de Abreu Silva

Msc. Adriano Ribeiro de Mendonça

LAVRAS
MINAS GERAIS – BRASIL
2007

Ficha Catalográfica

Brandão, FillipeGustavo

Estimativa da altura total de *Eucalyptus* sp. utilizando Lógica Fuzzy e Neuro Fuzzy / Fillipe Gustavo Brandão. Lavras – Minas Gerais, 2007. 62p : il.

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

1.Inteligência Artificial 2.Lógica *fuzzy* 3.Neuro *fuzzy*. I. BRANDÃO,F.G. II. Universidade Federal de Lavras. III. Título.

FILLIPE GUSTAVO BRANDÃO

**ESTIMATIVA DA ALTURA TOTAL DE EUCALYPTUS SP.
UTILIZANDO LÓGICA FUZZY E NEURO FUZZY**

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 (6 de Agosto de 2007)

Prof. Dr. Thiago de Souza Rodrigues

Prof. Dr. Claudio Fabiano Motta Toledo

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

Msc. Adriano Ribeiro de Mendonça
(Co-orientador)

LAVRAS
MINAS GERAIS – BRASIL

"A coisa mais bela que o homem pode experimentar é o mistério. É esta a emoção que está na raiz de toda ciência e arte. O homem que desconhece esse encanto, incapaz de sentir admiração e estupefação, esse já está, por assim dizer, morto, e tem os olhos extintos." Albert Einstein

Agradecimentos

A Deus pela fé e perseverança concedidos em todos os momentos da vida.
Aos meus pais, Francisco Antônio Brandão e Gilma Lopes Brandão, que não pouparam esforços para minha formação, seja de caráter ou profissional, a quem devo tudo e expresso meu eterno amor e gratidão.
Às minhas irmãs, Fernanda e Flávia, pelo carinho, amizade, força, confiança e incentivo para a realização deste curso.
À Aline por ter me acolhido com muito amor e carinho a todo instante e a quem devo muitos dos melhores momentos da minha vida.
Aos meus avós que nem cheguei a conhecer mas que lhes agradeço pela vida. Em especial minha vovó Cacilda a quem amo muito e devo minha gratidão e respeito por tudo que representa.
Ao Tio Zé, Dudu e Thiago que tiveram passagens importantes na minha vida e que agora estão em um lugar melhor.
Aos meus orientadores, Ricardo e Adriano, pela amizade, orientação, paciência e atenção dedicada durante todo o transcorrer do desenvolvimento deste trabalho.
Aos meus companheiros de república pela convivência e amizade.
Ao pessoal da TecnoLivre que me ensinaram muito, e que se tornaram pessoas especiais para mim.
Aos membros da equipe Danilo, Gleimar (baiano), Felipe, Alexandre que me ajudaram na construção deste trabalho.
A todos os professores do DCC, que me ajudarem ao longo do curso.
Enfim, a todos aqueles que tenham contribuído, direta ou indiretamente, para a realização deste trabalho, deixo registrado os meus sinceros agradecimentos.

ESTIMATIVA DA ALTURA TOTAL DE *EUCALYPTUS* sp. UTILIZANDO LÓGICA FUZZY E NEURO-FUZZY

RESUMO

A importância do Eucalipto se mostra diante de seu uso múltiplo em vários segmentos, destacando-se papel, celulose e energia. Estimar sua altura total colabora para o manejo florestal e estimativa da produção. Portanto, o objetivo desse presente trabalho será estudar os efeitos do DAP (diâmetro na altura do peito) e da idade da árvore na sua altura total e depois com base neste estudo desenvolver um sistema de decisão baseado em Lógica *fuzzy* e outro em Neuro-*fuzzy*. Em seguida, uma comparação será realizada com os principais modelos clássicos da literatura.

Palavras-Chave: *Eucalyptus* sp., Lógica *fuzzy*, Neuro-*fuzzy*

ESTIMATE OF THE TOTAL HEIGHT OF *EUCALYPTUS* sp. USING LOGICAL FUZZY AND NEURO-FUZZY

ABSTRACT

The importance of the Eucalypto if ahead shows of its multiple use in some segments, being distinguished paper, cellulose and energy. Esteem its total height collaborates for the forest and estimative handling of the production. Therefore, the objective of this present work will be to study the effect of the DBH (diameter at breast height) and the age of the tree in its total height and later on the basis of this study to develop a system of decision based on *fuzzy* Logic and another one in Neuro-*fuzzy*. After that, a comparison will be carried through with the main classic models of literature.

Key-words: *Eucalyptus* sp., *fuzzy* Logic, Neuro-*fuzzy*

SUMÁRIO

Lista de Figuras.....	ix
Lista de Tabelas.....	xi
1 Introdução.....	1
2 Referencial Teórico.....	3
2.1 Setor Florestal.....	3
2.2 O gênero Eucalyptus.....	4
2.3 Altura.....	4
2.3.1 Relações Hipsométricas.....	5
2.3.1.1 Fatores que afetam a relação hipsométrica.....	7
2.4 Lógica Fuzzy.....	7
2.4.1 Conjuntos fuzzy.....	9
2.4.2 Sistema de Inferência fuzzy.....	14
2.5 Redes Neurais.....	17
2.5.1 Treinamento da Rede.....	19
2.5.2 Neuro fuzzy.....	20
3 Proposta.....	23
3.1 Modelo baseado em Lógica fuzzy.....	23
3.2 Modelo Neuro fuzzy.....	26
4 Metodologia.....	29
4.1 Tipo de Pesquisa.....	29
4.2 Obtenção dos Dados.....	29
4.3 Procedimentos Metodológicos.....	31
4.4 Modelos comparados.....	32
4.5 Avaliação dos modelos.....	33
5 Resultados e Discussão.....	35
5.1 Avaliação com o conjunto de treino.....	35
5.2 Avaliação do conjunto de checagem.....	40
6 Conclusões e Propostas futuras.....	46
6.1 Conclusões.....	46
6.2 Trabalhos Futuros.....	46
Bibliografia.....	47

LISTA DE FIGURAS

Figura 2.1: Exemplo da operação de União.....	10
Figura 2.2: Exemplo da operação de interseção.....	10
Figura 2.3: Exemplo da operação de Complemento.....	11
Figura 2.4: Principais padrões de Funções de Pertinência.....	13
Figura 2.5: Diagrama de processo de inferência fuzzy.....	14
Figura 2.6: Exemplo de fuzzificação.....	15
Figura 2.7: Exemplo de aplicação do operador de implicação.....	16
Figura 2.8: Agregação de todas as saídas.....	16
Figura 2.9: Diagrama esquemático de um sistema neuro fuzzy.....	22
Figura 2.10: Estrutura de um sistema Neuro fuzzy.....	22
Figura 3.1: Conjuntos fuzzy com suas respectivas funções membro para o DAP.....	24
Figura 3.2: Conjuntos fuzzy com suas respectivas funções membro para a altura total.....	24
Figura 3.3: Diagrama de inferência ‘fuzzy’ utilizado para estimar a altura total do eucalipto para um DAP de 11 cm.....	25
Figura 3.4: Sistema de inferência fuzzy.....	26
Figura 3.5: Conjuntos fuzzy para a Idade.....	27
Figura 3.6: Conjuntos fuzzy para o DAP.....	28
Figura 4.1: Distribuição de frequência das idades das árvores-amostra para o treinamento.....	30
Figura 4.2: Distribuição de frequência das idades das árvores-amostra para validação dos modelos.....	30
Figura 5.1: Distribuição Residual para o modelo de Curtis com conjunto de treino.....	36
Figura 5.2: Distribuição Residual para o modelo de Curtis com Idade com conjunto de treino.....	36
Figura 5.3: Distribuição Residual para o modelo Parabólico com conjunto de treino.....	37
Figura 5.4: Distribuição residual para modelo logístico com conjunto de treino.....	37
Figura 5.5: Distribuição residual para o modelo de Prodan com conjunto de treino.....	37
Figura 5.6: Distribuição Residual do modelo fuzzy com conjunto de treino.....	38
Figura 5.7: Distribuição Residual do modelo Neuro-fuzzy com conjunto de treino.....	38
Figura 5.8: Distribuição residual da altura total para Curtis com o conjunto de checagem.....	41
Figura 5.9: Distribuição residual da altura total para Curtis com idade com o conjunto de checagem.....	42
Figura 5.10: Distribuição residual da altura total para o modelo Parabólico com o conjunto de checagem.....	42
Figura 5.11: Distribuição residual da altura total para o modelo Logístico com conjunto de checagem.....	42
Figura 5.12: Distribuição residual da altura total para o modelo de Prodan com conjunto de checagem.....	43
Figura 5.13: Distribuição residual da altura total para o modelo fuzzy com o conjunto de	

checagem.....	43
Figura 5.14: Distribuição residual da altura total para o modelo Neuro-fuzzy com o conjunto de checagem.....	43

LISTA DE TABELAS

Tabela 2.1: Principais modelos hipsometricas tradicionais	6
Tabela 3.1: Tabela com as regras geradas.....	25
Tabela 4.1: Critérios para avaliação do ajuste e validação dos modelos.....	34
Tabela 5.1: Medidas de precisão para o conjunto de treino	36
Tabela 5.2: Estatística da Bias, média das diferenças absolutas (MD) e desvio padrão das diferenças (DPD) para estimativa a altura total.....	39
Tabela 5.3: Notas atribuídas, a partir das estatísticas da Tabela 5.2, para as estimativas de altura total.....	40
Tabela 5.4: Medidas de precisão para o conjunto de checagem.....	41
Tabela 5.5: Estatística da Bias, média das diferenças absolutas (MD) e desvio padrão das diferenças (DPD) para a altura total com conjunto de checagem.....	43
Tabela 5.6: Notas atribuídas, a partir das estatísticas da Tabela 5.5, para as estimativas de altura total com o conjunto de checagem.....	43

1 INTRODUÇÃO

O setor florestal brasileiro contribui com uma parcela importante para a economia brasileira, gerando produtos para consumo direto ou para exportação, gerando impostos e empregos para a população e, ainda, atuando na conservação e preservação dos recursos naturais. De acordo com a classificação do Programa Nacional de Florestas (PNF) do Ministério do Meio Ambiente, oito cadeias produtivas exploram o patrimônio florestal: chapas e compensados, óleos e resinas; fármacos; cosméticos; alimentos; carvão, lenha e energia; papel e celulose; madeira e móveis. Segundo Embrapa (2003) no setor florestal brasileiro no que diz respeito às áreas plantadas, destacam-se as espécies do gênero *Pinus* e *Eucalyptus* que hoje no Brasil, ocupam uma área de cerca de 4,8 milhões de hectares, sendo 64% de *Eucalyptus* e 36% de *Pinus*. As maiores áreas plantadas estão nos estados de Minas Gerais, São Paulo e Paraná, destacando-se, também, Santa Catarina e Bahia.

Por ser uma madeira que pode ser aproveitada no segmento de indústria de celulose, siderurgia a carvão vegetal, lenha, serrado, compensados e lâminas, o *Eucalyptus* tem uma grande influência na economia nacional. Para Medrado (2003) a produção brasileira está aquém do desejado e acredita-se, que com base nas expectativas de crescimento de demanda, haverá uma necessidade de plantio em torno de 630 mil hectares ao ano, ao invés dos 200 mil hectares atuais. A Sociedade Brasileira de Silvicultura - SBS distribui essa necessidade de plantio como sendo: 170 mil ha / ano para celulose, 130 mil ha / ano para madeira sólida, 250 mil ha / ano para carvão vegetal e 80 mil ha / ano para energia.

Com base nesses dados observa-se a importância do *Eucalyptus* por ser uma espécie de uso múltiplo com possibilidade de atender a todos os segmentos acima descritos, principalmente para papel, celulose e energia onde historicamente tem contribuição especial. Sendo assim com este aumento de demanda surge a necessidade de uma estimativa mais precisa da altura total do Eucalipto, conseqüentemente auxiliando no controle e manejo das plantações no intuito de aumentar a produção do mesmo.

Vários estudos já foram feitos para tentar estimar a altura total do gênero *Eucalyptus* sp. Em sua maioria modelos matemáticos complexos que utilizam tanto regressão linear quanto não-linear, entre os quais pode-se citar Assman (1952), Herinksen (1950), Stofells(1953), Curtis(1967) , Scolforo (1993), Soares et al (2004).

Devido a importância de estimar a altura total de *Eucalyptus* e na tentativa de melhorar tal estimativa, o objetivo do presente trabalho foi a proposição de dois modelos, um baseado em lógica *fuzzy* e outro em *neuro-fuzzy*, para estimar a altura de *Eucalyptus sp.* diante das variáveis idade e DAP. No caso do primeiro modelo utilizar-se-á o Método Direto de Mandani. Quanto ao segundo modelo, será aplicado no desenvolvimento a técnica *Neuro-fuzzy* a partir dos dados obtidos. Tal técnica realiza o ajuste dos parâmetros de um sistema de lógica *fuzzy* do tipo Sugeno, que utiliza funções lineares nas regras de inferência.

Após toda a abordagem teórica, a proposta para a resolução do problema será explicada em detalhes referente a construção tanto do modelo em Lógica *fuzzy* quanto do modelo *Neuro-fuzzy*. Posteriormente os resultados obtidos serão explicitados e analisados de forma a se ter uma conclusão concreta sobre quais os modelos obtiveram maior desempenho.

2 REFERENCIAL TEÓRICO

2.1 Setor Florestal

De acordo com Embrapa(2005) o Setor Florestal Brasileiro conta com, aproximadamente, 530 milhões de hectares de florestas nativas, 43,5 milhões de hectares em Unidades de Conservação Federal e 4,8 milhões de hectares de florestas plantadas com *Pinus*, *Eucalyptus* e acácia-negra. Com a exploração de áreas de florestas nativas e florestas plantadas gera-se mais de 2 milhões de empregos, contribui com mais de US\$ 20 bilhões para o PIB, exporta mais de US\$ 4 bilhões (8% do agronegócio) e contribui com US\$ 3 bilhões 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.

Há uma plena convicção particularmente nos meios técnico-científicos e acadêmicos de que as atividades floresto-industriais e os produtos extraídos das florestas para os mais diversos usos (bebidas, fármacos, resinas, etc...) fazem do recurso florestal no Brasil, se gerido de forma sustentável, importante e imprescindível fator para o desenvolvimento rural. Além disso constitui um suporte para uma indústria transformadora próspera, moderna e competitiva, num contexto de ampla inserção e aceitação social, além de proporcionar importante melhoria dos recursos naturais fundamentais como a água, o solo, o ar a biodiversidade. (TONELLO et al, 2000)

Graças ao domínio tecnológico da silvicultura e às vantagens ambientais, as florestas plantadas alcançam tamanho de corte entre 12 e 14 anos, onde a idade de corte para o eucalipto chega a ser de 5 a 7 anos, para algumas regiões contra períodos em torno de 50 anos em clima temperado. Logo o eucalipto se mostra um importante segmento do agronegócio colaborando em uma grande fatia para a economia nacional.

“Estamos plenamente convencidos de que Floresta com tecnologia é Investimento econômico, social e ambiental; promove a segurança social e alimentar, apóia as ações de conservação do meio ambiente e promove a sustentabilidade do agronegócio brasileiro” (HOEFLICH, 1998).

2.2 O gênero *Eucalyptus*

O gênero *Eucalyptus*, pertencente a família Myrtaceae, é uma planta originária da Austrália, onde existem mais de 600 espécies. A partir do início do século XX, o *Eucalyptus* teve seu plantio intensificado no Brasil, sendo usado durante algum tempo nas ferrovias, como dormentes e lenha para as mariafumaças e mais tarde como poste para eletrificação das linhas. (ForestBrazil,2007).

A importância econômica que assume a cultura do *Eucalyptus* em nosso país decorre tanto da inerente multiplicidade de seus usos e empregos de suas diferentes espécies, como da expressiva área de florestas implantadas existentes. Atualmente, do eucalipto, muito se aproveita. Extraem-se óleos essenciais das folhas empregados em produtos de limpeza e alimentícios, em perfumes e em remédios. A casca oferece tanino, usado no curtimento do couro. O tronco fornece madeira para sarrafos, lambris, ripas, vigas, postes, varas, esteios para minas, mastros para barco, tábuas para embalagens e móveis. Sua fibra é utilizada como matéria-prima para a fabricação de papel e celulose.

“O eucalipto tem o dobro da produtividade de espécies coníferas plantadas no Brasil e da maioria das árvores nativas. O eucalipto é uma árvore bastante versátil e com inúmeras aplicações industriais”(Aracruz,2007).

Com base no que foi dito anteriormente observa-se a importância do eucalipto por ser uma espécie de uso múltiplo com possibilidade de atender a todos os segmentos acima descritos, principalmente para papel e celulose e energia onde historicamente deu contribuição especial.

2.3 Altura

A altura da árvore é uma importante variável dendrométrica, necessária para estimar, junto com o diâmetro, fundamentalmente o volume de madeira da árvore e seus componentes. Torna-se também necessária conhecer a medida de altura para a interpretação do processo de crescimento e incremento volumétrico, e fornece importante subsídio à classificação de sítios. A variável altura adquire também importância fundamental no estudo de sítios (CAMPOS, 1983 e FINGER, 1992), ou seja, quando se deseja conhecer o

comportamento de uma espécie em um determinado local, ao longo do tempo. Para o manejo florestal, é importante o conhecimento desta variável, pois traduz as respostas em crescimento das árvores segundo os fatores do meio em que vegetam.

Os pontos de mensurações da altura da árvore podem distinguir-se da seguinte forma:

- Altura total (H): distância vertical considerada desde o chão até o ápice da copa.
- Altura do fuste: distância vertical que corresponde desde o chão até a base da copa.
- Altura comercial: parte do fuste economicamente aproveitável que corresponde a distância desde a altura do corte até a altura do diâmetro mínimo comercial.
- Altura do toco: parte que fica no terreno após o corte aproveitável da árvore, que corresponde normalmente a distância desde o chão até uma altura de aproximadamente 30 cm.
- Altura da copa: É a distância ao longo do eixo da árvore, entre o ponto de inserção e a extremidade superior da copa.

2.3.1 Relações Hipsométricas

Segundo Campos (1983), a relação hipsométrica pode ser definida como a relação matemática entre as variáveis dendrométricas altura e diâmetro de uma árvore. A determinação da altura de uma árvore em função de seu DAP, em várias circunstâncias é a única possibilidade viável de poder definir a correspondente estrutura vertical do povoamento.

A determinação das alturas das árvores por meio de instrumentos é uma operação onerosa e sujeita a erros. Com as alturas estimadas das árvores, juntamente com seus respectivos diâmetros, é possível, empregando-se equações de volume, estimar o volume de cada árvore e conseqüentemente o volume da parcela e do povoamento.

A partir de uma amostra de dados de diâmetro e altura, é possível estabelecer uma relação matemática que permite estimar as alturas restantes da amostra e em consequência

da população, significando um grande ganho prático na realização de inventários florestais. Campos (1983) e Scolforo (1993) citam que em populações com árvores de grande porte como de eucaliptos, a variável altura é de difícil mensuração, elevando muito o tempo e o custo da coleta dos dados do inventário, podendo também aumentar a margem de erro na coleta dessa informação.

“É importante ressaltar que o uso da relação hipsométrica torna o inventário florestal mais operacional e com menor custo” (CAMPOS,1983). Com o intuito de reduzir custos durante a coleta de dados no inventário florestal, vários pesquisadores têm estudado a relação existente entre o diâmetro e a altura das árvores (BARROS, 2002).

De acordo com Campos (1993), a literatura registra uma série bastante complexa de modelos matemáticos para interpretar a relação hipsométrica. Dependendo da espécie e do sítio será escolhida uma equação matemática mais apropriada. Entre os melhores modelos e mais utilizados estão os seguintes citados na Tabela 2.1:

Tabela 2.1: Principais modelos hipsométricos tradicionais

Modelo	Autor	Forma de Ajuste
1	Modelo Parabólico	$h = \beta_0 + \beta_1 dap + \beta_2 dap^2 + \varepsilon_i$
2	Stoffels	$\ln(h) = \beta_0 + \beta_1 \ln(dap) + \varepsilon_i$
3	Curtis	$\ln(h) = \beta_0 + \beta_1 dap^{-1} + \varepsilon_i$
4	Prodan	$h = (dap^2/\beta_0 + \beta_1 dap + \beta_2 dap^2) + \varepsilon_i$
5	Modelo da Linha Reta	$h = \beta_0 + \beta_1 dap + \varepsilon_i$
6	Petterson	$1/\sqrt{h-1,3} = \beta_0 + \beta_1 dap + \varepsilon_i$

Os modelos citados acima são ditos tradicionais pois descrevem as alturas das árvores em função apenas dos diâmetros medidos a 1,30 m do solo (*DAP*).

Em populações florestais onde se conhecem o índice de sítio, suas estruturas diamétrica e de altura, a densidade e a idade, podem-se obter estimativas da altura média através dos modelos hipsométricos, os quais são denominados genéricos (SCOLFORO,1993).

2.3.1.1 Fatores que afetam a relação hipsométrica

Existem vários fatores que afetam diretamente a relação hipsométrica. Estes fatores têm sido estudados ao longo do tempo e são tratados em diversas literaturas, dentre as quais pode-se citar Loestch et al. (1973), Finger (1992), Scolforo (1993). A seguir são apresentados os principais fatores e como eles afetam a relação hipsométrica.

- **Idade:** Em idades mais jovens, o crescimento em altura das árvores é mais acentuado, o que não ocorre quando as árvores atingem a fase adulta. Baseado nisso não é difícil perceber a influência da idade nas relações hipsométricas.
- **Sítio:** Assim como a idade, o sítio também influencia as relações de crescimento, principalmente em locais menos produtivos. Portanto, povoamentos jovens em sítios bons mostram uma curva de altura íngreme, enquanto que em situação contrária as curvas são mais achatadas.
- **Densidade:** Este é um outro ponto que influencia a relação hipsométrica e ela vai ser maior ou menor dependendo a qual estrato da floresta pertence à árvore. Nas árvores dominantes a altura é pouco afetada pelo espaçamento, já nas dominadas a influência no desenvolvimento da altura é bastante acentuada.
- **Posição Sociológica:** Para árvores dominantes, a razão altura/DAP é menor do que para árvores dominadas.

2.4 Lógica *Fuzzy*

Aristóteles, filósofo grego (384 - 322 a.C.), foi o fundador da ciência da lógica, e estabeleceu um conjunto de regras rígidas para que conclusões pudessem ser aceitas logicamente válidas. O emprego da lógica de Aristóteles levava a uma linha de raciocínio lógico baseado em premissas e conclusões. Como por exemplo: se é observado que "*todo ser vivo é mortal*" (*premissa 1*), a seguir é constatado que "*João é um ser vivo*" (*premissa 2*), como conclusão tem-se que "*João é mortal*". Desde então, a lógica Ocidental, assim chamada, tem sido binária, isto é, uma declaração é falsa ou verdadeira, não podendo ser ao mesmo tempo parcialmente verdadeira e parcialmente falsa. Esta suposição e a lei da

não contradição, que coloca que "*U ou não U*" cobre todas as possibilidades, formam a base do pensamento lógico Ocidental.

A lógica *fuzzy* viola estas suposições. O conceito de dualidade, estabelecendo que algo possa e deva coexistir com o seu oposto, faz a lógica difusa parecer natural, até mesmo inevitável. A lógica de Aristóteles trata com valores "*verdade*" das afirmações, classificando-as como verdadeiras ou falsas. Não obstante, muitas das experiências humanas não podem ser classificadas simplesmente como verdadeiras ou falsas, sim ou não, branco ou preto. Por exemplo, é aquele homem alto ou baixo? A taxa de risco para aquele empreendimento é grande ou pequena? Um sim ou um não como resposta a estas questões é, na maioria das vezes, incompleta.

A lógica *fuzzy* nasceu em 1965. Neste ano Lotfi A. Zadeh, que então era professor do departamento de engenharia elétrica da Universidade da Califórnia em Berkeley, publicou um artigo titulado "*fuzzy Sets*" (ZADEH, 1965) no *journal Information and Control*. Ele propôs graduar a pertinência de elementos nos conjuntos. Esta nova teoria foi vista naquela época, por uma parte da comunidade científica, como um escândalo matemático e uma forma de pensamento impreciso.

Segundo Oliveira (2006), técnicas da área da Inteligência Artificial (IA) têm sido amplamente utilizadas na construção de sistemas que necessitam manipular conhecimento humano especializado. Um dos grandes gargalos na construção de sistemas que envolvem conhecimento especialista é a dificuldade na obtenção e modelagem desse conhecimento. Particularmente, a lógica *fuzzy* tem sido apresentada na literatura como uma das tecnologias de IA que efetivamente resolve com sucesso certa classe de problemas.

De acordo com Zanon et al (2004) a lógica *fuzzy* expressa exatamente os valores com que lida. Com lógica *fuzzy*, não trata-se 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 defina-se conjuntos em que um dado valor pode ser enquadrado. Neste exemplo da casa tem-se três conjuntos: casas grandes, médias e pequenas. Mas nada impede que tenha cinco conjuntos: casas enormes, grandes, médias, pequenas e minúsculas. O número de conjuntos nos diz quão precisamente estamos lidando com uma variável.

Segundo Lenke (2005) a força da 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 de base *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.

Tibiriçá (2005) cita como exemplo a aprovação ou reprovação de um aluno em uma disciplina que pode ser tratada como uma medida *fuzzy*, pois os conjuntos “aprovado” e “reprovado” são bem delimitados (clássico) entretanto pode existir algumas incertezas com relação aos trabalhos realizados pelo aluno ou seu comportamento em sala de aula os quais podem lhe atribuir um “grau de evidência” para cada um dos dois conjuntos.

2.4.1 Conjuntos *fuzzy*

A teoria de conjuntos *fuzzy* tem sido estendida a diversas abordagens, sendo o termo lógica *fuzzy* usado em dois sentidos distintos: um sentido mais restrito que se refere a um sistema lógico que generaliza a lógica clássica para uma mais flexível (teoria de conjuntos, implicações lógicas, verdades parciais, etc.) e um sentido mais amplo, que engloba o sentido mais restrito, que se refere a todas as teorias e tecnologias onde se aplicam conjuntos *fuzzy* (processos de decisão *fuzzy*, *fuzzy clustering*, relações *fuzzy*, modelos híbridos, etc.). Todavia, a grande maioria das teorias e técnicas abrangidas pelo sentido mais amplo da lógica *fuzzy* estão baseadas em quatro conceitos básicos: conjuntos *fuzzy*, variáveis linguísticas, distribuição de possibilidades e regras Se-Então *fuzzy*

Os conjuntos *fuzzy* são conjuntos que não possuem fronteiras bem definidas e que foram introduzidos devido ao fato de que os conjuntos clássicos apresentarem limitações para lidar com problemas onde as transições de uma classe para outra acontecem de forma suave. Sua definição, propriedades e operações são obtidas da generalização da teoria de conjuntos clássicos, recaindo esta em um caso particular da teoria de conjuntos *fuzzy*.

A teoria de conjuntos clássicos está baseada na função característica clássica, dada por

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

onde U é o conjunto Universo, A é um subconjunto de U e x é um elemento de U , ou seja, a função característica é um mapeamento do conjunto universo no conjunto $[0, 1]$. Essa função característica discrimina entre todos os elementos de U aqueles que, segundo algum critério, pertence ou não ao subconjunto A , dividindo o conjunto universo em duas partes com fronteira bem definida. As operações básicas dos conjuntos clássicos são a união, a intersecção e o complemento e eles podem ser expressos através da função característica. Seja A e B subconjuntos de U , então, temos respectivamente:

a) União

$$\mu_{A \cup B}(x) = \max(\mu_A(x), \mu_B(x))$$

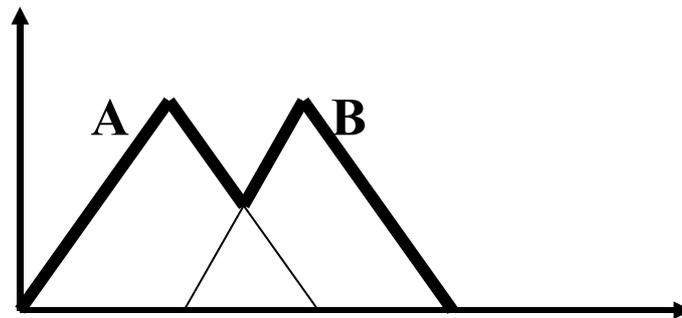


Figura 2.1: Exemplo da operação de União

b) Intersecção

$$\mu_{A \cap B}(x) = \min(\mu_A(x), \mu_B(x))$$

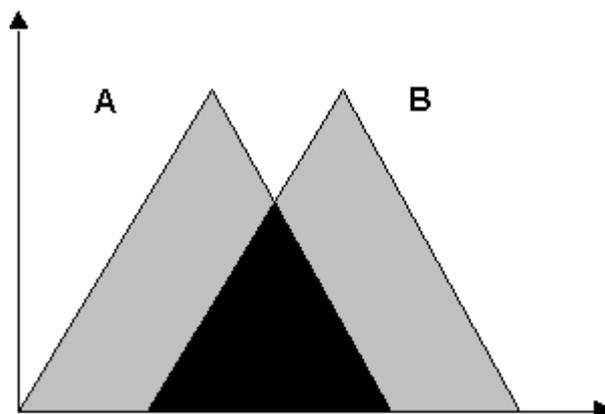


Figura 2.2: Exemplo da operação de intersecção

c) Complemento

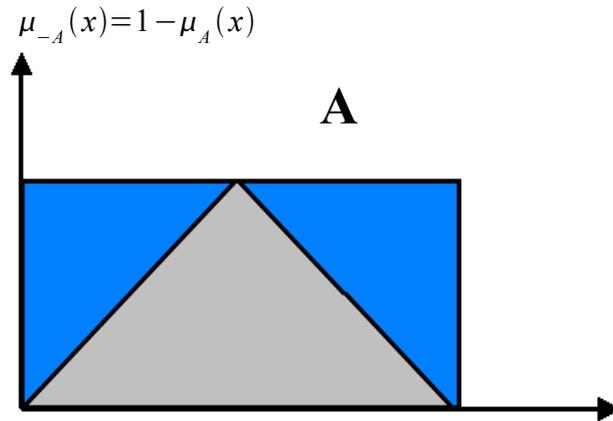


Figura 2.3: Exemplo da operação de Complemento

Note que a escolha dos operadores união e intersecção é arbitrária. A única propriedade que a operação intersecção deve satisfazer é retornar 1 quando ambos os argumentos são 1 e zero quando algum dos argumentos é 0. Da mesma forma, a operação união exige apenas que o operador retorne 1 se pelo menos um dos argumentos é 1 e zero caso contrário. Para obtermos os conjuntos *fuzzy* e suas operações basta generalizarmos a função característica da lógica clássica para o intervalo $[0, 1]$, ou seja, $\mu_A(x) : U \rightarrow [0, 1]$, o que implica em considerarmos um contínuo de valores de pertinência e não apenas pertence e não-pertence. O elemento x pertencerá ao subconjunto A com um grau de pertinência que é um valor no intervalo $[0, 1]$.

De acordo com Tanaka (1991) um conjunto *fuzzy* é caracterizado por uma função de pertinência, e o grau de pertinência pode ser considerado como uma medida que expressa a possibilidade de que um dado elemento seja membro de um conjunto *fuzzy*. Os métodos de expressão para conjuntos *fuzzy* podem ser divididos aproximadamente em dois:

- Expressão Discreta (quando o universo é finito): Na representação de um conjunto *fuzzy* temos que, se ele é discreto podemos simplesmente enumerar os seus elementos juntamente com seus graus de pertinência, peguemos o universo X sendo

$$X = \{x_1, x_2, \dots, x_n\}.$$

Então, o conjunto A em X pode ser representado como a seguir:

$$A = \mu_A(x_1)/x_1 + \mu_A(x_2)/x_2 + \dots + \mu_A(x_n)/x_n = \sum \mu_A(x_i)/x_i$$

- Expressão Contínua (quando o universo é infinito): Quando o universo X é um conjunto infinito, o conjunto *fuzzy* A em X pode ser representado como a seguir:

$$A = \int_x \mu(x_i) / x_i$$

Quando os conjuntos *fuzzy* são contínuos sua representação é a própria função de pertinência. As formas para as funções de pertinência são totalmente arbitrárias. Todavia, as funções mais utilizadas são:

- Função Triangular:

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

- Função- Γ :

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

- Função-S:

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

- Função Trapezoidal:

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

- Função Gaussiana:

$$\mu_A(x) = \left\{ e^{-k(x-m)^2}, \quad \text{se } k > 0 \right.$$

- Função Exponencial:

$$\mu_A(x) = \left\{ 1/(1+k(x-m)^2), \quad \text{se } k > 1 \right.$$

A figura 2.4 exemplificada as formas das funções de pertinência citadas acima:

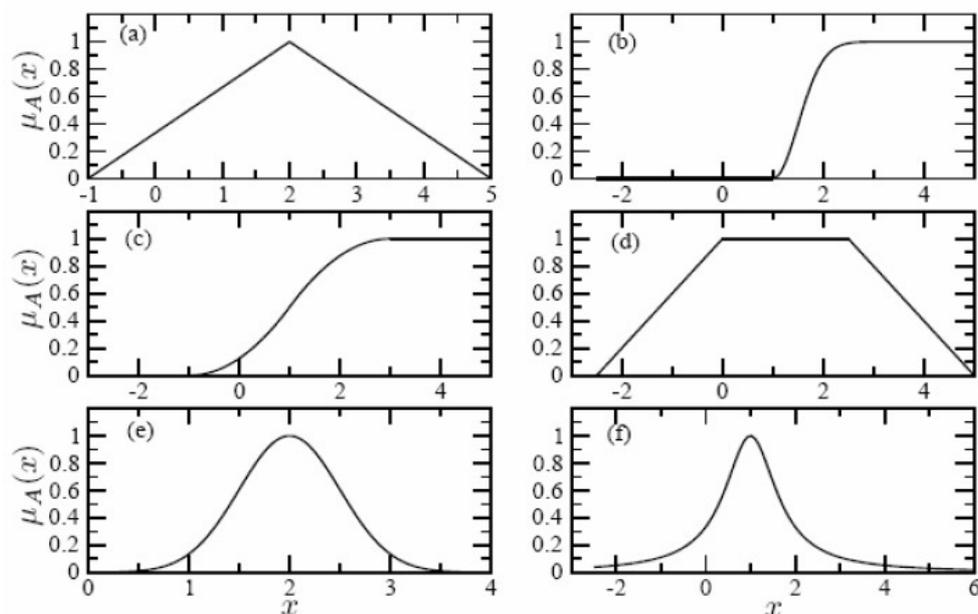


Figura 2.4: Principais padrões de Funções de Pertinência

2.4.2 Sistema de Inferência *fuzzy*

Os conceitos estabelecidos pela teoria de conjuntos *fuzzy* e da lógica *fuzzy* são utilizados na geração de programas de computador aplicados à solução de problemas como controle e automação, classificação de dados, análise de decisões, sistemas especialistas e robótica entre outras. Tais programas são conhecidos como sistemas de inferência *fuzzy*. Os principais elementos de um sistema de inferência são:

- (1) A base de regras, que contém o conjunto de regras se-então;
- (2) Um dicionário de funções de pertinência utilizadas pelas regras;
- (3) O procedimento de inferência, também denominado agregador;
- (4) Caso a saída necessite ser numérica, um processo para conversão de *fuzzy* para número, denominado “defuzzificação”.

A figura 2.5 mostra um diagrama básico de um sistema de inferência *fuzzy*.

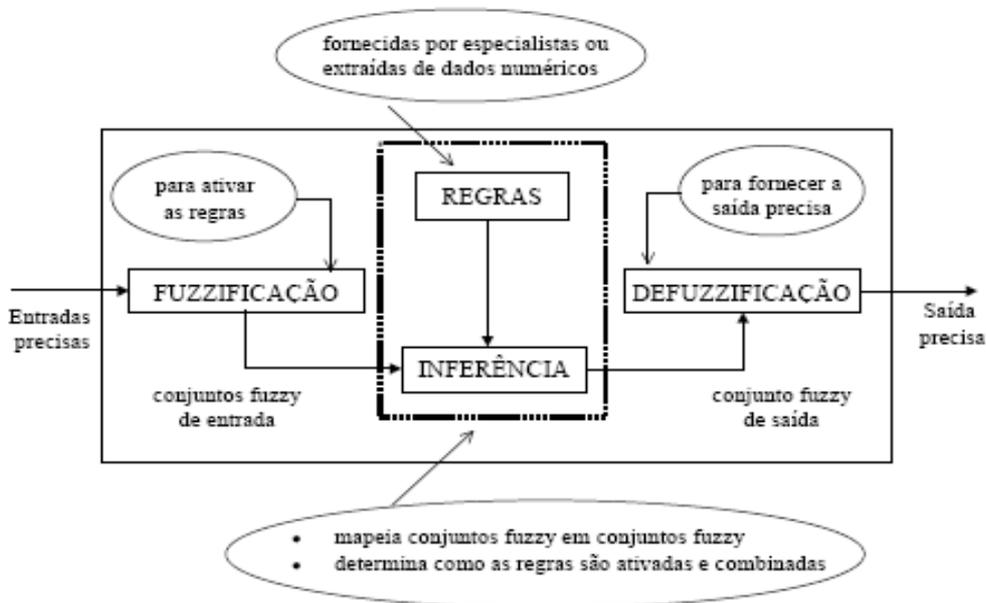


Figura 2.5: Diagrama de processo de inferência *fuzzy*

Para Tanaka (1991) a inferência *fuzzy* é o processo de mapear uma dada entrada para uma saída, utilizando-se para isto a lógica *fuzzy*. Neste processo, tem-se: funções de pertinência, operadores lógicos *fuzzy* e regras do tipo Se-Então.

De acordo com Domingos et al (2005), para estabelecer um processo de inferência *fuzzy*, é necessário estabelecer um conjunto de regras, as quais são sentenças com uma estrutura do tipo Se-Então, que são interpretadas pelo sistema. Convém ressaltar que há um paralelismo natural das regras, na forma em que são avaliadas, sendo este um dos aspectos mais importantes dos sistemas de lógica *fuzzy*. As regras são muito úteis, pois fazem referência as variáveis, aos termos e aos adjetivos que as descrevem. Para cada caso de variável analisada é estabelecida uma faixa de valores na qual ela é esperada variar, como também qual é o significado de cada termo lingüístico.

Em um Sistema de Inferência *fuzzy*, consideram-se entradas não-*fuzzy*, ou precisas – resultantes de medições ou observações (conjuntos de dados, por exemplo) –, que é o caso da grande maioria das aplicações práticas. Em virtude disto, é necessário efetuar um mapeamento destes dados precisos para os conjuntos *fuzzy* (de entrada) relevantes, o que é realizado no estágio de *fuzzificação*. Neste estágio ocorre também a *ativação* das regras relevantes para uma dada situação. A figura 2.6 apresenta um exemplo de “*fuzzificação*” da qualidade do serviço de um garçom.

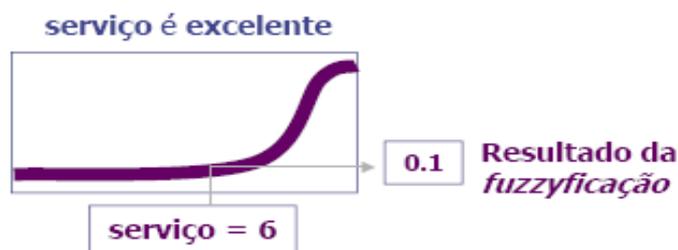


Figura 2.6: Exemplo de fuzzificação

As *regras* podem ser fornecidas por especialistas, em forma de sentenças linguísticas, e se constituem em um aspecto fundamental no desempenho de um sistema de inferência *fuzzy*. Novamente tomando o exemplo de um controlador *fuzzy*, este só terá um bom desempenho se as regras que definem a estratégia de controle forem consistentes. Extrair regras de especialistas na forma de sentenças do tipo *se ... então* pode não ser uma tarefa fácil, por mais conhecedores que eles sejam do problema em questão. Alternativamente ao uso de especialistas para a definição da base de regras, existem métodos de extração de

regras de dados numéricos. Este métodos são particularmente úteis em problemas de classificação e previsão de séries temporais.

No estágio de *inferência* ocorrem as operações com conjuntos *fuzzy* propriamente ditas: combinação dos *antecedentes* das regras, *implicação* e *modus ponens generalizado*. Os conjuntos *fuzzy* de entrada, relativos aos antecedentes das regras, e o de saída, referente ao conseqüente, podem ser definidos previamente ou, alternativamente, gerados automaticamente a partir dos dados.

A Figura 2.7 mostra um exemplo de implicação do serviço do garçom e qualidade da comida no valor da gorjeta. Neste caso se o serviço do garçom foi excelente ou se a comida for deliciosa então a gorjeta dada ao garçom será generosa.



Figura 2.7: Exemplo de aplicação do operador de implicação

A Figura 2.8 apresenta a agregação de todas as saídas, ainda seguindo o exemplo do garçom. Todas as saídas são combinadas em um único conjunto *fuzzy* onde as entradas são as funções retornadas pela implicação e a saída é um conjunto *fuzzy* para cada variável de saída.

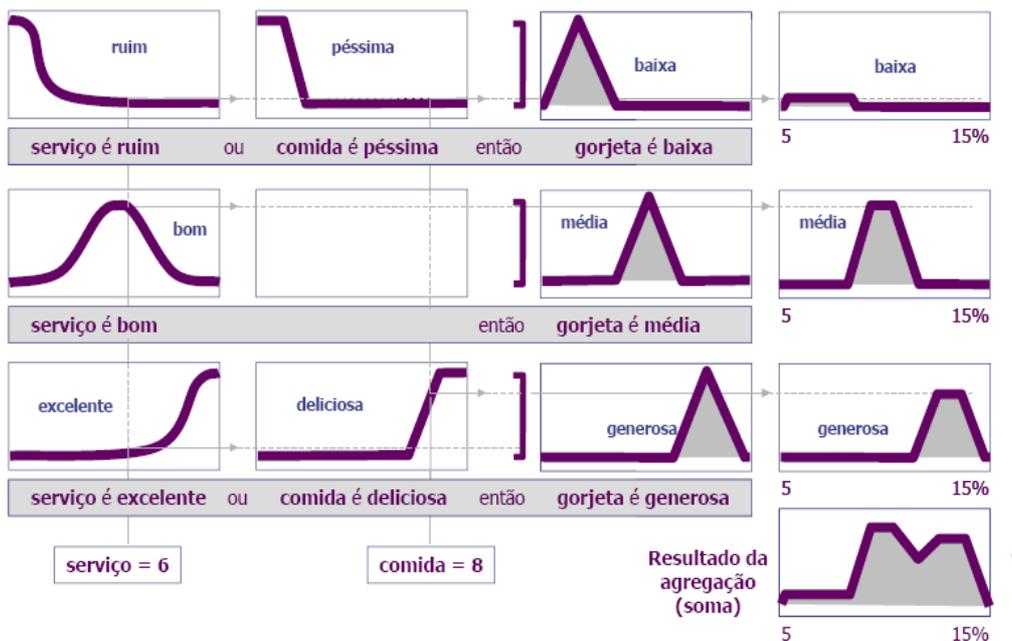


Figura 2.8: Agregação de todas as saídas

Uma vez obtido o conjunto *fuzzy* de saída por meio do processo de inferência (*modus ponens* generalizado), no estágio de *defuzzificação* é efetuada uma interpretação dessa informação. Isto se faz necessário, pois em aplicações práticas, geralmente são requeridas saídas precisas. No caso de um sistema de controle, por exemplo, em que o controle é efetuado por um sistema de inferência *fuzzy* (ou controlador *fuzzy*), este deve fornecer à planta dados ou sinais precisos, já que a "apresentação" de um conjunto *fuzzy* à entrada da planta não teria significado algum. Existem vários métodos de defuzzificação na literatura; dois dos mais empregados é o centro de gravidade e a média dos máximos. Neste, a saída precisa é obtida tomando-se a média entre os dois elementos extremos no universo que correspondem aos maiores valores da função de pertinência do consequente. Com o centro de gravidade, a saída é o valor no universo que divide a área sob a curva da função de pertinência em duas partes iguais.

Em resumo, o desempenho de um sistema de inferência *fuzzy* depende da escolha de uma base de regras adequada e do número e forma dos conjuntos atribuídos a cada variável. Pode-se inserir também a escolha do operador de implicação e do método de defuzzificação.

2.5 Redes Neurais

As redes neurais artificiais surgiram na década de 40, como uma tentativa de emular a estrutura e o funcionamento do cérebro biológico. Não se trata de uma abordagem de natureza algorítmica, ou seja, baseada em procedimentos que descrevem a solução de problemas. É um modelo inteligente, paralelo e dinâmico que adquire conhecimento e experiência paulatinamente. Devido a estas características, a computação neural é uma alternativa a métodos clássicos para resolver problemas mais complexos.

Jang(1993) cita que as redes neurais artificiais são sistemas paralelos e distribuídos formados por elementos de processamento simples que calculam funções, geralmente funções não-lineares. Esses elementos estão dispostos em camadas, interconectados por ligações geralmente unidirecionais, as quais estão associadas a um peso. Esses pesos armazenam o conhecimento da rede e servem para ponderar a entrada recebida por cada elemento.

O paradigma neural não faz uso dos conceitos que até então caracterizam os demais algoritmos e sistemas computacionais. Uma rede neural pode ser integralmente implementada em Hardware, os chips neurais são objeto de intenso estudo em grandes centros de pesquisa e muito em breve serão realidade em muitas aplicações e produtos comerciais. No Japão é comum encontrar-se hoje eletrodomésticos sendo lançados com recursos de auto-controle, por eles chamados *neuro-fuzzy* (Sistemas híbridos combinando redes neurais e lógica *fuzzy*).

Os modelos neurais foram concebidos com base na estrutura do sistema nervoso, mais especificamente na estrutura do cérebro humano e, assim, sua principal característica está na capacidade de aprender com base na exposição a exemplos. A construção de uma rede neural se constitui portanto, na configuração da sua arquitetura interna (uma rede interligada de neurônios) e no treinamento desta rede com base em exemplos, até que ela própria consiga aprender como resolver o problema.

Na sua tarefa de emular a estrutura e o funcionamento básico do cérebro, as redes neurais fazem uso de um modelo abstrato (matemático) do neurônio cerebral. No modelo de neurônio artificial, a intensidade das ligações entre neurônios (sinapses) são emuladas através de pesos, que são ajustáveis durante o processo de evolução do treinamento e aprendizado da rede. O corpo celular é emulado pela composição de duas funções, chamadas geralmente na literatura de funções de ativação e de propagação. Estas funções realizam o mapeamento, ou seja a transferência dos sinais de entrada em um único sinal de saída. Este sinal de saída é então, propagado para os neurônios seguintes da rede, como no modelo biológico.

Diversos são os modelos de rede propostos na literatura, cada qual advindo de uma linha de pesquisa diferente e visando um melhor desempenho na solução de um tipo específico de problema. Basicamente, os modelos neurais podem ser classificados segundo:

- (a) **A estratégia de treinamento:** em supervisionados (quando a rede dispõe de um instrutor apontando erros e acertos) ou não-supervisionados (caso contrário).
- (b) **A forma de treinamento:** em incremental (quando o conhecimento da rede se ajusta após a apresentação de cada padrão de entrada (estímulo)) ou lote (onde o ajuste do conhecimento só é realizado após “visão” de todos os estímulos).

- (c) **A forma de operação:** em unidirecional (os sinais internos se propagam apenas na direção entrada/saída - *feedforward*) e recorrente (quando há realimentação – *recurrent*).

As RNAs para resolver um problema, antes devem passar por um processo de aprendizagem, durante o qual os seus pesos são ajustados. Para treinar uma rede, é necessário apresentar a ela um conjunto de exemplos de entradas, chamado de conjunto de treinamento. Desta forma, a rede consegue extrair informações importantes sobre as características das entradas. Após a aprendizagem, a rede é capaz de fazer generalizações, ou seja, fornecer respostas coerentes para dados de entrada nunca vistos, baseada em características de exemplos já aprendidos.(OLIVEIRA,2002).

2.5.1 Treinamento da Rede

É na fase de treinamento que a rede neural aprende o problema e tenta resolvê-lo auto ajustando seus parâmetros internos. Uma vez que a rede tenha aprendido, isto é, ela tenha chegado a uma condição de erro considerada satisfatória, seus parâmetros são congelados e ela, a partir de então, está pronta para ser usada com dados da situação corrente.

Segundo Thome (2005) existem várias arquiteturas e várias técnicas de treinamento de rede neural propostas na literatura. Cada uma com vantagens e desvantagens, dependendo do problema e da aplicação específica a que se destinam. Na etapa do treinamento é escolhido o algoritmo de aprendizado juntamente com os parâmetros de aprendizado. O aprendizado é o processo pelo qual a rede adapta seus parâmetros (em geral os pesos das conexões entre os neurônios) de forma a satisfazer os requisitos de mapeamento estabelecidos. A dinâmica de treinamento representa a frequência com que estes parâmetros (pesos) são atualizados.

A taxa de aprendizado é um valor positivo, geralmente menor do que 1, que regula a intensidade com que as atualizações dos parâmetros (pesos) serão efetuadas. Taxas muito baixas, próximas de zero, tendem a fazer com que o aprendizado seja bastante lento, porém taxas muito altas, próximas de 1, podem fazer com que a rede oscile, como se estivesse aprendendo e desaprendendo, e às vezes nem consiga chegar a um patamar aceitável de aprendizado. O valor da taxa de aprendizado não precisa permanecer fixo durante todo o

treinamento. Em algumas implementações ela pode ser adaptativa e controlada pela própria rede.

A taxa de momento é um parâmetro de uso opcional, de valor também positivo e menor do que 1, cuja utilização visa imprimir uma dinâmica no treinamento tal que, eventualmente, possibilite o algoritmo livrar-se de mínimos locais durante o processo de busca pelo mínimo global (ponto de menor erro). Fazendo um paralelo com o mundo real, a taxa de momento aplica um fator de inércia no processo de evolução do treinamento, que se mantém acelerando enquanto o permanecer diminuindo e, assim, eventualmente faz com que o processo adquira velocidade suficiente para livrar-se de pequenos buracos (mínimos locais) que possam ser encontrados pelo caminho.

A condição de parada é geralmente estipulada com base na ocorrência de dois eventos: erro mínimo e número de ciclos. A parada pelo erro mínimo ocorre se e quando o algoritmo de treinamento levar a rede a convergir para um erro menor que o mínimo estipulado como critério de término. A parada pelo número de ciclos de treinamento encerra o processo independentemente do nível de aprendizado alcançado pela rede. A parada por este critério deve sempre ser utilizada em conjunto com qualquer outro, com vistas a evitar processos de treino intermináveis.

2.5.2 Neuro *fuzzy*

Cada técnica de inteligência artificial possui características que a torna adequada a determinadas aplicações. Por causa do alto paralelismo na sua estrutura, as redes neurais têm respostas mais rápida e com melhor desempenho do que os computadores seqüenciais na emulação do cérebro humano (KWAN e CAI, 1994). Assim processamentos de grandes quantidades de dados tornam-se fáceis mediante *hardware* adequado.

De outro lado, a lógica *fuzzy* é uma poderosa ferramenta para modelar o pensamento e a percepção humana (KWAN e CAI, 1994). O raciocínio humano é de alguma forma nebuloso, pois é capaz de trabalhar com dados incertos, incompletos e ambíguos. As imagens na vida real, frequentemente contém dados que são incompletos ou ambíguos (LAW, ITOH e SEKI, 1994). A utilidade da lógica “*fuzzy*” está na sua habilidade de tratar esses dados que são encontrados frequentemente na prática (PAL e MITRA, 1992).

Os sistemas híbridos combinam duas ou mais técnicas de maneira a aproveitar suas vantagens, e também superar algumas limitações que as técnicas individuais possuem. Assim, para habilitar um sistema a manipular situações da vida real de uma forma mais parecida com a do ser humano, uma forma é incorporar os conceitos dos conjuntos *fuzzy* dentro de redes neurais (PAL e MITRA, 1992).

As redes neuro-*fuzzy* podem ser divididas em duas categorias. Um grupo de redes neurais para o raciocínio *fuzzy* utilizam pesos *fuzzy* nas conexões entre nós. No segundo grupo, os dados são “fuzzificados” na primeira ou segunda camada, mas os pesos da rede não são *fuzzy*, sendo este o grupo mais utilizado na prática.

Um neurônio não *fuzzy* convencional possui N entradas, N pesos e uma saída. O neurônio soma o produto das N entradas com seus pesos correspondentes e através de uma função de ativação é calculada a saída.

Segundo 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 modelo pertence ao conjunto *fuzzy*.

Um sistema neuro-*fuzzy* pode ser representado através das seguintes camadas (HIGGINS e GOODMAN, 1989):

- Camada de entrada (“fuzzificação”): esta camada implementa a função de pertinência gerando valores entre 0 e 1 para um dado na 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 regras AND/OR podem ser implementadas em camadas diferentes (LEE, KWAK & KWANG, 1996) ou na mesma camada. As operações AND e OR podem, também, ser implementadas na mesma regra (HIGGINS & GOODMAN, 1989).
- Camada de saída (“defuzzificação”): esta camada transforma o sinal nebuloso em sua entrada em um sinal definido utilizando algumas das estratégias de “defuzzificação”.

Uma possível arquitetura de um sistema híbrido neuro-*fuzzy* é mostrada na Figura 2.9 O sistema contém três diferentes camadas, sendo elas:

- Camada de Fuzzificação;
- Camada de Inferência (Regras *fuzzy*);
- Camada de Defuzzificação.

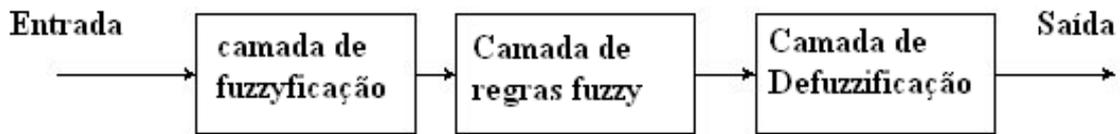


Figura 2.9: Diagrama esquemático de um sistema neuro *fuzzy*

Na *Camada de Fuzzificação* cada neurônio representa uma função "membro" de entrada do antecedente de uma regra *fuzzy* (ver Figura 2.10) . Na *Camada de Inferência* as regras são ativadas e os valores ao final de cada regra representam o peso inicial da regra, e serão ajustados ao seu próprio nível ao final do treinamento. Na *Camada de Defuzzificação* cada neurônio representa uma proposição conseqüente e suas funções "membros" podem ser implementadas combinando uma ou duas funções "sigmoid" e lineares. O peso de cada saída representa aqui o centro de gravidade de cada saída da função "membro". Após adquirir a saída correspondente o ajuste é feito na conexão do peso e nas funções "membro" visando compensar o erro e produzir um novo controle de sinal.

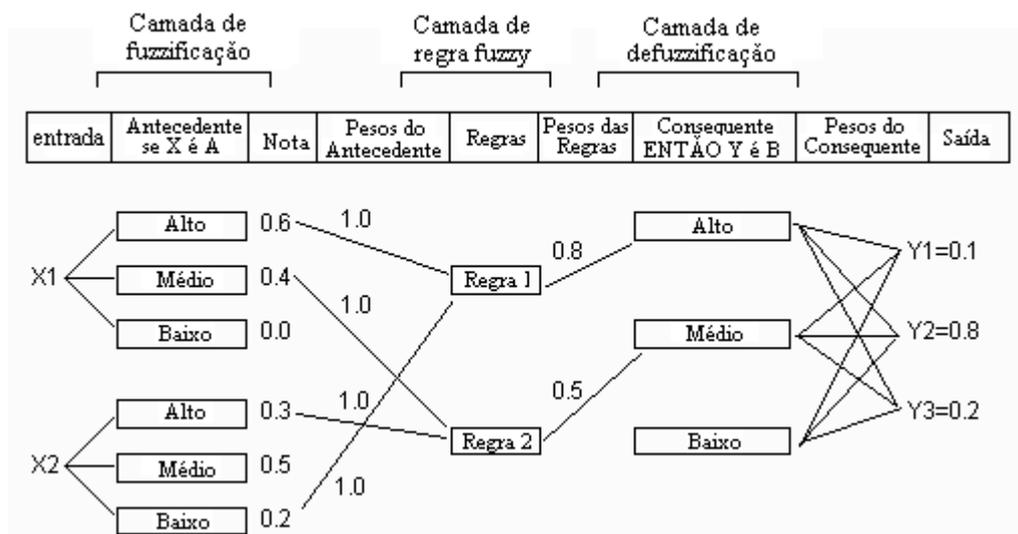


Figura 2.10: Estrutura de um sistema Neuro *fuzzy*

3 PROPOSTA

3.1 Modelo baseado em Lógica *fuzzy*

Para o desenvolvimento do modelo em lógica *fuzzy* foi usado o modelo direto de Mandani. Foram construídas funções de pertinência, diferentes conjuntos *fuzzy* para cada variável, e regras de inferência, do tipo ‘se-então’. Para essa construção foi requerida a ajuda de especialistas, de informações da literatura da área e de dados cuja interpretação possa ajudar nesse trabalho.

O modelo contém uma entrada e uma saída. Como entrada foi usado o DAP e para ela foram criados 9 conjuntos *fuzzy* (Figura 3.1). A altura total foi utilizada como saída e neste caso foram criados 7 conjuntos *fuzzy* (Figura 3.2). Posteriormente especificou-se um conjunto de regras de inferência para relacionar as variáveis e seus conjuntos de forma a constituir o mecanismo de inferência (Tanaka, 1997). O sistema utilizou o operador de implicação “Mínimo” de Mamdani por ser intuitivo, amplamente aceito e por traduzir melhor a experiência humana (Driankov et al., 1993), para composição foi usado o operador 'MAX' que considera apenas o valor de pertinência máximo.

Foram geradas nove regras de inferência (Tabela 3.1), de acordo com informações do especialista e análise da base de dados. O esquema que mostra as regras criadas operando sobre os conjuntos e suas funções de pertinência para determinados valores de entrada é o diagrama de inferência (Figura 3.3).

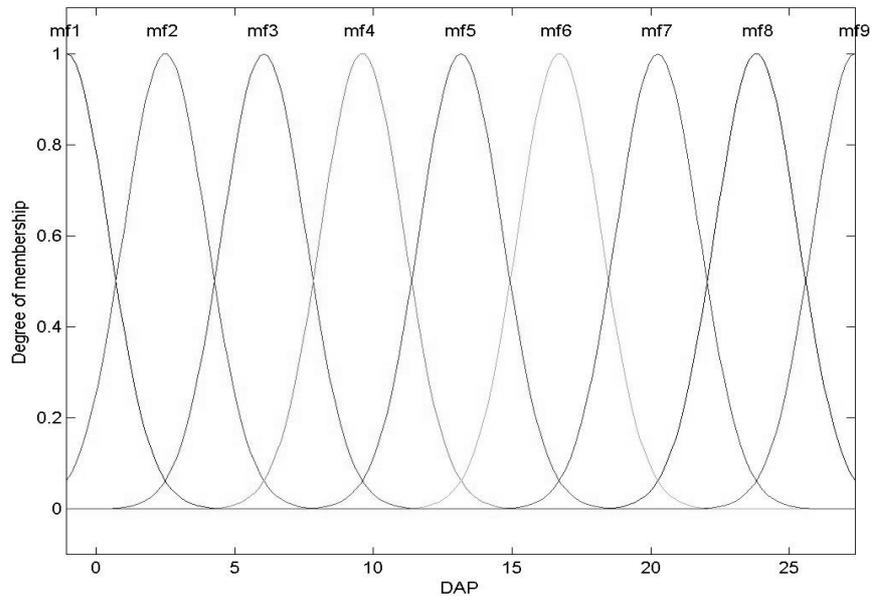


Figura 3.1: Conjuntos *fuzzy* com suas respectivas funções membro para o DAP

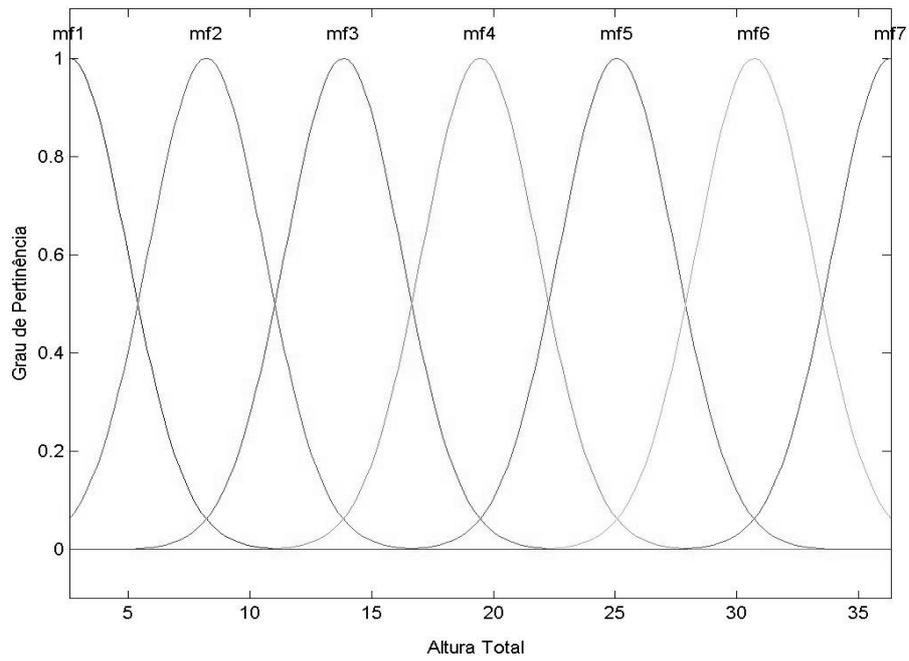


Figura 3.2: Conjuntos *fuzzy* com suas respectivas funções membro para a altura total

Nº		REGRAS SE-ENTÃO		
1.	se	(DAP is mf7)	ENTÃO	(Altura_Total is mf6)
2.	SE	(DAP is mf4)	ENTÃO	(Altura_Total is mf4)
3.	SE	(DAP is mf5)	ENTÃO	(Altura_Total is mf5)
4.	SE	(DAP is mf3)	ENTÃO	(Altura_Total is mf3)
5.	SE	(DAP is mf6)	ENTÃO	(Altura_Total is mf5)
6.	SE	(DAP is mf2)	ENTÃO	(Altura_Total is mf2)
7.	SE	(DAP is mf1)	ENTÃO	(Altura_Total is mf1)
8.	SE	(DAP is mf8)	ENTÃO	(Altura_Total is mf6)
9.	SE	(DAP is mf9)	ENTÃO	(Altura_Total is mf7)

Tabela 3.1: Tabela com as regras geradas

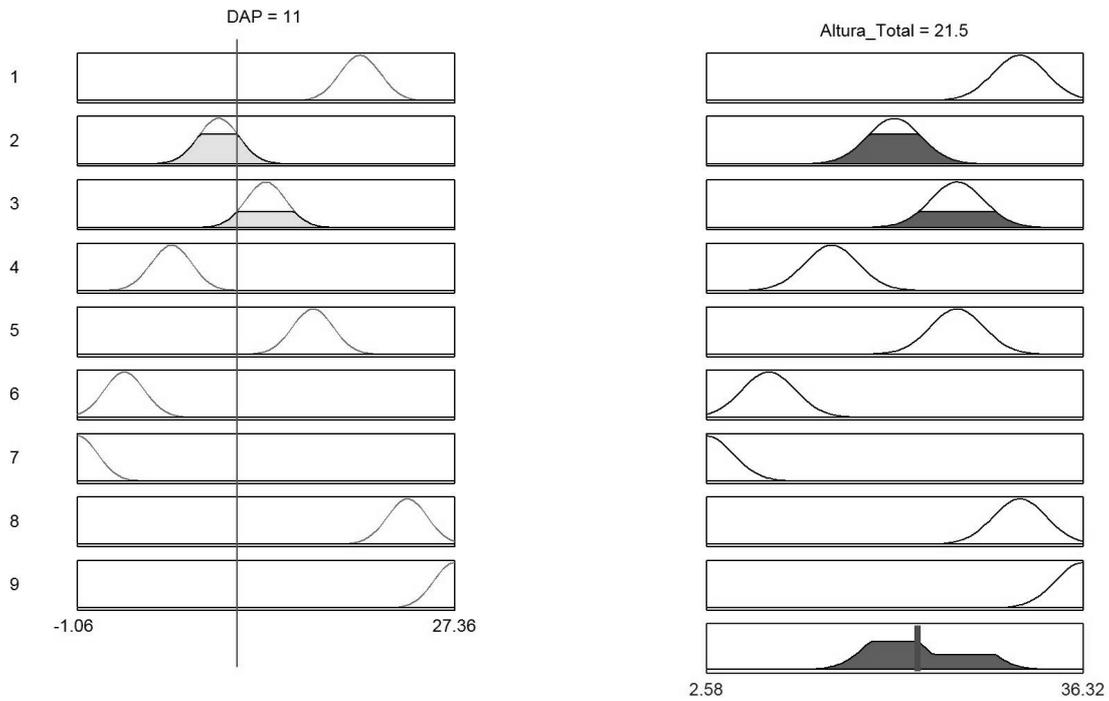


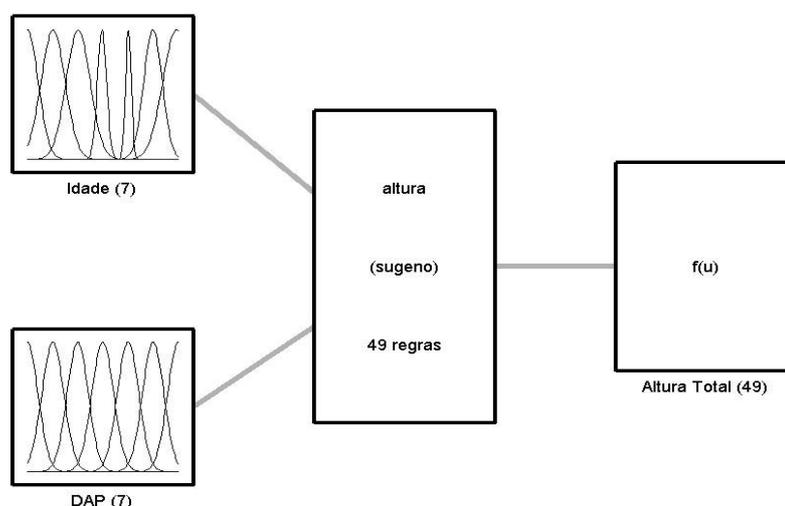
Figura 3.3: Diagrama de inferência 'fuzzy' utilizado para estimar a altura total do eucalipto para um DAP de 11 cm.

3.2 Modelo Neuro *fuzzy*

O modelo proposto utiliza o sistema híbrido *neuro-fuzzy* idealizado por Roger Jang (JANG, 1993). Para desenvolver o sistema *Neuro-fuzzy* foi necessário um conjunto de dados, representados na forma de matriz, onde os dados referentes à variável de saída estavam na última coluna. Foram utilizados dados obtidos nos experimentos descritos. Nesse caso, definiram-se as funções de pertinência ou funções membro e base de regras por meio de uma rede neuronal (Jang, 1993; Jang & Sun, 1995; Almeida, 2004)

A matriz de dados possui duas entradas e uma saída. A primeira entrada é a idade do *Eucalyptus*, a segunda o DAP da árvore e a saída é a altura total. Como o treinamento foi supervisionado, esta saída é a valor real da base de dados, pois é necessário calcular o erro para o aprendizado. Esta matriz de dados então foi carregada para a rede.

Após o carregamento foi gerado o FIS (*fuzzy Inference System*). Neste trabalho escolheu-se o método *Grid Partition*, com 7 funções de pertinência para a primeira variável (idade), 7 funções de pertinência para a segunda (DAP). A Figura 3.4 mostra o FIS do problema abordado.



System altura total: 2 entradas, 1 saída, 49 regras

Figura 3.4: Sistema de inferência *fuzzy*

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 foram o erro igual a zero e o número de épocas igual a 50.

Neste método de treinamento o aprendizado ocorre 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.

Logo após o fim do treinamento, gerou-se as funções de pertinência *fuzzy*, mostradas nas Figuras 3.5 e 3.6.

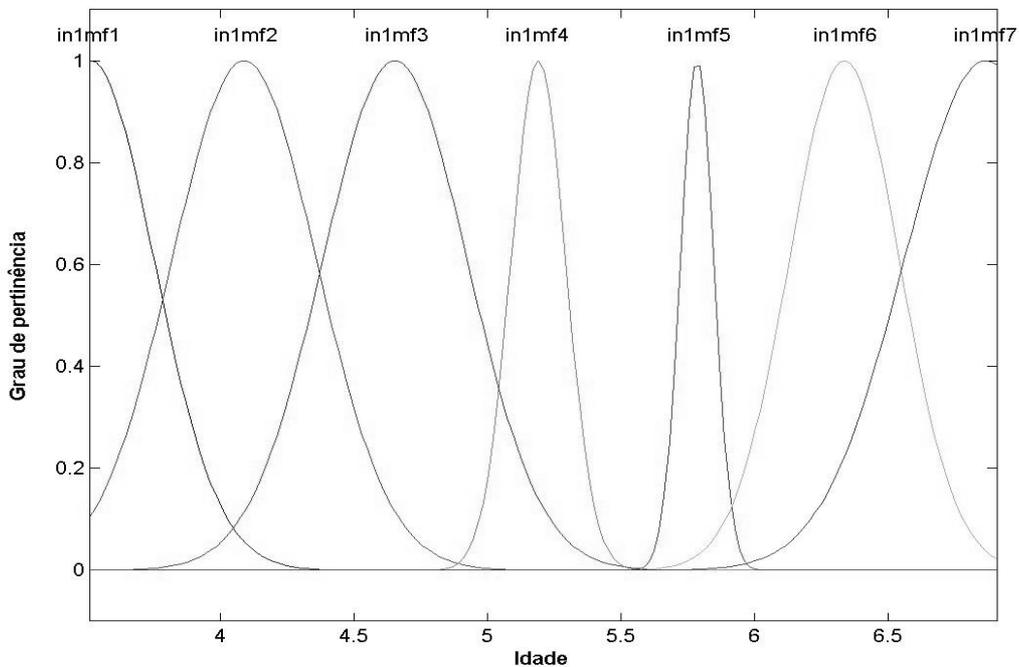


Figura 3.5: Conjuntos *fuzzy* para a Idade

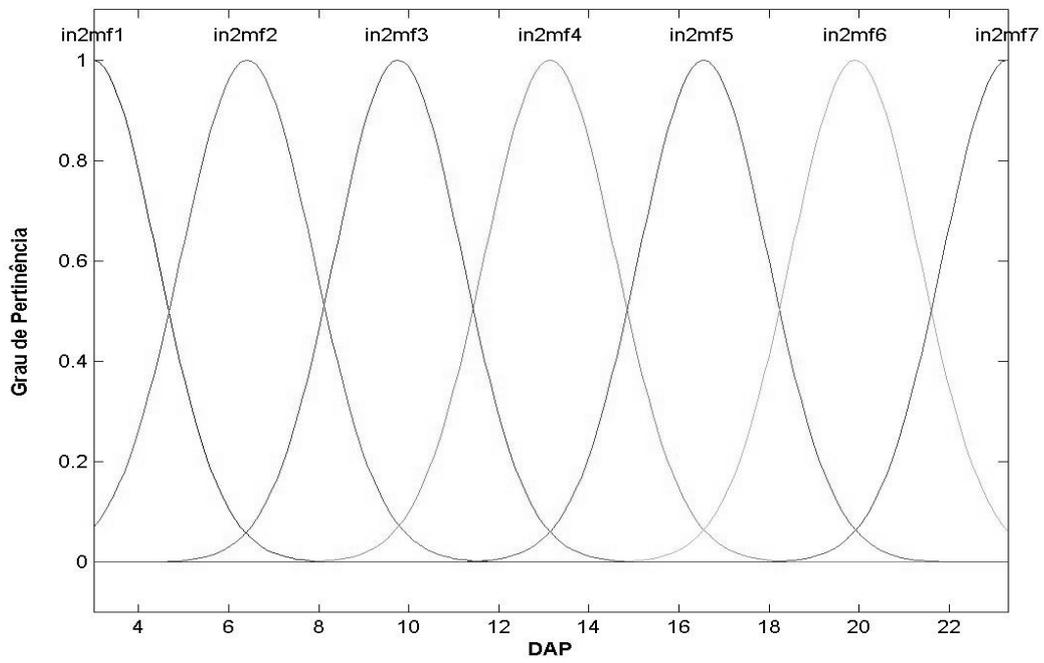


Figura 3.6: Conjuntos *fuzzy* para o DAP

4 METODOLOGIA

Para desenvolver um sistema de lógica *fuzzy* e neuro *fuzzy* foram necessários dados sobre o problema abordado. Estes ajudarão a interpretar e construir a intuição sobre o problema utilizando o método direto de Mandani ou de Sugeno.

4.1 Tipo de Pesquisa

Pesquisa é o mesmo que busca ou procura. Pesquisar, portanto, é buscar ou procurar respostas para alguma coisa. Em se tratando de Ciência a pesquisa é a busca de solução a um problema em que alguém queira saber a resposta. Não é certo dizer que se faz ciência, mas que se produz ciência através de uma pesquisa. Pesquisa é portanto o caminho para se chegar à ciência, ao conhecimento.

É na pesquisa que utilizaremos diferentes instrumentos para se chegar a uma resposta mais precisa. O instrumento ideal deverá ser estipulado pelo pesquisador para se atingir os resultados ideais.

Segundo Jung (2004), tem-se que a presente pesquisa será de natureza aplicada ou tecnológica pois pode ser utilizada para prever o crescimento e conseqüentemente a produção do *Eucalyptus*, com características de pesquisa exploratória porque visa conhecer os fatos e fenômenos relacionados ao tema e recuperar as informações disponíveis sobre o problema, seguindo os procedimentos de pesquisa operacional, fundamentados em referências bibliográficas e documental, classificada quanto ao local como pesquisa laboratorial e quanto ao tempo como estudo longitudinal.

4.2 Obtenção dos Dados

A base de dados utilizada é proveniente da empresa International Paper. É originada de povoamentos comerciais clonais de *Eucalyptus sp.*, situados em Mogi das Cruzes, São Paulo - Brasil. Os dados foram coletados a partir do processo de inventário florestal com a medição do diâmetro a 1,30 m do solo (DAP) e altura total de árvores de *Eucalyptus sp.* com idades variando de 3,51 a 6,90 anos. Foram selecionadas 131 árvores-amostra de um mesmo clone, totalizando 131 árvores.

Destas foram selecionadas 91 árvores da amostra para o treinamento e para o ajuste dos modelos que utilizam regressão. Já para a validação dos modelos utilizou-se 40 árvores-amostra. As figuras 4.1 e 4.2 mostram respectivamente a distribuição de frequência dos conjuntos de árvores-amostra usados no treinamento e validação dos modelos utilizados.

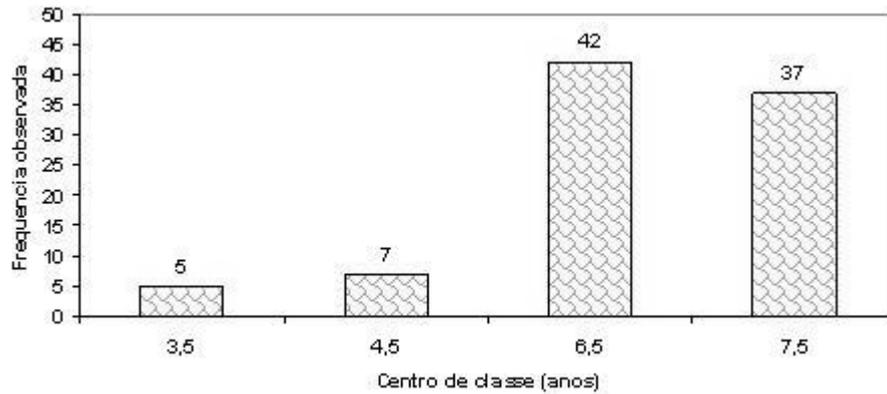


Figura 4.1: Distribuição de frequência das idades das árvores-amostra para o treinamento

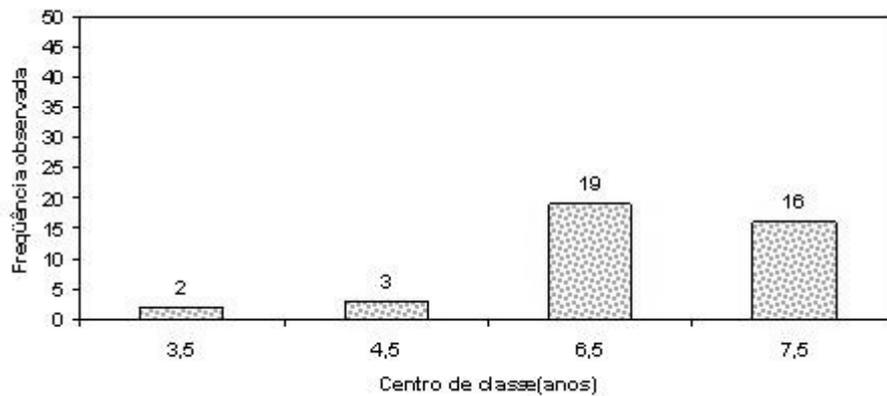


Figura 4.2: Distribuição de frequência das idades das árvores-amostra para validação dos modelos

4.3 Procedimentos Metodológicos

A pesquisa foi desenvolvida no período de janeiro a junho de 2007.

Inicialmente foi feita uma revisão bibliográfica sobre a predição da altura utilizando o DAP, teorias e técnicas relativas a lógica *fuzzy*, redes neurais, sistemas híbridos e neuro-*fuzzy*. Para tal foram utilizados livros, teses e artigos e materiais disponíveis na internet. Em paralelo foi realizado o estudo e análise da base de dados disponibilizada para o trabalho.

Posteriormente foram criados os modelos de lógica *fuzzy* e neuro *fuzzy* para a resolução do problema e ambos comparados a outros 5 modelos. Foram escolhidos para a comparação os modelos de Curtis, Curtis com idade, Parabólico, Logístico e de Prodan pois como já foi dito antes estes são uns dos melhores e mais utilizados na predição de altura utilizando o DAP.

O utilitário usado para o desenvolvimento da parte relacionada a lógica *fuzzy* foi o *fuzzy Logic Toolbox* versão 2.2 que faz parte do software MATLAB R2006b v.7.3.0.267[®]. Para o desenvolvimento do modelo neuro *fuzzy* utilizou-se o módulo denominado ANFIS parte integrante do toolbox citado acima.

Os sistemas operacionais utilizados tanto para a modelagem e desenvolvimento quanto para a revisão de literatura foram o Microsoft Windows XP[®] Professional versão 2002 Service Pack 2 e o Kurumin 7. A criação e simulação do modelo foi feita em um computador AMD Athlon 3800+ com 1GB de memória RAM.

4.4 Modelos comparados

Existem vários modelos para a predição da altura total das árvores. Para este trabalho foram comparados cinco modelos hipsométricos que são bem difundidos no meio florestal. Esses modelos são descritos abaixo:

- Curtis: $\ln H = \beta_0 + \beta_1 DAP^{-1} + \varepsilon$
- Curtis com idade: $\ln H = \beta_0 + \beta_1 DAP^{-1} + \beta_2 I^{-1} + \beta_3 (DAP \cdot I)^{-1} + \varepsilon$

onde I : idade

- Parabólico: $H = \beta_0 + \beta_1 DAP + \beta_2 DAP^2 + \varepsilon$
- Prodan: $\ln H = \beta_0 + \beta_1 \ln(DAP) + \varepsilon$
- Logístico: $H = \frac{\beta_0}{(1 + \exp((\beta_1 - DAP)/\beta_2))}$

Estes modelos citados acima foram comparados tanto com o modelo de lógica *fuzzy* quanto com o neuro-*fuzzy*.

4.5 Avaliação dos modelos

Foram utilizadas 91 árvores para o ajuste dos modelos e 40 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} (%)).

$$S_{yx} = \sqrt{\frac{(Y - \hat{Y})^2}{(n - p)}}$$
$$S_{yx} (\%) = \frac{S_{yx}}{\bar{Y}} \cdot 100$$

onde,

S_{yx} = erro padrão da estimativa (m);

S_{yx} (%) = erro padrão relativo;

\hat{Y} = altura total (m) estimada;

Y = altura total (m) observada;

\bar{Y} = media das alturas totais;

n = número de observações;

p = número de parâmetros (considerada zero (0) para *Fuzzy* e *Neuro-Fuzzy*).

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

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

Realizou-se também testes complementares, por meio das seguintes estatísticas: *bias* (B); média das diferenças absolutas (MD); e desvio padrão das diferenças (DPD). Foi considerado o modelo mais preciso, aquele que resulta em menor somatório nas notas para a altura total (Lima, 1986 e Mendonça et al., 2007). A Tabela 4.1 apresenta os critérios e respectivos estimadores para avaliação do ajuste e validação dos modelos.

Tabela 4.1: Critérios para avaliação do ajuste e validação dos modelos

Critério	Estimador
Bias (B)	$B = \frac{\sum_{i=1}^n Y_i - \sum_{i=1}^n \hat{Y}_i}{n}$
Media das diferenças absolutas (MD)	$MD = \frac{\sum_{i=1}^n Y_i - \hat{Y}_i }{n}$
Desvio padrão das diferenças (DPD)	$DPD = \sqrt{\left(\sum_{i=1}^n d_i^2\right) - \left(\sum_{i=1}^n d_i\right)^2 / n}$

Para a estatística Bias os valores negativos e positivos indicam um subestimativa e superestimativa respectivamente. Os menores valores das três estatísticas testadas indicam que a equação apresenta maior precisão quanto a estimativa da altura total da árvore.

5 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 Curtis, Curtis com idade, Parabólico, Logístico e Prodan. No subtópico 5.1 será apresentado os resultados para o conjunto de dados de treinamento e no subtópico 5.2 será apresentando os resultados para o conjunto de checagem/validação, conjunto este que não é conhecido por nenhum dos modelos.

5.1 Avaliação com o conjunto de treino

As equações estimadas para os modelos tradicionais com o conjunto de 91 árvores que foram para a obtenção dos parâmetros são apresentadas logo abaixo:

- Curtis: $\ln H = 3,534882 - 5,44553 \cdot \frac{1}{DAP}$

- Curtis com idade:

$$\ln H = 3,461818 - 5,06878 \cdot \frac{1}{DAP} + 0,419402 \cdot \frac{1}{I} - 2,18368 \cdot \frac{1}{DAP \cdot I}$$

- Parabólico: $H = -0,0988 + 2,552543 \cdot DAP - 0,06052 \cdot DAP^2$

- Prodan: $\ln H = 0,627045 + 0,635641 \cdot \ln DAP$

- Logístico: $H = \frac{27,3394}{(1 + \exp((6,49695 - DAP)/3,83406))}$

Através das medidas de precisão das equações testadas apresentadas na Tabela 5.1, observa-se que os modelos *Neuro-fuzzy e fuzzy* apresentam um melhor grau de ajuste, pois apresentaram valores de r superiores (mais próximos de 1) e de erro padrão relativo ($S_{Y,X}$ (%)) mais baixo, seguido dos modelos Parabólico, Logístico, Prodan, Curtis e Curtis com idade.

Modelos	r	Syx(%)
Curtis	0,964471	7,237039
Curtis com idade	0,96436	7,285877
Parabólico	0,969668	6,467256
Logístico	0,969548	6,480282
Prodan	0,967808	6,553775
Lógica Fuzzy	0,97022	6,335519
Neuro-Fuzzy	0,988495	3,965766

Tabela 5.1: Medidas de precisão para o conjunto de treino

As Figuras 5.1 a 5.7 apresentam graficamente a distribuição residual da estimativa da altura total para os modelos avaliados.

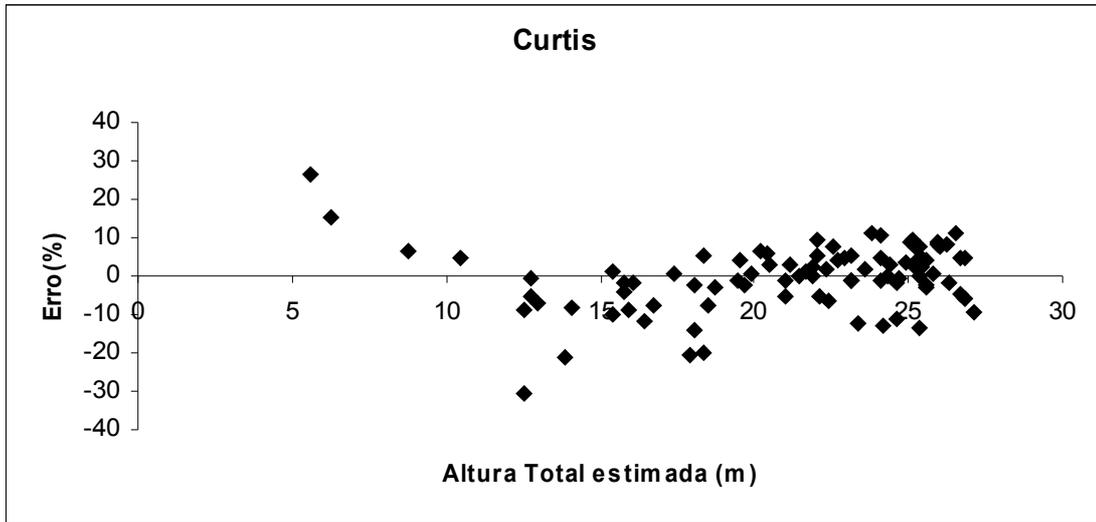


Figura 5.1: Distribuição Residual para o modelo de Curtis com conjunto de treino

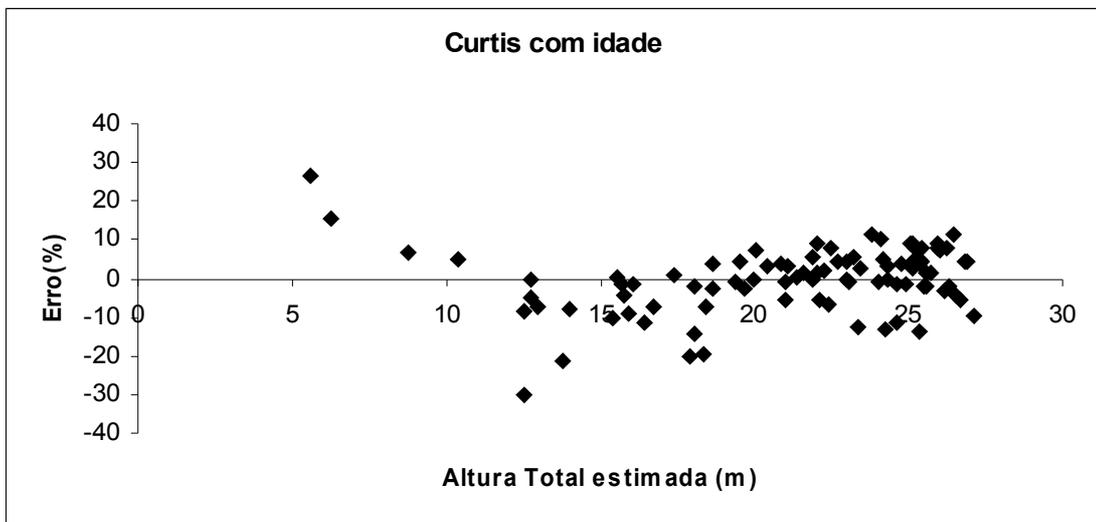


Figura 5.2: Distribuição Residual para o modelo de Curtis com Idade com conjunto de treino

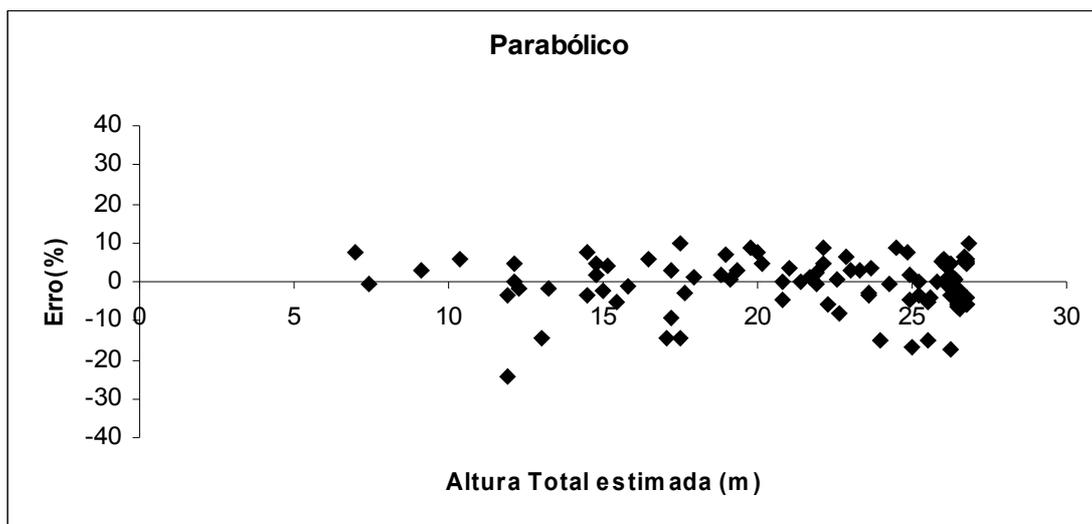


Figura 5.3: Distribuição Residual para o modelo Parabólico com conjunto de treino

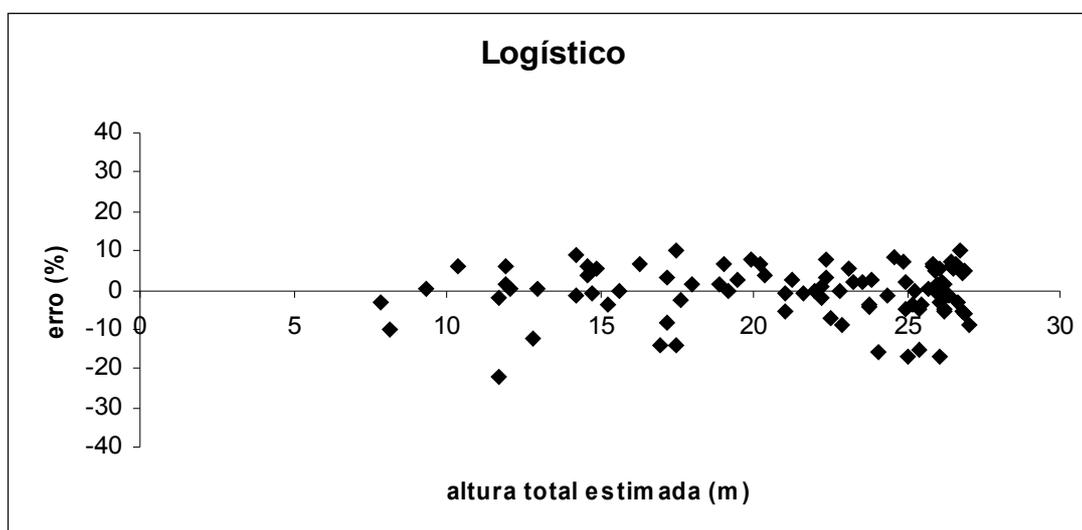


Figura 5.4: Distribuição residual para modelo logístico com conjunto de treino

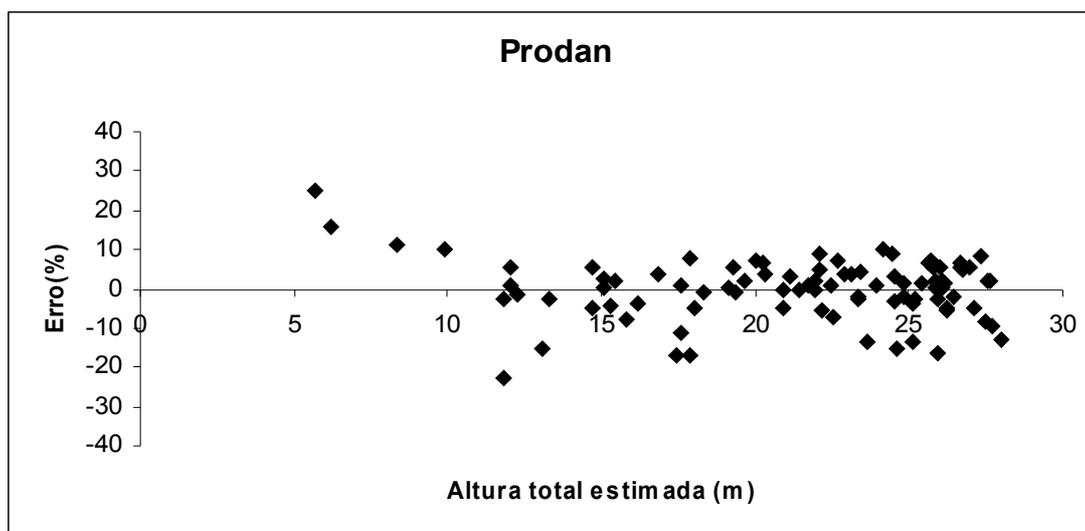


Figura 5.5: Distribuição residual para o modelo de Prodan com conjunto de treino

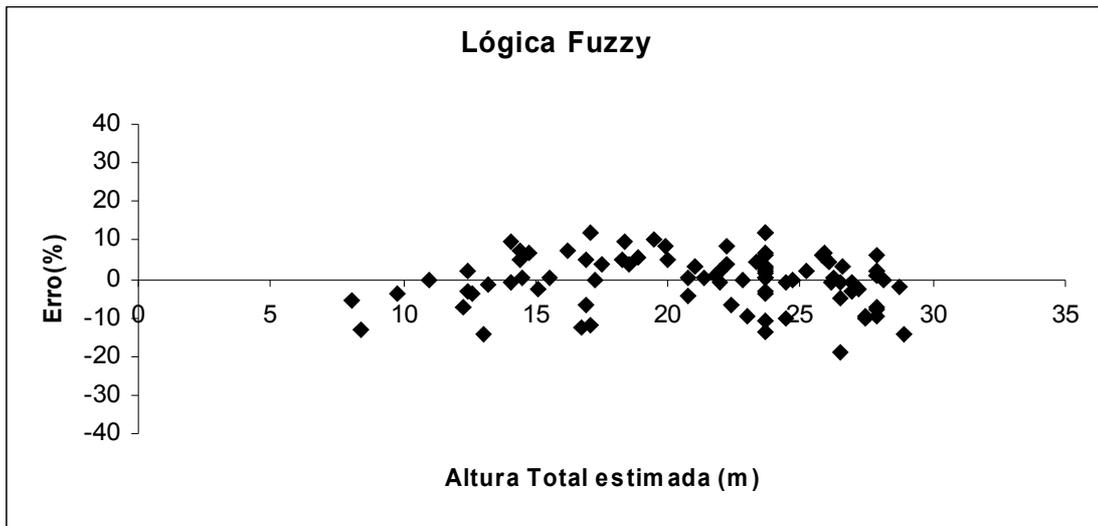


Figura 5.6: Distribuição Residual do modelo *fuzzy* com conjunto de treino

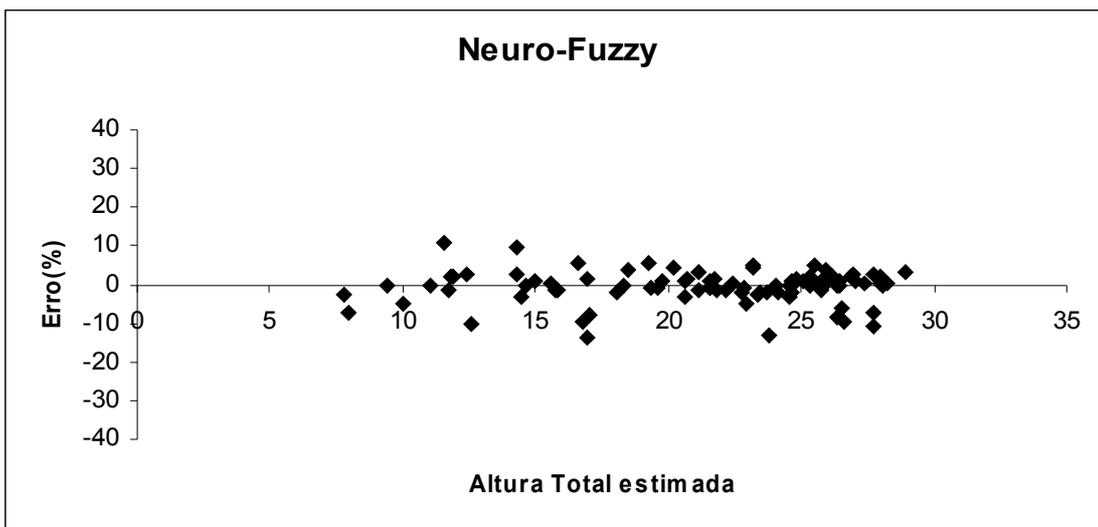


Figura 5.7: Distribuição Residual do modelo Neuro-*fuzzy* com conjunto de treino

Ao analisar as Figuras observa-se uma melhor distribuição residual referente ao modelo *Neuro-fuzzy* pois obteve uma variação menor, que ficou entre -13% a +10%. Os modelos *fuzzy*, Logístico e Parabólico também apresentaram distribuições semelhantes a do *Neuro-fuzzy*. Já os modelos de Curtis e Curtis com idade apresentaram a maior variação, entre -30% e +30%.

Os modelos de Curtis, Curtis com idade e Prodan apresentaram tendência em errar a estimativa para as árvores com alturas menores. Diferentemente dos outros modelos que não apresentaram tal tendência.

A Tabela 5.2 apresenta as estatísticas “bias” (B), média das diferenças absolutas (MD) e desvio padrão das diferenças (DPD) para estimativa da altura total.

Tabela 5.2: Estatística da Bias, média das diferenças absolutas (MD) e desvio padrão das diferenças (DPD) para estimativa a altura total

Modelos	Bias	MD	DPD
Curtis	0,108491	1,21048	1,51382
Curtis com idade	0,108013	1,214452	1,541301
Parabólico	-0,00018	1,043621	1,371634
Logístico	-0,003968	1,039649	1,374391
Prodan	0,013375	1,088737	1,413413
Lógica Fuzzy	0,085066	1,004396	1,34626
Neuro-Fuzzy	-0,093676	0,566755	0,835863

A Tabela 5.3 mostra as notas atribuídas para as estimativas da altura total, baseadas nas estatísticas da Tabela 5.2. Os valores positivos e negativos da estatística *Bias* indicam subestimativa e superestimativa, respectivamente. Os menores valores das três estatísticas testadas indicam que a equação apresenta maior precisão para o objetivo em pauta. Como exemplo, o modelo *Neuro-fuzzy*, para a altura, tem para a estatística média das diferenças absolutas (*MD*) o valor 0,566755 (Tabela 5.2). Quando este valor é comparado com o MD das equações associadas aos outros modelos, a nota atribuída a ele foi 1 (Tabela 5.3). Esse valor significa que, considerando o *MD*, o modelo *neuro-fuzzy* obteve a melhor estimativa em relação as outras equações avaliadas, seguida, pela ordem, pelos modelos lógica *fuzzy* (Nota 2), Logístico (Nota 3), Parabólico (Nota 4), Prodan (Nota 5) Curtis (Nota 6) e Curtis com idade (Nota 7).

Tabela 5.3: Notas atribuídas, a partir das estatísticas da Tabela 5.2, para as estimativas de altura total

Modelos	Bias	MD	DPD	Total
Curtis	7	6	6	19
Curtis com idade	6	7	7	20
Parabólico	1	4	3	8
Logístico	2	3	4	9
Prodan	3	5	5	13
Lógica Fuzzy	4	2	2	8
Neuro-Fuzzy	5	1	1	7

Seguindo o raciocínio apresentado e analisando os dados das Tabelas 5.2 e 5.3, verifica-se que os modelos Neuro-*fuzzy*, *fuzzy* e Parabólico apresentaram os melhores resultados para estimativa da altura total, seguidos dos modelos Logístico, Prodan, Curtis e Curtis com idade.

Estes resultados, de maneira geral, corroboram os anteriormente encontrados, ou seja, comprovam o que foi mostrado nos gráficos de resíduos (Figuras 5.1 a 5.7) e através do S_{yx} e do r da Tabela 5.1 que os modelos Neuro-*fuzzy* e *fuzzy* apresentaram maior precisão na predição da altura total dos eucaliptos utilizando o conjunto de treino.

5.2 Avaliação do conjunto de checagem

É na avaliação com o conjunto de checagem que os modelos mostram sua capacidade de generalização, ou seja, através de uma amostra conseguir estimar os valores de todo o inventário. Então nesta avaliação é feita a validação dos dados.

O conjunto de checagem contém como foi dito anteriormente 40 árvores-amostra, ou seja, aproximadamente 30,5% do total da base de dados. Nesta parte não há obtenção dos parâmetros (modelos tradicionais) e treino (Neuro-*fuzzy*), apenas tem-se o teste deste conjunto em cima do que já foi obtido no tópico anterior.

A Tabela 5.4 mostra as medidas de precisão r e S_{yx} (%) para o conjunto de checagem.

Tabela 5.4: Medidas de precisão para o conjunto de checagem

Modelos	r	Syx(%)
Curtis	0,966003	8,931018
Curtis com idade	0,963527	9,015184
Parabólico	0,974691	7,361681
Logístico	0,978041	7,095013
Prodan	0,973367	7,315504
Lógica Fuzzy	0,981727	6,141636
Neuro-Fuzzy	0,997969	1,860791

Através das medidas de precisão das equações testadas apresentadas na Tabela 5.4, observa-se que os modelos *Neuro-Fuzzy e Fuzzy* apresentam um melhor grau de ajuste, pois apresentaram valores de r superiores (mais próximos de 1) e de erro padrão relativo ($S_{Y.X}$ (%)) mais baixo, seguido dos modelos Logístico, Parabólico, Prodan, Curtis e por último Curtis com idade.

As Figuras 5.8 a 5.14 mostram a distribuição residual para os modelos testados com o conjunto de checagem para a predição da altura total.

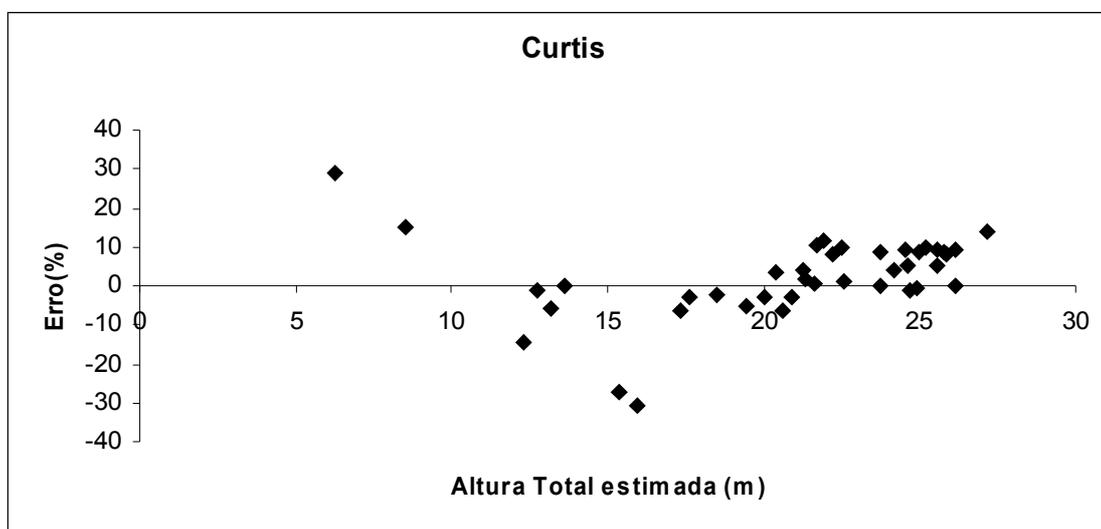


Figura 5.8: Distribuição residual da altura total para Curtis com o conjunto de checagem.

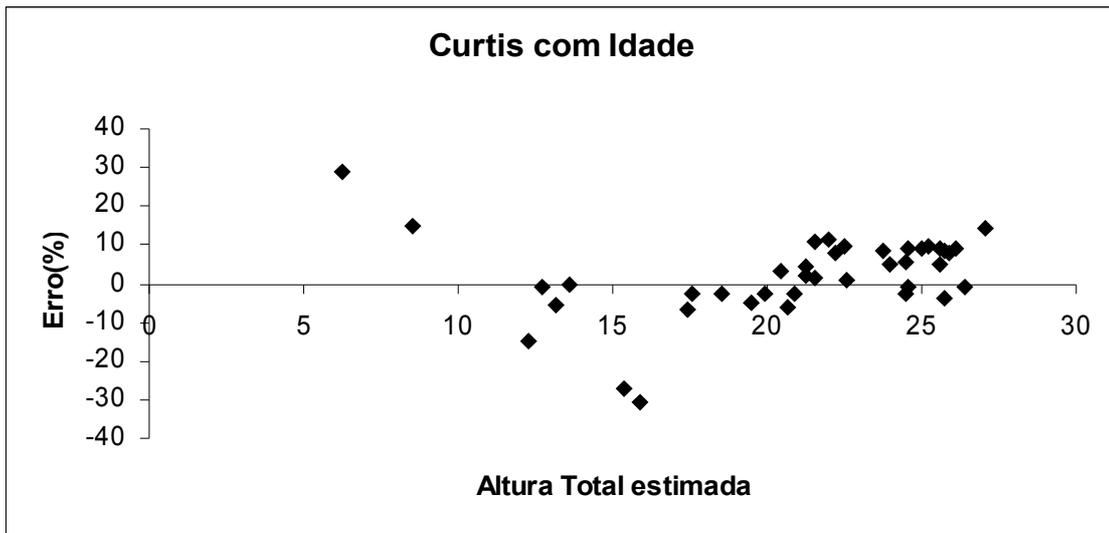


Figura 5.9: Distribuição residual da altura total para Curtis com idade com o conjunto de checagem.

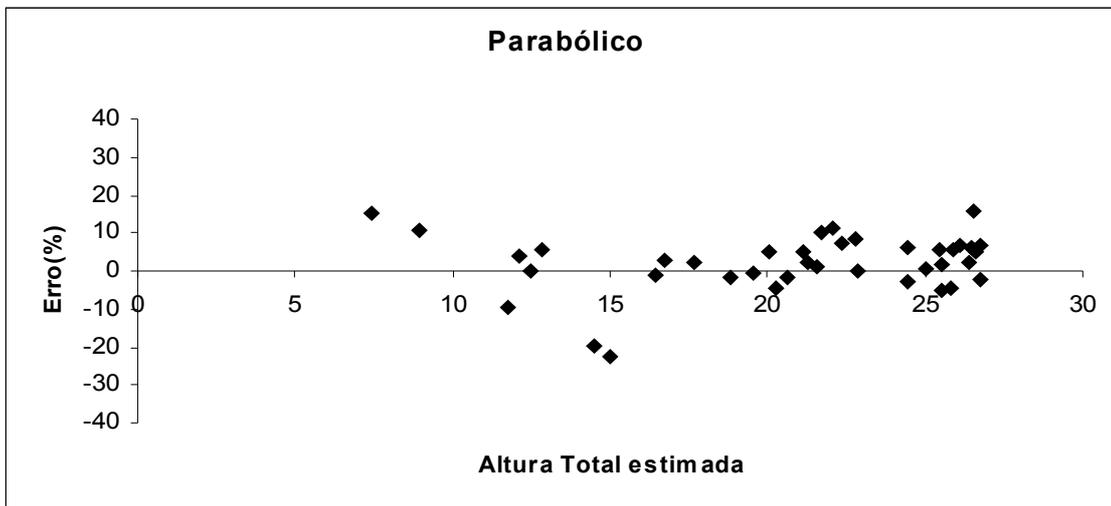


Figura 5.10: Distribuição residual da altura total para o modelo Parabólico com o conjunto de checagem.

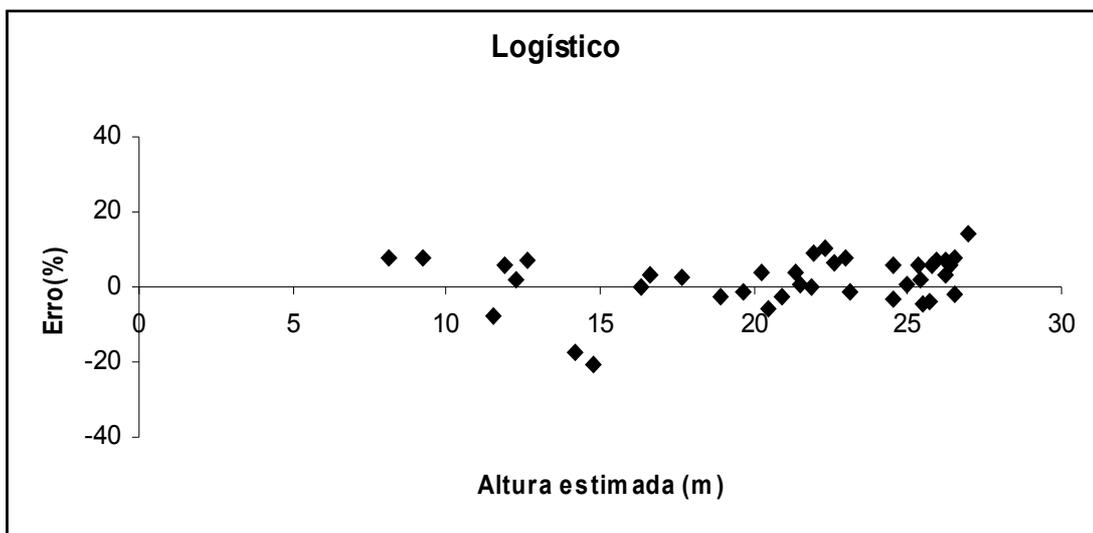


Figura 5.11: Distribuição residual da altura total para o modelo Logístico com conjunto de checagem

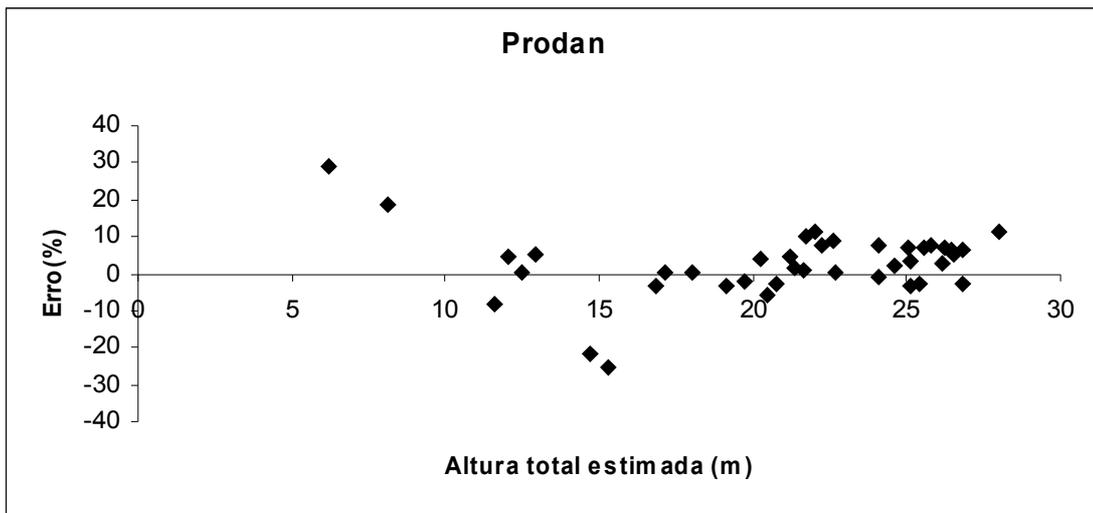


Figura 5.12: Distribuição residual da altura total para o modelo de Prodan com conjunto de checagem

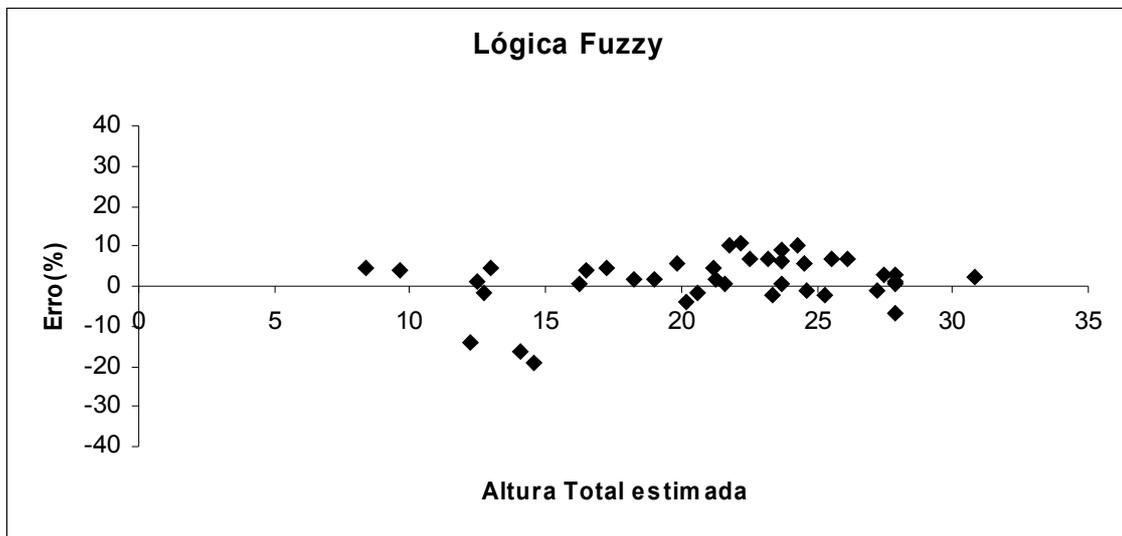


Figura 5.13: Distribuição residual da altura total para o modelo *fuzzy* com o conjunto de checagem.

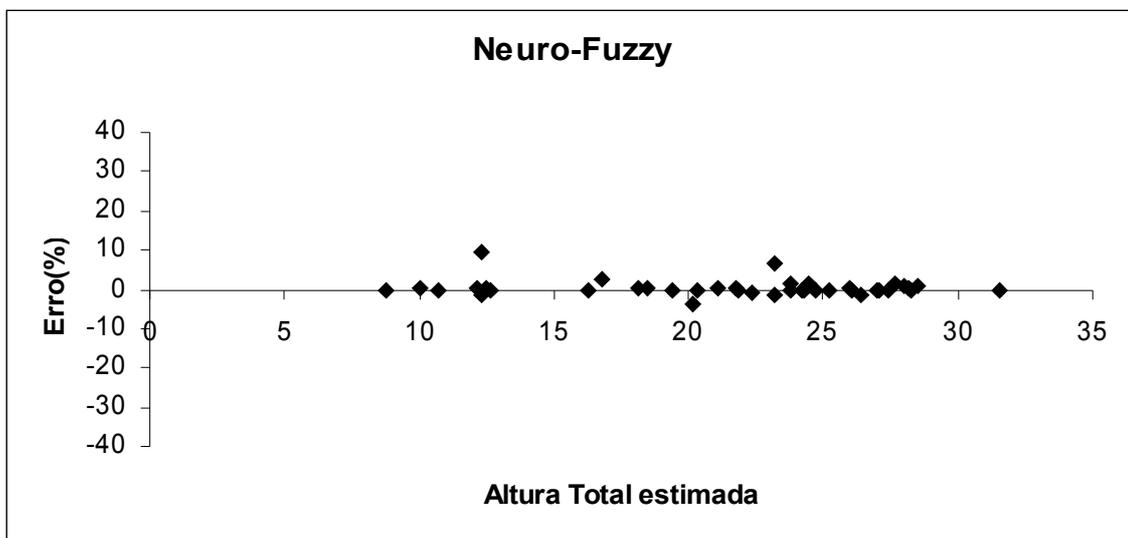


Figura 5.14: Distribuição residual da altura total para o modelo Neuro-*fuzzy* com o conjunto de checagem

Ao analisar as Figuras observa-se uma melhor distribuição residual referente ao modelo *Neuro-fuzzy* pois obteve uma variação menor, que ficou entre 0% a +10%. Os modelos *fuzzy*, Logístico e Parabólico apresentaram distribuições semelhantes. Já os modelos de Curtis e Curtis com idade apresentaram a maior variação, entre -30% e +30%, igual à alcançada com o conjunto de treino.

Como no conjunto de treino, os modelos de Curtis, Curtis com idade e Prodan apresentaram tendência em errar a estimativa para as árvores com alturas menores.

A Tabela 5.5 apresenta as estatísticas Bias (B), média das diferenças absolutas (MD) e desvio padrão das diferenças (DPD) para estimativa da altura total com o conjunto de checagem

Tabela 5.5: Estatística da Bias, média das diferenças absolutas (MD) e desvio padrão das diferenças (DPD) para a altura total com conjunto de checagem

Modelos	Bias	MD	DPD
Curtis	0,723793	1,486494	1,769552
Curtis com Idade	0,693856	1,535251	1,850958
Parabolico	0,611	1,19386	1,471821
Logístico	0,583762	1,161884	1,398505
Prodan	0,657192	1,270315	1,484707
Fuzzy	0,48225	1,01225	1,192444
Neuro Fuzzy	0,070022	0,179633	0,383371

A Tabela 5.6 mostra as notas atribuídas para as estimativas de altura total referentes ao conjunto de checagem, baseadas nas estatísticas da Tabela 5.5 mostrada acima.

Tabela 5.6: Notas atribuídas, a partir das estatísticas da Tabela 5.5, para as estimativas de altura total com o conjunto de checagem

Modelos	Bias	MD	DPD	Total
Curtis	7	6	6	19
Curtis com Idade	6	7	7	20
Parabolico	4	4	4	12
Logístico	3	3	3	9
Prodan	5	5	5	15
Fuzzy	2	2	2	6
Neuro Fuzzy	1	1	1	3

O modelo *Neuro-fuzzy* assim como no conjunto de treinamento obteve o melhor resultado com uma pontuação maior. Em seguida tem-se o modelo *fuzzy*, Logístico, Parabólico, Prodan, Curtis e Curtis com idade.

Estes resultados, de maneira geral, confirmam com os resultados anteriormente encontrados que os modelos *Neuro-fuzzy* e *fuzzy* obtiveram melhor desempenho que os outros modelos usados. Esta verificação pode ser obtida analisando os gráficos residuais (Figuras 5.8 a 5.14) e os valores de S_{yx} e r dados na tabela 5.4. Comparando os dados do conjunto de treinamento, percebe-se que os melhores modelos são também os melhores modelos para os dados de validação. Com isso percebe-se que os modelos propostos fornecem boas estimativas tanto para a base de dados utilizadas para o treinamento quanto para uma generalização para o restante dos dados.

6 CONCLUSÕES E PROPOSTAS FUTURAS

6.1 Conclusões

Após as avaliações tanto do conjunto de treino quanto o de checagem conclui-se que os sistemas baseados em inteligência artificial, que no caso são os modelos em lógica *fuzzy* e *neuro-fuzzy*, obtiveram melhores resultados que os modelos baseados em regressão. Vale ressaltar que o conjunto de treino foi usado para ajuste dos modelos matemáticos e para treinamento da rede neural. Já o de checagem foi utilizado para validar o resultado encontrado.

Estes modelos têm grande aplicação prática, já que tanto o modelo *Neuro-fuzzy* quanto o *fuzzy* mostraram-se melhores que os modelos utilizados no cotidiano das empresas que cultivam *Eucalyptus* pois apresentaram maior capacidade de generalização quando foi aplicado o teste com o conjunto de checagem.

6.2 Trabalhos Futuros

Como foi dito no tópico 6.1, os modelos baseados em inteligência artificial se mostram com grande aplicabilidade, então futuramente eles poderão ser usados em um ambiente real. Para isso deve ser desenvolvido um sistema com interface gráfica para facilitar ainda mais o trabalho.

Outro trabalho futuro seria por meio da estimativa da altura, conseguir também estimar o volume total com uma precisão grande. Isto também poderia estar sendo acoplado ao sistema citado acima.

BIBLIOGRAFIA

ALMEIDA, M. R. A. **Sistema híbrido *Neuro-fuzzy*-genético para mineração automática de dados**. Rio de Janeiro : PUC. Departamento de Engenharia Elétrica, 2004. 112 p.

ANDRADE, V. C. L.; MARTINS, S. V.; CALEGARIO, N; CHICHORRO, J. F. **Influência de três sistemas de amostragem na estimativa da relação hipsométrica e do volume de árvores em um fragmento de Mata Atlântica**, Scientia Florestalis - n. 70, p. 31-37, abril 2006

BARROS L.C. 1992. “Modelos determinísticos com parâmetros subjetivos”. Dissertação de Mestrado, Instituto de Matemática, Estatística e Ciência da Computação, Universidade de Campinas, Brasil.

CAMARGOS, F. L. **Lógica Nebulosa: uma abordagem filosófica e aplicada**, Santa Catarina, Brasil - Universidade Federal de Santa Catarina (UFSC), 2002.

CAMPOS, J. C. Ch. **Dendrometria, I parte**. Viçosa: Universidade Federal de Viçosa, Escola Superior de Florestas, 1983. 43p.

COSTA, J. C. **Aplicação da Lógica Fuzzy na Construção de um Modelo de Cadeia Ising**; Lavras, Brasil, 2006. 34 p.

COX, E. **The fuzzy systems: handbook a practitioner's guide to building, using, and maintaining fuzzy systems**. London: Academic Press, 1994. 625 p.

DOMINGOS, V. F., VALENÇA, M. J. S., LUDERMIR, T. B., SILVA, G. P. F. **Uma Proposta fuzzy na Avaliação de Desempenho de Bibliotecas Universitárias Brasileiras**. Pernambuco, Brasil. 2005.

DRIANKOV, D.; HELLENDORRN, H.; REINFRANK, M. **An introduction to Fuzzy control**. New York: Springer-Verlag, 1993. 316 p.

FINGER, C. A. G. **Fundamentos de Biometria Florestal**. Santa Maria. Universidade Federal de Santa Maria CEPEF – FATEC, 1992. 481p.

FINGER, C. A. G. **Ein Beitrag zur Ertragskunde von Eucalyptus grandis und Eucalyptus saligna in Sudbrasilien**. Wien: Universität für Bodenkultur, 1991. 137p. Tese Doutorado

FOREST BRAZIL – Viveiro Florestal..Disponível em:
<<http://www.forestbrazil.com.br/eucalipto.htm>>. Acesso em: 21 jun. 2007.

GOODMAN, R., HIGGINS, A. **Neuronal misconnections and psychiatric disorder. Is there a link?** Br J Psychiatry 1989;154:292-9.

HEILPERN S. 1993. “*fuzzy* subsets of the space of probability measures and expected value of *fuzzy* variable”. ***fuzzy Sets and Systems* 54**, 301-309.

HOEFLICH, V. A. **Planejamento estratégico para o desenvolvimento florestal brasileiro: 504 anos de espera, até quando?** . Paraná, Brasil. Embrapa, 1998.

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.

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.

KLIR, G. J.; YUAN, B. ***fuzzy sets and fuzzy logic*: theory and applications**. New Jersey: Prentice Hall, 1995. 574 p.

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.

T. Law, H. Itoh, H. Seki, "**Filtering Images for Edge Detection Using *fuzzy* Reasoning,**" **Proc. Third Int'l Conf. Automation, Robotics, and Computer Vision**, Singapura, 1994.

LEE, K. M., KWAK, D. H., KWANG, L. H. ***fuzzy* Inference Neural Network for *fuzzy* model tuning**, **IEEE Transactions Systems Man Cybernetics**, vol. 26, n° 4B

LENKE, A. P. **Solução Computacional Para um Sistema de Avaliação da Qualidade dos Serviços em Instituições de Ensino Superior, Baseado nos Parâmetros do PQSP**. Pelotas, Brasil. Universidade Federal de Pelotas, 2005.

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

LOETSCH, F., ZOEHRER, F., HALLER, K. E. **Forest Inventory**. München: BLV, 1973. v.2, 469p.

MAMDANI, E. H. 1974. Applications of *fuzzy* algorithms for control of a simple dynamic plant. **Proceedings IEEE**, 121, 12; 1585-1588.

MARSEGUERRA, M., ZIO, E. Model-free *fuzzy* tracking control of a nuclear reactor; **Annals of Nuclear Energy**; n.30; 2003; p.953–981

MEDRADO, M. **Embrapa**. O cultivo do Eucalipto em:
http://sistemasdeproducao.cnptia.embrapa.br/FontesHTML/Eucalipto/CultivodoEucalipto/01_Importancia_economica.htm. acessado em 29/01/2007.

MENDONÇA, A. R., SILVA, F. G., OLIVEIRA, S. T., NOGUEIRA, S. G., ASSIS, A. L. Avaliação de funções de afilamento visando a otimização de fustes de *Eucalyptus sp* para multiprodutos, **Cerne, Lavras, v. 13, n. 1, p. 71-82, jan./mar. 2007**

MOUZOURIS, G. C.; MENDEL, J. M. Dynamic Non-Singleton *fuzzy* Logic Systems for Nonlinear Modeling. **IEEE Transactions on *fuzzy* Systems**, New York, v. 5, n. 2, p. 199-208, May 1997.

OLIVEIRA, A. A. S. **Modelagem *Fuzzy* e *Neuro-Fuzzy* do Processo Monocíclico da Ferrugem Asiática da Soja**, Universidade Federal de Lavras, Lavras – Minas Gerais, 2007. 29p

OLIVEIRA, A. G. **Implementação de um Sistema de Tratamento e Reconhecimento de Padrões para uma Microbalança de Quartzo Utilizando Redes Neurais Artificiais**; Lavras – Minas Gerais, 2002

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

PEDRYCZ W. & GOMIDE F. 1998. **An Introduction to *fuzzy* Sets: Analysis and Design**. editora MIT Press, USA.

REZNIK L. ***fuzzy* Controllers**. Newnes, Reino Unido, 1997.

SCOLFORO, J. R. S. **Apostila de Dendrometria**. Lavras, DCF – ESAL, 1992. 320p.

SCOLFORO, J. R. S. **Mensuração Florestal 3**. Lavras, Brasil. 1993. 292p.

SUGENO M. 1974. “**Theory of *fuzzy* integrals and its applications**”. Tese de doutorado, Instituto de Tecnologia de Tokio, Tokio, Japão.

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

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

TIBIRIÇÁ, G. **Uma Abordagem Híbrida *fuzzy*-Bayesiana para Modelagem de Incertezas**. Florianópolis, Brasil. Universidade Federal de Santa Catarina, 2005.

THOMÉ, A. C. G. **Redes Neurais - uma Ferramenta para KDD E DATA MINING.** 2005

TONELLO, C. T.; COTTA, M. K.; ALVES, R. R.; CARMELITA, C. A. **O Destaque Econômico Do Setor Florestal Brasileiro.** Campinas, Brasil. UNICAMP, 2000.

WU C. & MA M. 1990. “*fuzzy norms, probabilistic norms and fuzzy metrics*”. *fuzzy Sets and Systems* **36**, 137-144.

YEN J. & LANGARI R. 1999. ***fuzzy Logic: Intelligence, Control, and Information.*** Prentice Hall, EUA.

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

ZADEH L.A. 1978. “*fuzzy sets as a basis for a theory of possibility*”. ***fuzzy Sets and Systems*** **1** (1); 3-28

ZADEH L. A. 1973. “Outline of a New Approach to the Analysis of Complex Systems and Decision Processes”. ***IEEE Transactions on systems, man and cybernetics*** **S1C-3** (1), 28-44.

ZANON, D. ; DEUS, A. M. ; PAULO, A. R. G. S. ; ALMEIDA, K. A. **A Comparative Analysis of Neural and Fuzzy Cluster Techniques Applied to the Characterization of Electric Load in Substations.** In: T&D IEEE Congress, 2004, São Paulo, 2004.