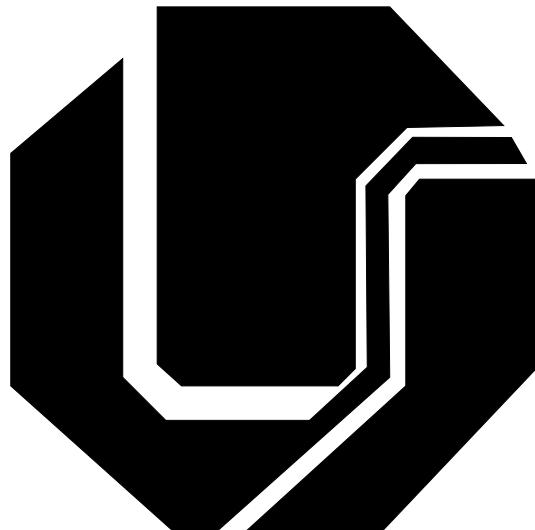


Universidade Federal de Uberlândia
Faculdade de Engenharia Elétrica
Pós-Graduação em Engenharia Elétrica



**PREDIÇÃO RECURSIVA DE DIÂMETROS DE CLONES DE
EUCALIPTO UTILIZANDO REDE PERCEPTRON DE
MÚLTIPLAS CAMADAS PARA O CÁLCULO DE VOLUME**

Fabrízzio Alphonsus Alves de Melo Nunes Soares

Uberlândia - MG, Brasil

13 de abril de 2012

Fabrízzio Alphonsus Alves de Melo Nunes Soares

PREDIÇÃO RECURSIVA DE DIÂMETROS DE CLONES DE EUCALIPTO UTILIZANDO REDE PERCEPTRON DE MÚLTIPLAS CAMADAS PARA O CÁLCULO DE VOLUME

Tese de Doutorado apresentada à Faculdade de Engenharia Elétrica da Universidade Federal de Uberlândia como parte dos requisitos para obtenção do título de Doutor em Engenharia Elétrica. Área de concentração: Processamento da Informação.

Orientador:
Edna Lúcia Flôres

UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE ENGENHARIA ELÉTRICA

Uberlândia - MG, Brasil

13 de abril de 2012

Dados Internacionais de Catalogação na Publicação (CIP)
Sistema de Bibliotecas da UFU, MG - Brasil

S676p Soares, Fabrizzio Alphonsus Alves de Melo Nunes, 1976-
2012 Predição recursiva de diâmetros de clones de eucalipto utilizando
rede Perceptron de múltiplas camadas para o cálculo de volume /
Fabrizzio Alphonsus Alves de Melo Nunes Soares. - 2011.

111 p. : il.

Orientadora: Edna Lúcia Flôres.

Tese (doutorado) – Universidade Federal de Uberlândia,
Programa de Pós-Graduação em Engenharia Elétrica.
Inclui bibliografia.

1. Engenharia elétrica - Teses. 2. Redes neurais (Computação) -
Teses. 3. Árvores - Inventários - Teses. I. Flôres, Edna Lúcia, 1958- II.
Universidade Federal de Uberlândia. Programa de Pós-Graduação em
Engenharia Elétrica. III. Título.

CDU: 621.3

Tese de doutorado sob o título “*PREDIÇÃO RECURSIVA DE DIÂMETROS DE CLONES DE EUCALIPTO UTILIZANDO REDE PERCEPTRON DE MÚLTIPLAS CAMADAS PARA O CÁLCULO DE VOLUME*”, defendida por Fabrizzio Alphonsus Alves de Melo Nunes Soares e aprovada em 13 de abril de 2012, em Uberlândia, estado de Minas Gerais, pela banca examinadora constituída pelos professores:

Prof. Dr. Alexandre Cardoso
Universidade Federal de Uberlândia
Coordenador do Programa de Pós-Graduação
em Engenharia Elétrica

Profª. Drª. Edna Lúcia Flores
Universidade Federal de Uberlândia
Orientadora

Prof. Dr. Antônio Cláudio Paschoarelli Veiga
Universidade Federal de Uberlândia

Prof. Dr. Gilberto Arantes Carrijo
Universidade Federal de Uberlândia

Prof. Dr. Cláudio Afonso Fleury
Pontifícia Universidade Católica de Goiás

Prof. Dr. Christian Dias Cabacinha
Universidade Federal de Minas Gerais

Dedicatória

Dedico este trabalho à memória da minha amada mãe.

Querida mãe,

a senhora assistiu a minha formatura da escola técnica,
a minha colação de grau na faculdade e o meu casamento.
Durante meu mestrado a senhora ficou doente. Eu pedi a Deus que a senhora ficasse ...
... Ele me atendeu e a senhora me viu virar mestre.
Durante meu doutorado, a senhora ficou doente. Eu pedi a Deus que a senhora ficasse ...
... Ele já tinha outros planos para a senhora.

Quando comecei a escrever esta tese, eu estava na sua casa. Nossa casa.
Eu estava na sala, no computador como sempre. A senhora estava no hospital.
Quando terminei de escrevê-la nem eu e nem a senhora estavamos mais lá.
Mamãe, esta tese é nossa.

Se eu virar doutor, saiba que isto nunca seria possível se não fosse pela senhora.
Eu só queria que estivesse aqui para assistir.

Mamãe,
tem tanta coisa que eu queria que você estivesse aqui para assistir ...
... minha defesa era apenas uma delas!
Tudo que sou devo a você.

Beijos e te amo.

Agradecimentos

Agradeço a Deus pela minha vida e todas as bênçãos que tenho recebido, à minha mãe por todo amor e carinho e tudo que só ela poderia me dedicar durante sua vida, ao meu pai pela dedicação e por ter me proporcionado tudo que precisei para chegar até aqui, à minha amada esposa Luciana que está sempre ao meu lado lutando e não me deixando desistir, sem seu apoio, sua paciência e seu carinho esta tese não seria possível, à minha orientadora, professora Edna, por acreditar em mim e me dar a oportunidade de ser seu aluno, ao grande amigo Christian Cabacinha por me ajudar a sair da escuridão que eu me encontrava na pesquisa, aos grandes amigos Henrique, Fábio e Marcos que tiveram paciência de me escutar contar inúmeras vezes sobre o que eu fazia na minha pesquisa e me darem tanta força, à toda minha família, e a tantos amigos que direta ou indiretamente contribuíram para a conclusão desta etapa.

“Há apenas duas maneiras de se ver a vida: Uma é pensar que não existem milagres e a outra é acreditar que tudo é um milagre.”

(Albert Einstein)

Resumo

O volume de madeira plantado é uma informação essencial no direcionamento racional e sustentável dos recursos disponíveis nas florestas. Assim, é muito importante quantificá-lo da forma mais precisa possível. A atividade da Engenharia Florestal que trata da quantificação de madeira nas florestas é o Inventário Florestal. Este inventário é a base para o planejamento do uso dos recursos florestais. Por meio dele é possível a caracterização de uma determinada área e o conhecimento quantitativo e qualitativo das espécies que a compõe. Inventários florestais são utilizados em vários tipos de levantamentos com a finalidade de reconhecimento, diagnóstico e avaliações no campo florestal. A avaliação de estoque de madeira em estudos de viabilidade, planejamento e preparação de talhões de exploração, bem como, diagnóstico pós-exploratórios, exigem inventários específicos. As redes neurais, especialmente as redes perceptron multcamadas com o algoritmo back-propagation vêm sendo utilizadas em diversas áreas devido à sua alta capacidade para tratar com relações não-lineares de entrada-saída, destacando-se a habilidade de aprendizado e a capacidade de generalização, associação e busca paralela. Essas redes têm sido aplicadas em diversas áreas como finanças, previsão de séries temporais, classificação de padrões, entre outras. As redes neurais têm sido utilizadas também em diversos trabalhos de modelagem florestal para estimar diversos parâmetros das árvores tais como diâmetro, altura, volume, e outros. Neste trabalho são realizadas análise e predição de diâmetros e cálculo de volumes de árvores do gênero *Eucalyptus*. O modelo desenvolvido utiliza apenas três medidas de diâmetros da base das árvores, e recursivamente, os diâmetros seguintes são preditos. Para o modelo proposto foram realizados experimentos para abordagens com a altura total e com o diâmetro mínimo comercial. O desempenho do modelo nos experimentos foi comparado e os resultados mostraram que o modelo proposto apresentou desempenho satisfatório em relação aos modelos tradicionais utilizados na Engenharia Florestal.

Palavras-chave: Redes neurais, Inventário florestal, Clones de eucaliptos, Perceptron multcamadas, Predição de diâmetros.

Abstract

The volume of timber planted is essential information in a rational and sustainable direction of resources available in the forests. Thus it is very important to quantify it as precisely as possible. The Forestry activity that deals with the quantification of wood in the forest is the Forest Inventory. This inventory is the basis for planning the use of forest resources. Through it is possible to characterize a given area and the qualitative and quantitative knowledge of the species that compose it. Forest inventories are used in various types of surveys for recognition, diagnosis and evaluations in the field of forests. The assessment of timber stock in feasibility studies, planning and preparation of plots of exploitation, as well as exploratory post-diagnosis, require specific inventories. Neural networks, especially multilayer perceptron networks with back-propagation algorithm have been used in several areas due to its high capacity to deal with nonlinear relationships of input-output, highlighting the learning ability and the ability to generalization, association and parallel search. These networks have been applied in various areas such as finance, time series forecasting, pattern classification, among others. Neural networks have also been used in several works modeling to estimate forest trees of various parameters such as diameter, height, volume, and others. In this work we performed the analysis and prediction of diameters and calculation of volumes of trees of genus *Eucalyptus*. The model uses only three diameters measure from the base of the tree, and recursively, the diameters are predicted. For the proposed model experiments were performed to approaches with the overall height and the minimum commercial diameter. The model performance was compared in the experiments and the results showed that the proposed model showed satisfactory performance in relation to the traditional models used in Forestry.

Keywords: Neural networks, Forest inventory, Eucalyptus clones, Multilayer perceptron, Diameter prediction.

Sumário

Agradecimentos	iv
Resumo	vi
Abstract	vii
Sumário	viii
Lista de Figuras	xii
Lista de Tabelas	xvii
Lista de abreviaturas e siglas	xviii
1 INTRODUÇÃO	1
1.1 Introdução	1
1.2 Motivação para a Utilização de Redes Neurais Artificiais de Forma Recursiva .	2
1.3 Objetivo Deste Trabalho	3
1.4 Estrutura Deste Trabalho	3
2 INVENTÁRIO FLORESTAL	5
2.1 Introdução	5

2.2	Dendrometria	6
2.3	A importância do Inventário Florestal	7
2.4	O Eucalipto	8
2.4.1	Considerações sobre a forma da árvore	10
2.4.2	Funções de forma de tronco	12
2.4.3	Cubagem rigorosa	14
2.5	Estimativa de Volumes	19
2.6	Considerações Finais Deste Capítulo	22
3	REDES NEURAIS ARTIFICIAIS	23
3.1	Introdução	23
3.2	Introdução Às Redes Neurais Artificiais	23
3.2.1	Um breve histórico da área de redes neurais	25
3.3	Rede Perceptron Multi-Camadas	27
3.4	Algoritmo de Retropropagação	28
3.5	Função de Ativação	33
3.6	Taxa de Aprendizagem	34
3.7	Inicialização dos Pesos	35
3.8	Aprendizagem Entrada-a-Entrada e Aprendizagem por Ciclo	35
3.8.1	Aprendizagem entrada-a-entrada	36
3.8.2	Aprendizagem por ciclo	36
3.9	Critério de Parada	37
3.10	Generalização	37
3.11	Validação Cruzada	38
3.12	Aproximação de Funções	39
3.13	Algoritmo de Levenberg-Marquardt	40
3.14	Rede de Funções de Base Radial	43

3.15	Considerações Finais Deste Capítulo	45
4	REDES NEURAIS NA ÁREA FLORESTAL	46
4.1	Introdução	46
4.2	Estimativa de Diâmetros, Alturas e Volumes de Árvores	47
4.3	Classificação das Áreas e Mapeamento	48
4.4	Crescimento de Floresta e Modelagem Dinâmica	49
4.5	Análise de Dados Espaciais e Modelagem de Sistemas de Informação Geográfica (GIS)	50
4.5.1	Processamento de imagens de satélite	50
4.5.2	Modelagem espacial com GIS	51
4.6	Dinâmica de Doenças de Plantas e Manejo de Insetos-Pragas	52
4.7	Pesquisa em Mudanças Climáticas	53
4.8	Outras Aplicações	55
4.9	Considerações Finais Deste Capítulo	55
5	MODELO DE ESTIMATIVA DE DIÂMETROS COM REDES NEURAIS	56
5.1	Introdução	56
5.2	Predição de Diâmetros	56
5.3	O Modelo Proposto	59
5.4	Materiais e Métodos	60
5.4.1	Localização e caracterização da área de coleta dos dados	60
5.4.2	Dados	60
5.4.3	Arquitetura perceptron de múltiplas camadas	62
5.4.4	Treinamento da rede MLP	63
5.4.5	Predição recursiva de diâmetros com a utilização da altura total	65
5.4.6	Predição recursiva de diâmetros sem a utilização da altura total	65
5.5	Método de Avaliação de Desempenho do Modelo	67

5.5.1	Estimativa dos diâmetros com a rede neural de funções de base radial	67
5.5.2	Cálculo dos erros dos diâmetros preditos com a MLP e a RBF	68
5.5.3	Cálculos dos volumes das árvores a partir dos diâmetros estimados e utilizando as equações volumétricas	69
5.5.4	Cálculo dos erros de estimativa de volume	70
5.5.5	Análise de variância (ANOVA)	71
5.6	Considerações Finais Deste Capítulo	72
6	RESULTADOS OBTIDOS	73
6.1	Introdução	73
6.2	Experimentos Realizados Com o Método 1	73
6.2.1	Predição de diâmetros	74
6.2.2	Comparação entre os volumes das árvores calculados utilizando os diâmetros reais e os preditos pela MLP e RBF e os volumes estimados usando o método de Schumacher e Hall (log)	77
6.3	Experimentos Realizados Com o Método 2	80
6.3.1	Predição de diâmetros das árvores	80
6.3.2	Comparação entre os volumes das árvores calculados utilizando-se diâmetros reais e preditos pela MLP e pela RBF	84
6.4	Conclusões	86
7	CONCLUSÕES E CONTRIBUIÇÕES DESTE TRABALHO, TRABALHOS FUTUROS E AS PUBLICAÇÕES ORIGINADAS NESTA TESE	88
7.1	Introdução	88
7.2	Conclusões e Contribuições	88
7.3	Trabalhos Futuros	91
7.4	Publicações Originadas Deste Trabalho	91
Referências Bibliográficas		93

Lista de Figuras

2.1	Exemplo do método de cubagem rigorosa em uma árvore.	15
2.2	Protótipos dendrométricos mais comuns.	17
(a)	Cilindro	17
(b)	Cone	17
(c)	Parabolóide	17
(d)	Neilóide	17
2.3	Exemplo de uma seção de uma árvore e suas dimensões	18
3.1	Anatomia de um neurônio biológico. Fonte: (CANTO, 2004)	24
3.2	Transmissão do impulso nervoso por meio de uma sinapse química. Fonte: (CANTO, 2004).	24
3.3	Exemplo de arquitetura perceptron multi-camadas.	27
3.4	Modelo do neurônio artificial	30
3.5	Funções de ativação mais comuns	34
(a)	Linear	34
(b)	Limiar	34
(c)	Logística	34
(d)	Tangente Hiperbólica	34
5.1	Mapa do estado do Espírito Santo mostrando a localização da empresa Aracruz Celulose S.A. Fonte: (CABACINHA, 2003).	60

5.2	As alturas medidas e seus respectivos diâmetros.	61
5.3	Arquitetura da MLP de três camadas.	63
6.1	Exemplos de curvas preditas com a MLP (melhor e pior caso)	75
(a)	Classe 2 - Melhor	75
(b)	Classe 3 - Melhor	75
(c)	Classe 4 - Melhor	75
(d)	Classe 2 - Pior	75
(e)	Classe 3 - Pior	75
(f)	Classe 4 - Pior	75
6.2	Exemplos de curvas preditas com a RBF (melhor e pior caso)	75
(a)	Classe 2 - Melhor	75
(b)	Classe 3 - Melhor	75
(c)	Classe 4 - Melhor	75
(d)	Classe 2 - Pior	75
(e)	Classe 3 - Pior	75
(f)	Classe 4 - Pior	75
6.3	Histograma de $RMSE\%$ entre os diâmetros real e estimado com a MLP.	76
(a)	Classe 2	76
(b)	Classe 3	76
(c)	Classe 4	76
6.4	Histograma de $RMSE\%$ entre os diâmetros real e estimado com a RBF.	76
(a)	Classe 2	76
(b)	Classe 3	76
(c)	Classe 4	76
6.5	Gráfico de dispersão dos volumes estimados.	79
(a)	MLP	79

(b)	RBF	79
(c)	Schumacher e Hall (log)	79
6.6	Exemplos de curvas preditas com a MLP (melhor e pior caso)	82
(a)	Classe 2 - Melhor	82
(b)	Classe 3 - Melhor	82
(c)	Classe 4 - Melhor	82
(d)	Classe 2 - Pior	82
(e)	Classe 3 - Pior	82
(f)	Classe 4 - Pior	82
6.7	Exemplos de curvas preditas com a RBF (melhor e pior caso)	82
(a)	Classe 2 - Melhor	82
(b)	Classe 3 - Melhor	82
(c)	Classe 4 - Melhor	82
(d)	Classe 2 - Pior	82
(e)	Classe 3 - Pior	82
(f)	Classe 4 - Pior	82
6.8	Histograma de $RMSE\%$ entre os diâmetros real e estimado com a MLP	83
(a)	Classe 2	83
(b)	Classe 3	83
(c)	Classe 4	83
6.9	Histograma de $RMSE\%$ entre os diâmetros real e estimado com a RBF	83
(a)	Classe 2	83
(b)	Classe 3	83
(c)	Classe 4	83
6.10	Gráfico de dispersão dos volumes estimados	86
(a)	MLP	86

Lista de Tabelas

2.1	Modelos volumétricos de simples entrada.	20
2.2	Modelos volumétricos de dupla entrada.	20
5.1	Estatísticas descritivas das árvores do gênero <i>Eucalyptus</i>	61
5.2	Recursos computacionais utilizados neste trabalho.	62
5.3	Quantitativo de árvores e amostras para treino e estatísticas dos treinamentos da MLP por classe.	64
5.4	Algoritmo 1 de predição de diâmetros de árvore.	65
5.5	Definição formal do algoritmo de predição do modelo 1.	66
5.6	Algoritmo 2 de predição de diâmetros de árvore.	67
5.7	Definição formal do algoritmo de predição do modelo 2.	68
5.8	Quantitativo de árvores, de amostras para treino e estatísticas dos treinamentos da RBF por classe.	68
6.1	Erros de predição de diâmetros por classe - $RMSE\%$ (menor, maior, médio e desvio padrão) e correlação - R (menor e maior).	74
6.2	Volumes (m^3) calculados utilizando-se os diâmetros reais, preditos pela MLP, pela RBF e pelo método de Schumacher e Hall (log).	78
6.3	Comparação entre os volumes das árvores reais e os estimados.	78
(a)	MLP	78
(b)	RBF	78
(c)	Schumacher e Hall (log)	78

6.4	Erros de predição de diâmetros por classe - $RMSE\%$ (menor, maior, médio e desvio padrão) e correlação - R (menor e maior)	80
6.5	Diferenças entre as alturas reais e estimadas do diâmetro mínimo (4 cm)	84
6.6	Volumes comerciais (m^3) calculados utilizando-se os diâmetros reais, preditos pela MLP e pela RBF	84
6.7	Comparação entre os volumes das árvores reais e os estimados.	85
(a)	MLP	85
(b)	RBF	85

Listas de abreviaturas e siglas

BERA ensaio bioelétrico.

DAP Diâmetro na Altura do Peito.

GIS Sistemas de Informação Geográfica.

IA Inteligência Artificial.

LAI Índice de Área Foliar.

LMS Least Mean Square.

MLP Perceptron Multi-Camadas.

MSE Erro Médio Quadrático.

PRS Power Ring Espectral.

RBF Função de Base Radial.

RNA Redes Neurais Artificiais.

SAR Radar de Abertura Sintética.

INTRODUÇÃO

“No meio da dificuldade vive a oportunidade.”

Albert Einstein

1.1 Introdução

A extensa cobertura de florestas plantadas existentes no Brasil e a enorme cadeia produtiva desde o cultivo até a geração de produtos mostra a grande importância da atividade florestal nesse país. A consequência disso é o aumento da capacidade de geração de empregos e renda nesse setor. No ano de 2008, as estatísticas realizadas pela Sociedade Brasileira de Silvicultura (SBS) indicaram que o Produto Interno Bruto Florestal Brasileiro atingiu cerca US\$ 44,6 bilhões (ABRAF, 2009). Isto gerou cerca de 2 milhões de empregos diretos e indiretos. A cobertura florestal do território brasileiro, associada às excelentes condições edafoclimáticas (solo clima) para a silvicultura mostraram grande vantagem da atividade florestal no Brasil (JUVENAL; MATTOS, 2002).

Aproximadamente 74,8%, ou seja, em torno de 4,8 milhões de hectares das florestas plantadas no Brasil são do gênero *Eucalyptus*. O grande investimento de indústrias de papel e celulose, aliados aos esforços de instituições de pesquisas e universidades tornaram esse país um dos maiores produtores de madeira de eucalipto do mundo (ABRAF, 2012).

O eucalipto é uma espécie florestal de rápido crescimento, menor custo e produz muito mais madeira do que outras espécies. A produtividade média de madeira no Brasil é de $45 - 50\ m^3\ ha^{-1}\ ano^{-1}$. No Chile, Estados Unidos, Canadá e Finlândia, esse número é de 20, 10, 7 e

$4\ m^3\ ha^{-1}\ ano^{-1}$, respectivamente (Votorantim Celulose e Papel - VCP, 2004).

O volume de madeira plantada é uma informação essencial no direcionamento racional e sustentável dos recursos disponíveis nas florestas plantadas. Assim, é muito importante quantificá-lo da forma mais precisa possível. O método mais simples de estimativa e quantificação de madeira é a cubagem rigorosa. Alguns dos métodos de obtenção do volume das árvores pela cubagem rigorosa são as fórmulas de Smalian, Huber e de Newton. Estes métodos foram aplicados no setor florestal desde o fim do século XVIII (FINGER, 1992; MACHADO; FIGUEIREDO FILHO, 2003; SCOLFORO, 2005).

O principal inconveniente da cubagem rigorosa é a necessidade imediata de comercialização das árvores cubadas, pois para a sua realização é frequentemente necessário o abate das árvores. Outros métodos foram sendo desenvolvidos ao longo dos anos com a finalidade de reduzir os custos e diminuir a necessidade de abate das árvores. Como a cubagem de árvores em pé e o método da altura relativa, um dos métodos mais tradicional utilizado nas empresas brasileiras são as equações volumétricas para estimar o volume das árvores. Estas equações são ajustadas com amostras de cubagem rigorosa durante a realização do inventário florestal.

Nas equações volumétricas são feitas suposições geométricas sobre as árvores. Essas suposições necessitam de diversas medidas de diâmetros ao longo do fuste (tronco) para a construção dos modelos que representam o estrato (sub-área) do povoamento. No entanto, durante a cubagem, as árvores amostradas são abatidas. Como esse processo é repetido várias vezes até completar todos os estratos da população, essa atividade torna-se bastante demorada e onerosa. Com isto, muitas vezes as empresas florestais negligenciam a cubagem prejudicando as previsões realizadas com as equações volumétricas (ANDRADE; CALEGARIO; SCOLFORO, 2006).

Este capítulo apresenta a descrição geral do problema, sua motivação e os objetivos deste trabalho. Finalmente, são realizadas as considerações finais deste capítulo.

1.2 Motivação para a Utilização de Redes Neurais Artificiais de Forma Recursiva

Diversas pesquisas foram realizadas aplicando-se redes neurais na estimativa de diâmetros e volume de árvores. Porém, nesses trabalhos foram feitas suposições a respeito da forma das árvores, ou seja, se o tronco é cônico, cilíndrico, dentre outros. Como os eucaliptos possuem uma variedade muito grande de forma, tais suposições não puderam ser confirmadas.

Neste trabalho, ao invés de fazer alguma suposição sobre a forma do tronco dos eucaliptos adotou-se a abordagem recursiva de modo a deixar o modelo estimar a forma real de cada árvore. A motivação de utilizar essa abordagem inspirou-se na forte autocorrelação entre os diâmetros de cada árvore observada nos estudos realizados neste trabalho.

1.3 Objetivo Deste Trabalho

Os principais objetivos deste trabalho são simplificar a atividade de inventário florestal em campo e evitar a necessidade de se adequar um ou mais protótipos dendrométricos durante as estimativas. Assim, a base do modelo proposto é a estimativa dos diâmetros das árvores utilizando uma rede neural Perceptron de Múltiplas Camadas a partir de apenas três medidas na base da árvore. Estas medidas são os diâmetros a 0,3, 0,7 e 1,3 metros do solo. Elas são muito fáceis de serem obtidas sem equipamentos especiais ou escadas o que torna o inventário não só mais fácil, mas também rápido e consequentemente mais barato. Por excluir a cubagem rigorosa convencional, o modelo proposto baseou-se na recursividade para a estimativa dos diâmetros, isto dispensa a necessidade de se estimar os protótipos dendrométricos já que ao invés de tentar descobri-los, o modelo recursivo permite que sejam estimados.

Os dados utilizados neste estudo foram levantados em um plantio localizado no município de Aracruz na região metropolitana do estado do Espírito Santo, no Brasil. Foram usados dados de um sítio florestal com 615 árvores, de um híbrido do gênero *Eucalyptus*, obtidas de um mesmo material genético clonal.

Os modelos são analisados para árvores de diversas características de afilamento. O desempenho dos modelos foi avaliado fazendo-se comparações com as abordagens tradicionais, como a cubagem rigorosa. Além disso, foram realizados também cálculos de volume das árvores para avaliar o impacto em um inventário final. Neste caso, são utilizadas algumas medidas de erros para a comparação do desempenho do modelo, tais como, a raiz do erro quadrático médio, o erro médio, o viés (bias) e a correlação linear.

1.4 Estrutura Deste Trabalho

Este trabalho foi estruturado da seguinte forma:

Neste capítulo são apresentados a introdução, a descrição geral do problema, a sua motivação e o objetivo deste trabalho.

O capítulo 2 descreve a atividade do inventário florestal e a dendrometria. Nesse capítulo são apresentados os aspectos a respeito do eucalipto, as considerações sobre sua forma, a cubagem rigorosa e a estimativa do volume.

O capítulo 3 apresenta um breve tutorial sobre as redes neurais. É apresentado um breve histórico, as principais arquiteturas, os algoritmos de treinamento, bem como uma descrição mais detalhada do algoritmo de treinamento adotado neste trabalho.

O capítulo 4 apresenta uma revisão sobre a utilização das redes neurais na área florestal e ambiental. São apresentados os trabalhos desenvolvidos para a estimativa de diâmetros, alturas e volume de árvores, bem como, as aplicações em áreas correlatas.

O capítulo 5 apresenta o modelo proposto neste trabalho, a forma de treinamento e os métodos de avaliação do desempenho do modelo. É apresentado também o processo de cálculo do volume e a equação volumétrica utilizada para comparação.

O capítulo 6 apresenta os resultados dos experimentos realizados e a comparação entre outros modelos tradicionais da engenharia florestal.

O capítulo 7 apresenta as conclusões e as contribuições e publicações originadas deste trabalho e os trabalhos futuros que poderão ser realizados a partir desta tese.

Capítulo **2**

INVENTÁRIO FLORESTAL

“O impossível existe até quando alguém duvide dele e prove o contrário.”

Albert Einstein

2.1 Introdução

Informalmente, o inventário é um instrumento de “contagem de árvores” existente em uma determinada área. O objetivo central do inventário florestal é determinar o volume de madeira em um povoamento. Com a evolução tecnológica e a crescente necessidade de melhorar a qualidade das informações a serem incorporadas aos projetos de manejo florestal, os inventários florestais diversificaram as suas estratégias de coletas de dados que já não se limitam a simples quantificação de volume de madeira total ou por espécie de determinada área (COUTO; BASTOS; LACERDA, 1993). Os inventários florestais reúnem técnicas de coleta de dados dos recursos florestais de determinada área, visando fornecer informações qualitativas e quantitativas, ou seja, o que tem e quanto tem, e outros aspectos.

O inventário florestal é a base para o planejamento do uso dos recursos florestais. Por meio dele é possível a caracterização de uma determinada área e o conhecimento quantitativo e qualitativo das espécies que a compõe.

Este capítulo apresenta uma visão geral sobre a atividade do inventário florestal, dendrometria, além de mostrar algumas das abordagens tradicionais de medição de diâmetros e estimativa de volume.

2.2 Dendrometria

A dendrometria (do grego δένδρο (dendro), árvore; e μέτρο (metro), medida) literalmente medida da árvore, é um ramo das Ciências Florestais que se encarrega da determinação ou da estimativa dos recursos florestais, quer seja da própria árvore ou do próprio povoamento, com a finalidade de predizer com precisão o volume, o incremento ou a produção de um determinado recurso florestal. Outros sinônimos conhecidos para a dendrometria são silvimensuração, silvimetria, dasometria, medição florestal e mensuração florestal. Segundo Campos (1993), a dendrometria é o ramo da ciência florestal que se ocupa da medição da árvore, tanto do ponto de vista individual quanto do coletivo.

A dendrometria é ainda o ramo da ciência florestal que trata de medidas e/ou estimativas de árvores e florestas, de seus produtos e de suas dinâmicas de crescimento. Assim, o objetivo da dendrometria é fornecer informações parcial ou total sobre uma floresta, mediante medidas ou métodos estimativos, que possibilite o conhecimento das potencialidades produtivas e protetivas, visando definir as prioridades e estabelecer metas de condução e manejo florestal (SILVA; NETO, 1979).

Os três principais objetivos da aplicação da dendrometria são:

Comercial visa estimar com precisão o que é retirado das florestas na compra e na venda do material.

Ordenação florestal (manejo) na exploração do produto florestal, deve-se ter em mente o rendimento sustentado, onde o que é retirado equivale ao que cresce na mesma área. Para atingir esse objetivo deve-se elaborar planos de ordenamento florestal a longo prazo, e para isso é preciso conhecer o desenvolvimento da floresta, por espécies e locais.

Pesquisa para determinar ou estimar com precisão o desenvolvimento de uma floresta, é preciso usar técnicas especiais, técnicas essas que avançam a medida que se desenvolvem novos métodos, novos conhecimentos, novos instrumentos, tabelas, técnicas de amostragens, etc. Mas para que isso aconteça é necessário realizar pesquisas no campo da dendrometria, pois, como qualquer outra ciência a pesquisa deve anteceder a prática.

As principais variáveis das árvores utilizadas nos levantamentos florestais são a altura total e os diâmetros medidos no tronco em diversas alturas em relação ao solo. Na realização de um inventário florestal para o levantamento desses dados podem ocorrer diversos erros. O erro de 1 metro na medição da altura total (H_t) da árvore corresponde a aproximadamente 14%

do volume cilíndrico das árvores. Enquanto o erro de 1 cm no diâmetro a 1,30 m do solo (*DAP*) corresponde a um erro de aproximadamente 19% do volume total da árvore. No Brasil, o diâmetro na altura do peito adotado é o diâmetro a 1,30 metros do solo (COUTO; BASTOS, 1988).

Defeitos nos instrumentos de medição e falhas dos profissionais que os operam podem ocasionar erros na medição da altura total e dos diâmetros. A medição dos diâmetros é realizada diretamente na árvore utilizando a sutá¹ ou similar. Devido às dimensões das árvores, as medições da altura total são realizadas indiretamente com a árvore em pé. Nas medições indiretas são utilizados instrumentos para visualizar a base e o topo das árvores e por princípios geométricos ou trigonométricos são calculadas essas alturas.

Para que o operador possa medir a altura total da árvore é necessário que o topo e a base estejam visíveis. Porém, a densidade do povoamento, a inclinação do solo ou da árvore e os movimentos dos ventos podem prejudicar essa visualização e aumentar o tempo dos inventários florestais.

As medições dos diâmetros nas árvores podem ser realizadas com a árvore em pé quando essas medidas estão próximas ao *DAP*. Medidas acima do *DAP* poderão exigir o uso de escadas ou andaiques quando as alturas ainda forem acessíveis ou instrumentos tais como Pentaprisma de Wheel e o Relascópio de bitterlich. Porém, para alturas muito grandes exigirá equipamentos especiais para a escalada além de muita perícia do operador.

2.3 A importância do Inventário Florestal

Inventários florestais são utilizados em vários tipos de levantamentos com a finalidade de reconhecimento, diagnóstico e avaliações no campo florestal. A avaliação de estoque de madeira em estudos de viabilidade, planejamento e preparação de talhões de exploração, bem como, diagnóstico pós-exploratórios, exigem inventários específicos.

Os inventários florestais são instrumentos básicos utilizados para avaliar estatisticamente as reais potencialidades e as capacidades produtivas dos recursos florestais de determinada área.

Os inventários florestais são importantes ferramentas utilizadas no diagnóstico do potencial produtivo ou protetivo das florestas. É por meio dos resultados dos inventários florestais que se apoiam as decisões importantes a respeito da viabilidade de empreendimentos florestais, que

¹ Suta é um instrumento utilizado para medir diâmetros de árvores semelhante a um paquímetro, porém maior. Ele é feito de uma alça fixa presa a uma barra e outra móvel, na qual abre a alça móvel e fecha encaixando-a na árvore para medir seu diâmetro (IMAÑA-ENCINAS et al., 2009).

exigem investimentos de alguns milhões de dólares.

Os objetivos do inventário são estabelecidos de acordo com a utilização da área, que pode ser área de recreação, reserva florestal, área de manutenção da vida silvestre, áreas de reflorestamento comercial, entre outros. (CAGNANI; RODRIGUES; CARVALHAIS, 2009)

No caso das florestas com fins madeireiros por exemplo, o inventário florestal visa principalmente a determinação ou a estimativa de variáveis como biomassa, área basal, volume, qualidade do fuste, estado fitossanitário, classe de copa e potencial de crescimento da espécie florestal.

Nos levantamentos florestais é prática usual selecionar uma ou mais amostras que consiste em pequenas frações da população que se deseja obter a informação. O verdadeiro valor de uma característica ou variável é denominado parâmetro e só existe na natureza (HOSOKAWA; SOUZA, 1987). Entretanto, por meio da observação de um certo número de unidades amostrais pode-se estimar sua estatística correspondente.

Quaisquer estimativas dos parâmetros estão sujeitas a erros de amostragem, oriundos de procedimentos de seleção e operação das unidades amostrais. Em florestas tropicais, por exemplo, onde existe alta heterogeneidade de espécies e tipos florestais, os critérios de seleção das amostras é decisivo em termos de consistência e precisão dos resultados. Na maioria das situações, é necessário estratificar os ambientes de trabalho, por categoria tipológica, ecossistema predominante e topografia (BONETES, 2003).

Os inventários florestais devem ser executados periodicamente para permitir ao proprietário ou ao gerente florestal a planificação das atividades em função das mudanças ocorridas em determinados períodos de tempo considerado. Avaliar o crescimento, as mudanças ocorridas após a exploração florestal, planejar a produção e os tratamentos silviculturais visando o equilíbrio e a recuperação das florestas, exigem trabalhos de campo com inventários florestais (SEBEM, 2000).

2.4 O Eucalipto

O Eucalipto (do grego, ευ, verdadeira; e καλύπτω, cobertura) é a designação popular das várias espécies vegetais do gênero *Eucalyptus*. Este nome é usado também para outros gêneros da família *Myrtaceae*, nomeadamente dos gêneros *Corymbia* e *Angophora* (SOARES et al., 2010).

Originário da Austrália, o gênero *Eucalyptus*, pertencente à família *Myrtaceae*. Esse gênero

teve seu plantio intensificado no Brasil no início do século XX. Ele foi implantado no Brasil em 1909 pelo engenheiro agrônomo Edmundo Navarro de Andrade, então funcionário da Companhia Paulista de Estradas de Ferro (CPEF) (FREITAG, 2007). O *Eucalyptus* foi usado durante algum tempo como dormentes nas ferrovias, lenha para as marias-fumaça e mais tarde como poste para a edificação de linhas de transmissão. Ao final dos anos 20, começou a ser aproveitado como carvão vegetal, passando a ser utilizado nas siderúrgicas mineiras na fabricação de ferro-gusa.

O eucalipto é atualmente a espécie florestal mais plantada no mundo, com mais de 17,8 milhões de hectares. Dentre os países com maiores áreas reflorestadas, destaca-se a Índia com 8 milhões de hectares, seguida pelo Brasil com cerca de 4,8 milhões de hectares plantados (ABRAF, 2012). A eucaliptocultura no Brasil é intensiva com elevada produtividade média da ordem de 45 – 60 $m^3/ha/ano$ (MORA; GARCIA, 2000), e está baseada principalmente em florestas clonais (ALFENAS et al., 2009).

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

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

Em 2009, o Brasil alcançou 6,78 milhões de hectares de florestas plantadas com espécies de eucalipto (66,58%), pinus (26,46%) e outras espécies (6,96%). (ABRAF, 2010)

Devido ao clima tropical ou subtropical na maioria do território brasileiro, tem-se utilizado muito o gênero *Eucalyptus* em larga escala nas florestas industriais. Devido ao clima, o território brasileiro propicia um crescimento ininterrupto, e consequentemente, um rápido acúmulo de biomassa. Para exemplificar o quanto é propício o clima do território brasileiro, a idade de rotação de plantios de eucaliptos no Brasil está entre 5 e 7 anos, enquanto que em países de clima temperado este tempo de rotação salta para aproximadamente 12 anos (JÚNIOR; AHRENS, 2003).

Além disso, o Brasil ocupa uma posição de liderança mundial em silvicultura e melhoramento de *Eucalyptus* devido à atividade agroindustrial e o apoio de instituições governamentais de pesquisa e Universidades. Estima-se que o setor florestal no Brasil seja responsável pela existência de 500 mil empregos diretos e outros 2 milhões indiretos. Desse total, somente o

segmento de celulose e papel responde por 150 mil empregos diretos. Em termos tributários, o setor também fornece uma demonstração de força, pois a estimativa é de uma arrecadação anual de US\$ 4,6 bilhões em impostos (BALEIRO, 2007).

O eucalipto é aplicado em diversas áreas como: óleos essenciais, produtos apícolas, celulose, madeira serrada, postes e moirões, laminados, MDF, HDF, chapa de fibra, compensados, carvão, lenha, além de muitas outras aplicações (SOARES, 2010).

Atualmente, a principal prática silvicultural do eucalipto é do tipo clonal. A “silvicultura clonal” compreende todo o processo de formação de uma floresta clonal, incluindo a seleção da árvore superior, a multiplicação vegetativa, a avaliação das árvores selecionadas em teste clonal, a produção de mudas e o estabelecimento da floresta clonal (XAVIER, 2002). O clone é definido como uma população de células ou indivíduos originados por divisão assexuada a partir de uma célula ou indivíduo (RAVEN; EVERET; EICHHORN, 2007). A propagação vegetativa, assexuada, não consiste de recombinação genética, o que viabiliza a cópia fiel do genótipo de um indivíduo vegetal. As plantações de espécies originadas de propagação vegetativa não possuem variabilidade genética, constituindo assim as populações mais homogêneas do que as formadas por sementes, mas tornam-se mais vulneráveis aos fatores edáficos².

2.4.1 Considerações sobre a forma da árvore

Desde o século passado, a forma do tronco de espécies florestais vem sendo estudada, o que é demonstrado pelo grande número de publicações encontradas na literatura técnico-científica. O fuste das árvores apresenta formas bastante variáveis, modificando-se de acordo com a espécie e até mesmo dentro da mesma espécie, espaçamento, idade, sítio florestal, posição sociológica e outros.

A forma varia de indivíduo para indivíduo, conforme as condições edafoclimáticas, os tratamentos silviculturais e a posição sociológica em que cada árvore se desenvolve. A forma também varia ao longo da idade, quer como um fenômeno evolutivo natural ou como resultado das várias fases de concorrência relativas às árvores vizinhas (GOMES, 1957; LARSON, 1963; FINGER; ZANON; SCHNEIDER, 1995).

De maneira restrita, a forma do fuste pode ser associada ao termo “afilamento”, que representa a redução do diâmetro com o aumento da altura, tendência natural que ocorre na maioria das espécies e que, como tal, pode ser expressa como uma função matemática que descreve a tendência dessa variação. O afilamento do tronco ou “taper” tem sido definido como o decrés-

²Que resulta de fatores inerentes ao solo ou é por eles influenciado.

cimo em diâmetro a partir da base do fuste para a sua extremidade superior (ápice) (MACHADO et al., 2004).

O tronco de uma árvore é semelhante a determinados sólidos geométricos. A base da árvore é semelhante a um neilóide, a face intermediária a um parabolóide e a extremidade final a um cone (GOMES, 1957; CAMPOS, 1988; SCOLFORO; FIGUEIREDO FILHO, 1993; AVERY; BURKHART, 1997)

Segundo (BORGES, 1981), do ponto de vista dendrométrico, a forma do fuste de árvores, genericamente, é a sua configuração externa que, a rigor, não se identifica com a forma de um sólido geométrico específico, mas sim com várias formas, segundo a posição considerada no tronco.

Os troncos de coníferas, raras vezes são cones, parabolóides ou neilóides padrões, normalmente eles assumem formas intermediárias entre o cone e o parabolóide (HUSCH; MILLER; BEERS, 1982). As partes comercializáveis de folhosas assumem formas que variam de cone até um parabolóide, dependendo do ritmo de crescimento e das condições locais. Os fustes das folhosas apresentam formas cilíndricas (MANASSÉS; PEICHL, 1986; HUSCH; MILLER; BEERS, 1982).

Segundo (GOMES, 1957) se fosse possível determinar o início e o fim de cada figura geométrica ao longo do tronco, bastaria aplicar fórmulas correspondentes aos vários sólidos geométricos ocorrentes ao longo do perfil do tronco e o volume real da árvore seria obtido. Porém, este processo é praticamente impossível, o que levou ao desenvolvimento de metodologias (fórmulas) para fazer a cubagem rigorosa.

(SCHNEIDER, 1993) coloca que, independentemente das irregularidades das secções transversais dos troncos, as árvores possuem determinado tipo de forma de tronco que varia com a espécie e em função de vários fatores, como o sítio, a densidade do povoamento, a intensidade do vento que age sobre a copa das árvores e as intervenções silviculturais aplicadas aos povoamentos, como os desbastes e a desrama.

(SILVA, 1974; FINGER, 1992) observaram que a forma do tronco das árvores é bastante variada. Isto, segundo esses autores, acontece em razão do meio ambiente, da espécie, da idade, do manejo a que são submetidos e também de suas aptidões genéticas. Os modelos dendrométricos visam analisar a cubagem das árvores por meio de recursos matemáticos, comparando os sólidos geométricos de revolução às formas naturais das árvores, com o objetivo de determinar seu volume. Esses sólidos são chamados de “protótipos dendrométricos” ou “sólidos padrões”, que são comparáveis à forma do tronco ou as partes deste.

(FINGER, 1992) acrescentou que o estudo matemático dos volumes das árvores considera suas secções circulares, embora tenha-se conhecimento de que elas não são perfeitamente circulares.

(SILVA, 1974) mostrou que as árvores dominantes desenvolviam na base maior incremento relativo que o necessário, com a finalidade de poderem suportar o peso do tronco. Com isso, ele concluiu que, de maneira geral, as árvores não apresentam uma forma homogênea, característica da espécie, mas assumem diversas formas geométricas em função das variáveis genéticas, ambientais e silviculturais. A partir desse conhecimento, várias pesquisas foram desenvolvidas para definir a forma do tronco das árvores procurando demonstrar como se obter os diâmetros e os respectivos volumes a partir das alturas relativas (CAMPOS; ZUCONI; RIBEIRO, 1982).

2.4.2 Funções de forma de tronco

Para proporcionar o uso múltiplo do tronco de uma árvore em povoamentos florestais é necessário o conhecimento da forma do tronco, do volume e da dimensão dos seus sortimentos, possibilitando assim, o planejamento e o estudo da viabilidade econômica do povoamento. A forma das árvores possui uma variação muito grande dentro da floresta. Esta variação ocorre devido à diminuição do diâmetro em direção ao topo da árvore, que é conhecida como “taper” ou afilamento, afetando diretamente o volume e variando com a espécie, a idade, o espaçamento entre as árvores e as condições do sítio (PEREIRA et al., 2009).

Nos últimos anos, observa-se, na literatura, um crescente aumento no interesse em estimar o volume comercial até as alturas ou diâmetros definidos na parte superior do tronco, com a finalidade de saber qual a porção do tronco que poderá ser utilizada em produtos específicos.

A função da forma do tronco permite conhecer o diâmetro a uma determinada altura ou comprimento da tora, bem como o comprimento em que se encontra um determinado diâmetro, permitindo direcionar a tora segundo sua mais rentável utilização (MCTAGUE; BATISTA; STEINER, 1989). A utilização de equações de forma de tronco possibilita descrever o perfil do tronco e, por integração, obter a estimativa do volume total e parcial em diferentes seccionamentos com grande precisão, permitindo também a confecção das tabelas de sortimentos.

A função da forma do tronco é uma descrição matemática do perfil longitudinal de um tronco, sua função é desenvolvida com o propósito de permitir estimativas de forma e volume de uma árvore, ela é baseada somente no seu diâmetro à altura do peito - *DAP* ($d_{1,30}$) e na altura total (H_t) (PIRES; CALEGARIO, 2007). Embora seja complexa a definição de uma função da forma, os benefícios de um sistema analítico compatível para a forma e o volume

são evidentes, correspondendo à quantificação das estimativas do volume de matéria-prima, produtos e resíduos, antes do desbaste das árvores.

O uso das funções da forma do tronco assume importância significativa nos estudos sobre a quantificação do volume da madeira quando são estabelecidos padrões de dimensão para a utilização do material lenhoso. Funções matemáticas da forma são também úteis na descrição analítica dos efeitos de diferentes espaçamentos e intensidades da poda e do desbaste sobre a forma dos troncos (AHRENS, 2009).

(KOZAK; MUNRO; SMITH, 1969) propuseram uma simples função parabólica para estimar a forma de tronco, com a vantagem de sua forma poder ser ajustada pelo método dos mínimos quadrados. De acordo com (AHRENS, 1982; FIGUEIREDO FILHO; OLIVEIRA; MOURA, 1993), a utilização das funções da forma do tronco, no Brasil, pode ser datada a partir dos anos setenta.

Vários autores, dentre os quais (AHRENS, 1982; SCHNEIDER, 1993), citam que as funções da forma do tronco atuam como ferramenta para predizer o diâmetro em qualquer ponto do tronco a partir de uma ou duas variáveis medidas. Estas funções passaram a ser utilizadas também para estimar o volume do povoamento e construir tabelas de volume e sortimento para diferentes limites de dimensões de toras impostos pelo mercado.

No mesmo sentido, (LEITE; GUIMARÃES, 1992; GARCIA; LEITE; YARED, 1993) citam que os modelos matemáticos para descrever o perfil dos troncos de árvores passaram a ser ferramentas importantes na obtenção de estimativas mais realísticas do volume das partes do tronco. Dentre os principais modelos empregados, incluem-se:

- a. Modelos polinomiais: são aqueles modelos baseados principalmente na comparação entre a variável dependente $(d_i/dap)^2$ ou $(d_i/d_{0,1})^2$ e os polinômios formados pela variável independente (h_i/h) ;
- b. Modelos sigmoidais: utilizam as transformações de variáveis, de modo que o modelo é semelhante à forma natural dos troncos. Tratam-se de expressões matemáticas que geram um perfil semelhante a uma curva sigmóide;
- c. Modelos segmentados: consistem no uso de submodelos justapostos, cada um representando uma porção do tronco. A união dos submodelos é por meio da imposição de restrições ao modelo geral (funções *spline*, nas quais predominam a *spline* cúbica e a *spline* quadrática); e
- d. Modelos definidos por análise multivariada: baseiam-se na aplicação de análise mul-

tivariada, análise de componentes principais, para investigar as variações existentes na estrutura dos dados e definir o modelo de regressão a ser utilizado para descrever o perfil do tronco.

Como procedimento alternativo, Max e Burkhart (1976) utilizaram a regressão para modelar a forma do tronco. Esse método separou o tronco em três partes que foram representadas por três submodelos que, acrescidos de duas constantes (“join points”), produziram uma função da forma polinomial global e segmentada.

A técnica de modelagem empregada para a descrição do perfil dos troncos vem sendo utilizada com êxito. Um modelo pode ser definido como compatível ou não, quando a estimativa do volume total, obtida por integração dos segmentos do tronco, é semelhante àquela da equação do volume, que a equação de forma foi derivada (MUNRO; DEMAERSCHALK, 1974).

De acordo com Borges (1981), Köehler (1982), Silva (1982), Friedl (1989), Moura (1994), Finger, Zanon e Schneider (1995), FIGUEIREDO FILHO, Borders e Hitch (1996), Schneider et al. (1996), alguns modelos de funções da forma foram e são utilizados para expressar a forma do tronco de espécies florestais. Esses modelos possuem como variáveis: o diâmetro à altura do peito, diâmetros a partir das alturas relativas e a altura total.

2.4.3 Cubagem rigorosa

Segundo Gomes (1957), a cubagem rigorosa é a medição de sucessivos diâmetros ao longo do tronco da árvore. Esse mesmo autor comenta que, as medições diamétricas eram realizadas a 0,30; 1,30; 3,30; 5,30 e assim sucessivamente de 2 em 2 metros. Porém, as distâncias entre essas medições podem ser alteradas em função da forma e da rigorosidade do processo de cubagem. Scolforo e FIGUEIREDO FILHO (1993) recomendam as seguintes distâncias de medições para *Eucalyptus* e *Pinus*: 0,05; 0,07; 1,30; 2,30 com comprimentos das seções entre 1 e 2 metros. Segundo esses autores, esse comprimento deve ser tal, que seja controlado ao máximo o efeito da conicidade e que as seções sejam regulares. Para as árvores nativas, (SCOLFORO; MELLO; LIMA, 1994) estabeleceram as seguintes distâncias de medições dos diâmetros: 0,30; 0,70; 1,30; 2,00; 3,00 e assim sucessivamente de metro em metro até a altura desejada para a cubagem.

A Figura 2.1 mostra o método de cubagem rigorosa em uma árvore, onde d_1, d_2, \dots, d_n indicam os diâmetros medidos e h_1, h_2, \dots, h_n indicam as alturas onde os respectivos diâmetros são medido.

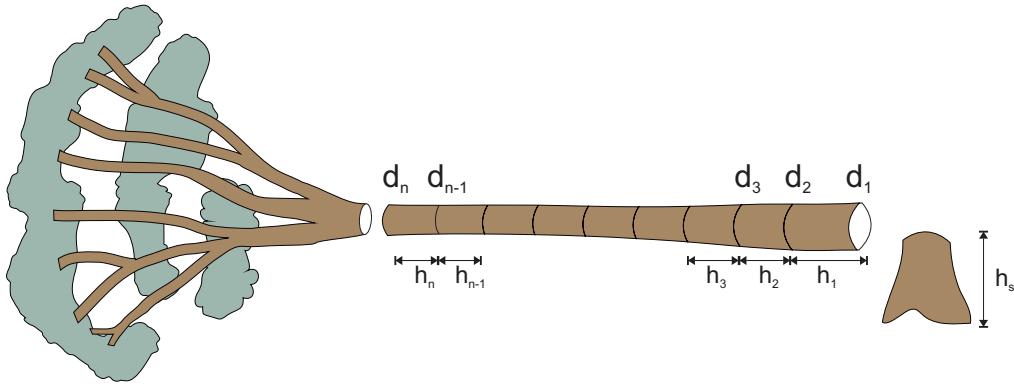


Figura 2.1: Exemplo do método de cubagem rigorosa em uma árvore.

Os métodos de cubagem rigorosa são divididos em métodos absolutos e relativos (MACHADO et al., 2006). Os métodos absolutos são aqueles em que o comprimento da seção (tora) não tem vínculo com o comprimento total da árvore. Nos métodos relativos, o comprimento da seção ou da tora representa um percentual do comprimento total da árvore, permitindo a comparação dos volumes individuais das árvores de tamanho diferente, porém com a mesma forma.

A cubagem rigorosa deve ser realizada por classe de diâmetro e de altura. Nestas condições e dentro dos tratamentos silviculturais semelhantes, espera-se que os indivíduos tenham forma semelhante e constante. Assim, existe uma constância nos volumes de todos os indivíduos pertencentes a mesma classe de altura e de diâmetro (GOMES, 1957).

Segundo Gomes (1957) os processos de cubagem de Huber e Newton, conduzem a valores diferentes. Esse autor concluiu que a diferença entre as médias dos volumes calculados com as fórmulas de Huber e Smalian, relativos a um mesmo grupo de troncos, não diferem significativamente. Portanto, o uso de um ou de outro método, é somente devido ao hábito do mensurador.

Segundo Gomes (1957), a cubagem rigorosa de árvores de pinheiro bravo pelos métodos gráfico, de Smalian e de Huber e as médias de volume não diferem estatisticamente.

Segundo Manassés e Peichl (1986), Husch, Miller e Beers (1982), o volume calculado pela fórmula de Huber, que mede apenas um diâmetro no centro da tora, é exato, quando a forma do tronco aproximar-se de um cilindro. Contudo, se a forma do tronco é cônica ou tende a um neilóide, os erros no cálculo do volume podem ser consideráveis.

Segundo Campos (1988), a fórmula de Newton utilizada para a cubagem rigorosa, destaca-se pela precisão proporcionada na determinação volumétrica, uma vez que ela exige um maior número de medições de diâmetros em uma determinada seção do tronco. Esse mesmo autor

menciona que, independentemente da fórmula utilizada para o cálculo do volume, quanto menor é o comprimento da seção e maior precisão é obtida na determinação volumétrica.

Machado e Nadolny (1991) compararam para *Pinus elliotti* os métodos de cubagem absolutos de Smalian, Huber e Newton para os comprimentos de 1, 2, 4 e 6 metros, para árvores situadas nas classes de diâmetro que esses autores denominaram inferior, média e superior. Esses mesmos autores utilizaram o volume obtido no xilômetro³ como base de comparação e concluíram que, as fórmulas de Huber e Newton foram as que apresentaram melhor desempenho, com uma tendência a menores erros na porção intermediária do fuste. Nas seções do cone (ponta) os erros foram altos, entretanto esses erros não foram considerados significativos, pois são peças de pequeno volume e pouco representativas no volume total. Quando consideradas às seções da base, as fórmulas não foram satisfatórias. Na maioria dos casos, a fórmula de Huber apresentou melhor desempenho do que as de Newton e Smalian. e esta última pior que as demais.

(MACHADO; NADOLNY, 1993) quando compararam também em *Pinus elliotti*, os métodos de cubagem relativos da FAO, Hohenadl e o método gráfico, usando como base de comparação o xilômetro, concluíram que o método da FAO para 5 e 10 seções apresentou um desempenho ligeiramente superior à fórmula de Hohenadl e como já era esperado os volumes obtidos pelo método gráfico tiveram um desvio pequeno em relação aos volumes obtidos no xilômetro para as classes de diâmetro inferior e média. Porém, sem uma explicação lógica, apresentou um desvio relativamente alto para a classe de diâmetro superior.

Um fato importante, segundo (SCOLFORO; FIGUEIREDO FILHO, 1993), é que a forma da árvore varia com a espécie, o espaçamento, a idade, o sítio e os tratamentos silviculturais. Como no Brasil, o ritmo de crescimento das florestas plantadas e o manejo aplicado aos plantios de *Pinus* e *Eucalyptus*, é completamente diferente ao aplicado nas coníferas e folhosas do hemisfério norte, é imprescindível avaliar se os métodos que são adequados naquelas regiões, também o são, para as condições do Brasil e qual o nível de compatibilidade desses em plantios nesse país.

Entre os métodos de cubagem, os absolutos são os mais utilizados nas empresas florestais. O método de Smalian é o que apresenta maior preferência devido a sua praticidade, porém esses métodos geralmente implicam no abate das árvores.

Os troncos de muitas espécies de árvores apresentam formas semelhantes a algum sólido geométrico definido - os protótipos dendrométricos. Entre esses, os mais conhecidos são: o ci-

³O xilômetro é um recipiente com água, no qual as toras de madeira são mergulhadas. O volume das toras corresponde ao volume de água deslocado, medido com uma régua graduada (SOARES; NETO; SOUZA, 2006).

lindro, o cone, o parabolóide e o neilóide. A Figura 2.2 apresenta os protótipos dendrométricos mais comuns. Entretanto, na prática, observa-se que os troncos nunca se identificam com um único protótipo dendrométrico, pois em um mesmo tronco podem ocorrer várias formas, além disso, a transição de uma forma para outra não pode ser exatamente determinada no tronco (LOETSCH; ZOHRER; HALLER, 1973).

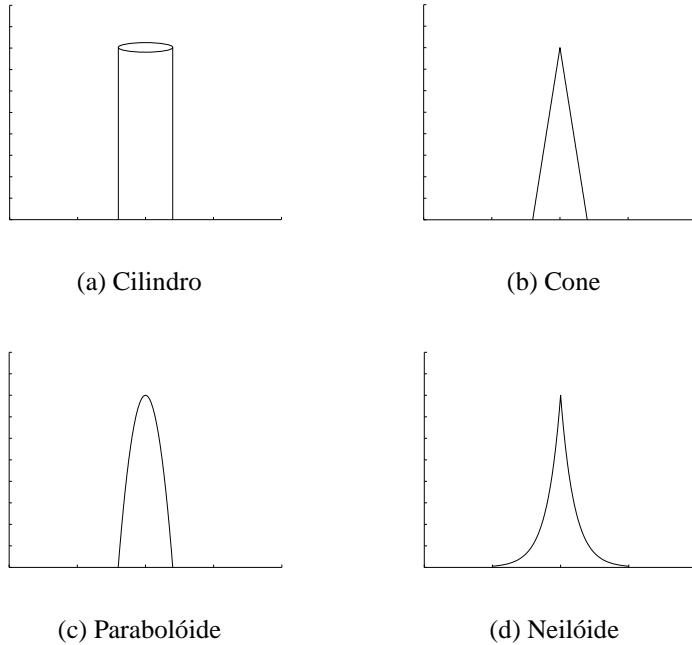


Figura 2.2: Protótipos dendrométricos mais comuns.

Para contornar esse problema, o tronco da árvore é dividido em seções (toras) e são aplicadas as fórmulas aproximadas para obter o volume de cada seção. O volume do tronco da árvore, consequentemente, é obtido pelo somatório dos volumes das seções (CAMPOS, 1993).

O volume de uma seção do tronco, então, pode ser obtido pelas equações de Huber (Equação (2.1)), Smalian (Equação 2.2)) ou Newton (Equação 2.3)).

$$v_i = g_m \cdot L \quad (2.1)$$

$$v_i = \left(\frac{g_i + g_s}{2} \right) \cdot L \quad (2.2)$$

$$v_i = \left(\frac{g_i + 4g_m + g_s}{6} \right) \cdot L \quad (2.3)$$

onde:

g_i - área seccional da seção i ;

g_s - área seccional da seção $i + 1$;

g_m - área da metade do comprimento da seção;

L - comprimento da seção; e

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

Após o cálculo do volume das seções, realiza-se o somatório das seções e obtém-se o volume total da árvore, como mostrado na Equação (2.4).

$$v = \left(\sum_{i=1}^{n-1} \frac{g_i + g_{i+1}}{2} l_i \right) + \frac{g_n l_n}{3} \quad (2.4)$$

$$g_i = \frac{(d_i/2)^2 \pi}{10.000} \quad (2.5)$$

onde:

v - volume total da árvore, g_i é a área basal da i -ésima posição;

l_i - comprimento da seção na i -ésima posição;

g_n - área basal do cone (ponta da árvore);

l_n - comprimento do cone; e

d_i - diâmetro da i -ésima posição.

Na Equação (2.5) a área de cada g_i é dividida por 10.000 para converter de cm^2 para m^2 .

A Figura 2.3 mostra um exemplo de uma seção de uma árvore e suas dimensões.

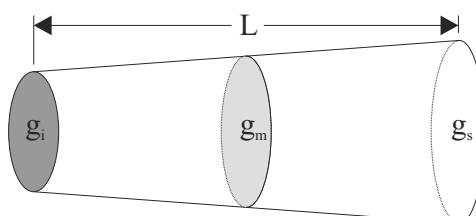


Figura 2.3: Exemplo de uma seção de uma árvore e suas dimensões

2.5 Estimativa de Volumes

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

A forma mais precisa de determinar o volume é pelo método do deslocamento de água seguindo o Princípio de Arquimedes, ou seja, as toras são colocadas em tanques cheios de água e, a partir do deslocamento da água, obtém-se o volume delas. Porém, essa forma de obtenção do volume é de difícil aplicação em inventários florestais devido ao tempo gasto na obtenção tornando uma prática inviável economicamente e tecnicamente. Outras metodologias de obtenção de volume de madeira é a prática de cubagem rigorosa e estimativa de volume por meio de equações de regressão (MACHADO et al., 2006).

As estimativas de volume podem ser realizadas a partir de várias metodologias. A equação de volume para árvores individuais é a mais utilizada. Pode-se também obter o volume dos fustes por meio dos fatores de forma, do método dos dois diâmetros, ou de uma relação hipsométrica associada a uma equação de volume. Essas metodologias propiciam estimativas precisas e com menores custos quando comparada com as equações que tem como variáveis independentes o diâmetro e a altura. Para volumes por unidade de área a equação do povoamento é uma boa opção. Para estimar os múltiplos produtos ou os sortimentos⁴, deve-se utilizar as funções de afilamento, as razões entre os volumes ou as funções splines (FRANCO, 1995).

Quando deseja-se obter estimativas mais precisas do estoque florestal, pode-se usar modelos matemáticos que estimam o volume para as árvores individuais e gerar tabelas de volume ou modelos que estimam o volume por unidade de área.

(SCOLFORO, 1997) divide as equações volumétricas em três grupos:

Equações de simples entrada o volume é estimado em função do DAP. Esse diâmetro deve estar fortemente correlacionado com a altura, ou seja, o diâmetro explica bem o desenvolvimento da altura;

Equações de dupla entrada o volume é estimado em função do DAP e da altura total. Neste caso o DAP não está fortemente correlacionado com a altura, ou seja, o diâmetro não explica bem o desenvolvimento da altura. São recomendáveis quando existe uma maior

⁴Procedimento adotado para definir o uso das toras obtidas na colheita florestal, geralmente baseado no comprimento da tora e no diâmetro mínimo de utilização estabelecido para cada tipo de uso (BATISTA, 1998).

heterogeneidade na relação altura-diâmetro; e

Equações de tripla entrada o volume é estimado em função do DAP, da altura total e de uma medida que expressa a forma da árvore. Este tipo de modelo não é recomendável, pois a forma da árvore é uma variável difícil de ser quantificada, e quando é realizada a cubagem rigorosa, esta já é controlada.

As tabelas 2.1 e 2.2 apresentam alguns dos modelos volumétricos de simples entrada e dupla entrada, respectivamente:

Tabela 2.1: Modelos volumétricos de simples entrada.

Autor	Modelo
Kopezky-Gehrhardt	$V = \beta_0 + \beta_1 DAP^2 + \varepsilon$
Dissescu-Meyer	$V = \beta_1 DAP + \beta_2 DAP^2 + \varepsilon$
Hohenadl-Krenm	$V = \beta_0 + \beta_1 DAP + \beta_2 DAP^2 + \varepsilon$
Berkhout	$V = \beta_0 DAP^{\beta_1} + \varepsilon$
Husch	$\ln V = \beta_0 + \beta_1 \ln DAP + \varepsilon$
Brenac	$\ln V = \beta_0 + \beta_1 \ln DAP + \beta_2 + \frac{1}{DAP} + \varepsilon$

Tabela 2.2: Modelos volumétricos de dupla entrada.

Autor	Modelo
Spurr	$V = \beta_0 + \beta_1 DAP^2 H_t + \varepsilon$
Spurr (log)	$\ln V = \beta_0 + \beta_1 \ln(DAP^2 H_t) + \varepsilon$
Schumacher-Hall	$V = \beta_0 DAP^{\beta_1} H_t^{\beta_2} + \varepsilon$
Schumacher-Hall (log)	$\ln V = \beta_0 + \beta_1 \ln DAP + \beta_2 \ln H_t + \varepsilon$
Honner	$V = \frac{DAP^2}{\beta_0 + \beta_1 H_t} + \varepsilon$
Ogaya	$V = DAP^2(\beta_0 + \beta_1 H_t)$
Stoate	$V = \beta_0 + \beta_1 DAP^2 + \beta_2 DAP^2 H_t + \beta_3 H_t + \varepsilon$
Naslund	$V = \beta_1 DAP^2 + \beta_2 DAP^2 H_t + \beta_3 DAPH_t^2 + \beta_4 H_t^2 + \varepsilon$
Takata	$V = \frac{DAP^2 H_t}{\beta_0 + \beta_1 DAP} + \varepsilon$
Meyer	$V = \beta_0 + \beta_1 DAP + \beta_2 DAP^2 + \beta_3 DAPH_t + \beta_4 DAP^2 H_t + \beta_5 H_t + \varepsilon$

onde:

V - volume;

DAP - diâmetro na altura do peito;

β_0, \dots, β_n - parâmetros a serem ajustados;

\ln - logarítmico neperiano; e

ε - erro de estimativa.

Segundo Rocha (1992), o mérito de uma equação volumétrica, aumenta consideravelmente se ela possuir poucas variáveis e que estas sejam fáceis de se mensurar com exatidão, que sejam altamente correlacionadas com o volume, que tenham baixa correlação entre si, e o volume estimado por árvore individual aproxime-se do valor calculado pela técnica padrão de cubagem rigorosa da árvore abatida.

Segundo Neto (1977), Campos, Júnior e Neto (1985) o modelo de Schumacher e Hall têm apresentado estimativas mais precisas dos volumes, quando comparados com outros modelos volumétricos.

Um modelo bastante utilizado também é o modelo de Schumacher e Hall (Equação 2.6), frequentemente utilizado em sua forma linearizada, logarítmica, conhecido também como Schumacher e Hall logarítmico ou simplesmente, Schumacher e Hall (log) (Equação 2.7). Este modelo é ajustado com os parâmetros obtidos de árvores cubadas rigorosamente (CABACINHA, 2003). O modelo de Schumacher e Hall (log) é uma equação volumétrica de dupla entrada que estima o volume das árvores a partir do diâmetro na altura do peito DAP , ou dbh , e da altura total (H_t), conforme a Equação (2.7).

$$V_i = \beta_0 \cdot DAP_i^{\beta_1} \cdot H_{t_i}^{\beta_2} + \varepsilon_i \quad (2.6)$$

$$\ln V_i = \beta_0 + \beta_1 \ln DAP_i + \beta_2 \ln H_{t_i} + \varepsilon \quad (2.7)$$

onde:

V_i - volume da árvore i ;

DAP_i - diâmetro na altura do peito da árvore i ;

β_0, β_1 e β_2 - parâmetros a serem estimados;

H_{t_i} - altura total da árvore i ;

\ln - logarítmico neperiano; e

ε - erro de estimativa.

(PINHEIRO; VEIGA, 1984) compararam os modelos de equações de volume para espécies do gênero *Pinus* e concluíram que os modelos de Naslund e Schumacher e Hall (log) foram os que propiciaram as melhores estatísticas.

2.6 Considerações Finais Deste Capítulo

Este capítulo apresentou uma visão geral sobre a atividade do inventário florestal, dendrometria, além de mostrar algumas das abordagens tradicionais de medição de diâmetros e estimativa de volume.

O próximo capítulo apresenta um breve tutorial sobre redes neurais. É apresentado um breve histórico, principais arquiteturas, algoritmos de treinamento, bem como uma descrição mais detalhada do algoritmo de treinamento adotado neste trabalho.

Capítulo **3**

REDES NEURAIS ARTIFICIAIS

“A Percepção do desconhecido é a mais fascinante das experiências. O homem que não tem os olhos abertos para o mistério passará pela vida sem ver nada.”

Albert Einstein

3.1 Introdução

As redes neurais artificiais originaram-se em diversas áreas como neurociência, matemática, estatística, física, ciência da computação e engenharia. Suas aplicações podem ser encontradas em campos tão diversos quanto a modelagem, análise de séries temporais, reconhecimento de padrões, aproximação de funções, processamento de sinais e controle (HAYKIN, 2001).

Este capítulo apresenta um breve tutorial sobre redes neurais. É apresentado um breve histórico, as principais arquiteturas, os algoritmos de treinamento, bem como uma descrição mais detalhada do algoritmo de treinamento adotado neste trabalho.

3.2 Introdução Às Redes Neurais Artificiais

As Redes Neurais Artificiais (RNA) podem ser definidas, basicamente como sendo sistemas de processamento paralelo e distribuído baseados no sistema nervoso biológico (BRAGA; CARVALHO; LUDERNIR, 2000). Os modelos de redes neurais são compostos de elementos computacionais, chamados neurônios, arranjados em padrões semelhantes a redes neurais

biológicas.

A Figura 3.1 ilustra um modelo de neurônio biológico. Um neurônio recebe os sinais de entrada por meio dos dendritos, processa-os no corpo celular, gerando sinais de saída que são transmitidos para outros neurônios por meio dos axônios e das suas ramificações.

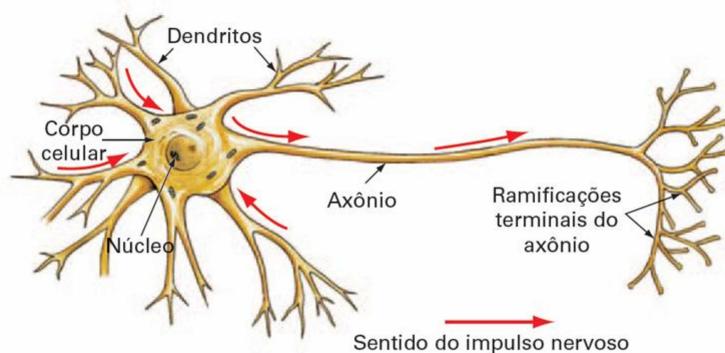


Figura 3.1: Anatomia de um neurônio biológico. Fonte: (CANTO, 2004)

Os neurônios comunicam-se por meio das sinapses. A sinapse é o nome da região onde o axônio de um neurônio encontra o dendrito de outro neurônio. A sinapse é de extrema importância para a transmissão de sinais entre os neurônios.

A Figura 3.2 ilustra a fenda sináptica.

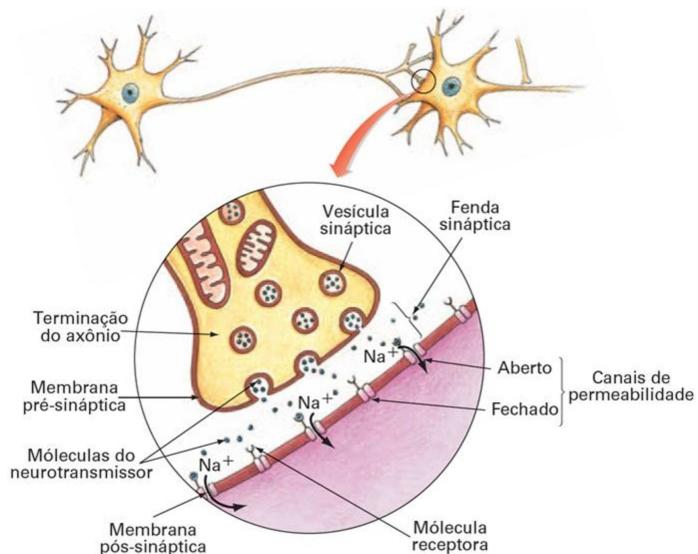


Figura 3.2: Transmissão do impulso nervoso por meio de uma sinapse química. Fonte: (CANTO, 2004).

A comunicação entre os neurônios pode ser inibida ou potencializada pela concentração dos neurotransmissores.

Neurotransmissores são substâncias químicas produzidas pelos neurônios. Por meio deles, pode-se enviar informações a outros neurônios. Os neurotransmissores podem também estimular a continuidade de um impulso ou efetuar a reação final no órgão ou no músculo alvo.

3.2.1 Um breve histórico da área de redes neurais

Os primeiros estudos de redes neurais artificiais são do início da década de 40 do século XX. Em 1943 com o trabalho de McCulloch e Pitts (1943) foi desenvolvido o primeiro modelo matemático de um neurônio biológico. Este modelo foi proposto como uma unidade de processamento binária descrevendo um cálculo lógico que procurava simular a forma, o comportamento e as funções de um neurônio biológico.

Nesse modelo, os dendritos foram definidos como entradas, cujas ligações com o corpo celular artificial são realizadas por meio dos pesos das conexões entre os neurônios que simulam a fenda sináptica e os neurotransmissores. Os estímulos captados pelas entradas são processados por uma função soma e um limiar (*threshold*) de disparo do neurônio biológico que é representado por uma função de ativação ou de transferência.

O primeiro modelo de um neurônio biológico, embora muito simples, apresentou grande poder computacional mas faltavam-lhe características que lhe forneceriam capacidades adaptativas e de aprendizagem, imprescindíveis em modelos de sistemas inteligentes.

Em 1949, o neurofisiologista Donald Hebb apresentou o primeiro método de aprendizagem em redes neurais (HEBB, 1949). Seu modelo sugeriu que as conexões ativas entre os neurônios tendem a se fortalecer, enquanto que as outras tendem a se enfraquecer. Inicialmente, o trabalho de Hebb foi muito influente, muito entre os psicólogos, porém, teve pouco ou nenhum impacto na comunidade de engenharia (HAYKIN, 2001).

No final dos anos 50, foi introduzido por (ROSENBLATT, 1958) uma nova abordagem para o problema de classificação de padrões com o desenvolvimento do perceptron. Rosenblatt defendeu que o cérebro humano trabalha como um associador adaptável de padrões, e não como um circuito lógico determinístico como foi proposto por (MINSKY, 1954; NEUMANN, 1956). O “Teorema da Convergência para Perceptron” foi demonstrado, sendo proposto um algoritmo para o ajuste dos pesos, provando a convergência quando os padrões são linearmente separáveis (ROSENBLATT, 1958).

No início dos anos 60, com a introdução do algoritmo Least Mean Square (LMS), (WIDROW; HOFF, 1960) formularam a Adaline (*Adaptive Linear Element*). Em 1962, Widrow e seus colaboradores desenvolveram a estrutura de múltiplos elementos adaptativos chamado

Madaline (WIDROW, 1962).

Em 1969 surge a publicação do trabalho de (MINSKY; PAPERT, 1969), onde foram provados matematicamente as limitações do perceptron linear, mostrando que este modelo de neurônio artificial não era capaz de solucionar problemas que não fossem linearmente separáveis. Estabelecendo assim, uma longa pausa nas pesquisas no campo das redes neurais, após um período de grande desenvolvimento.

Foram criadas alternativas de redes mais complexas, que seriam capazes de lidar com problemas não lineares, porém, a falta de um método de aprendizagem dessas redes mais complexas e de maior potencial computacional desestimulou os pesquisadores, fazendo com que as redes neurais permanecessem “esquecidas” durante os anos 70 (BRAGA; CARVALHO; LUDERNIR, 2000).

Embora, nos anos 70 não tenha havido uma pesquisa intensa na área das redes neurais, devem ser citados alguns pesquisadores que realizaram importantes trabalhos em redes neurais durante essa década:

- Grosberg no final dos anos 60 propôs um modelo aditivo de um neurônio, que consistia de equações diferenciais, e ele explorou o uso do modelo como uma base para a memória de curto-prazo (GROSSBERG, 1968a; GROSSBERG, 1968b);
- Werbos descreveu pela primeira vez o algoritmo de retropropagação do erro que foi aplicado para os modelos gerais de redes, mas não foi aplicado a redes neurais porque representaria um caso particular (WERBOS, 1974);
- Little e Shaw descreveram um modelo probabilístico de um neurônio, e eles usaram esse modelo para desenvolver uma teoria de memória a curto-prazo (LITTLE; SHAW, 1975);
- Willshaw e Von der Malsburg publicaram o primeiro artigo na formação de mapas auto-organizáveis (WILLSHAW; MALSBURG, 1976); e
- Anderson e outros publicaram o conceito de **Brain-State-in-a-Box** (BSB), que consistia de uma rede associativa simples acoplada a um sistema dinâmico não-linear (ANDERSON et al., 1988).

Após a publicação dos trabalhos do físico John Hopfield em 1982, o interesse nas pesquisas de redes neurais ressurgiu fortemente. Hopfield apresentou um modelo de rede neural recorrente composto de elementos interconectados, que buscavam atingir um estado de energia mínima, garantindo a estabilidade da rede. O modelo representava a operação do neurônio a partir de

um determinado nível de excitação, mostrando que a memória da rede neural está armazenada nas interconexões entre os neurônios (HOPFIELD, 1982).

Finalmente, em 1986, a criação do algoritmo de retropropagação por (RUMELHART; HINTON; WILLIAMS, 1986b) e a publicação do livro Parallel Distributed Processing (RUMELHART; HINTON; WILLIAMS, 1986a) forneceram o grande impulso para o interesse na área de redes neurais. A partir de então, o algoritmo de retropropagação passou a ser o método de aprendizagem mais popular para o treinamento de redes neurais perceptron multi-camadas, fazendo com que os pesquisadores tivessem interesses em aplicações de redes neurais artificiais nas mais diferentes áreas.

3.3 Rede Perceptron Multi-Camadas

A rede Perceptron Multi-Camadas, do inglês, Multilayer Perceptron (MLP), ou perceptron multicamadas, é uma das mais conhecidas e aplicadas arquiteturas de redes neurais, e representa uma generalização do perceptron proposto por Rosemblatt (BALLINI; SOARES; ANDRADE, 2003).

A arquitetura da Perceptron Multi-Camadas (MLP) consiste de uma camada de entrada, uma ou mais camadas intermediárias e uma camada de saída. A camada de entrada, cujos neurônios pertencentes a essa camada são denominados unidades de entrada, propaga os valores das entradas para as camadas seguintes sem modificação. As camadas intermediárias transmitem informações por meio das conexões entre as camadas de entrada e saída. Os neurônios pertencentes às camadas intermediárias são denominados unidades ocultas. Finalmente, a camada de saída, cujos neurônios são chamados unidades de saída, transmite a resposta da rede neural à entrada aplicada na camada de entrada. A Figura 3.3 mostra a arquitetura de uma rede neural com duas camadas intermediárias.

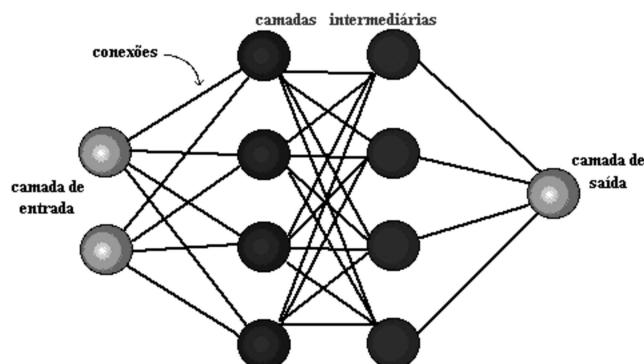


Figura 3.3: Exemplo de arquitetura perceptron multi-camadas.

Os neurônios são conectados por arestas e a cada aresta está associado um peso. A comunicação entre os neurônios é realizada por meio dessas interconexões ponderadas. Porém, a comunicação ocorre somente entre as unidades de camadas distintas, portanto, não existe comunicação entre as unidades de uma mesma camada.

Cada neurônio da rede tem uma função diferenciável, conhecida como função de ativação. Esta função pode ser linear, logística ou tangente hiperbólica.

Assim, a arquitetura da rede neural MLP apresenta três características distintas: variações quanto ao número de camadas e neurônios intermediários da rede, tipo de conexão determinada pelas sinapses e função de ativação.

O modelo MLP apresenta um treinamento supervisionado, ou seja, é necessário um “instrutor” para indicar a resposta desejada para um padrão de entrada apresentado à rede durante a fase de aprendizagem. Um erro é calculado pela diferença entre a resposta desejada e a resposta observada. Os parâmetros da rede (pesos e limiares) são ajustados de acordo com esse sinal. Assim, a rede é adaptada ou treinada por um processo iterativo de ajustes sucessivos dos pesos. Este método é chamado de método de aprendizagem.

Para o treinamento da rede MLP, o método de aprendizagem mais utilizado é o algoritmo de retropropagação do erro. Este algoritmo consiste basicamente de duas fases. A primeira fase, conhecida como fase *feed-forward*, as entradas são apresentadas e propagadas por meio da rede, camada por camada, calculando a saída de cada neurônio. Durante essa fase, os pesos são fixos e a saída calculada é comparada com a saída desejada, resultando em um erro para cada unidade. Na segunda fase, conhecida como fase *backward* o erro calculado é propagado da camada de saída para a camada de entrada e os pesos são ajustados de acordo com a regra de correção do erro. Originalmente, essa é denominada de “retropropagação do erro”.

3.4 Algoritmo de Retropropagação

O algoritmo de aprendizagem de retropropagação (*back-propagation*) consiste em alterar os pesos da rede com a finalidade de minimizar a diferença entre as saídas desejadas e as saídas fornecidas pelo modelo. Se o erro na camada de saída não é menor do que uma determinada tolerância, então o erro é retropropagado para a rede, tendo como base para a atualização dos pesos a regra Delta. Esta regra implementa o Método do Gradiente Descendente (HAYKIN, 2001).

Seja $y_{dj}(n)$ a saída desejada do neurônio j e $y_j(n)$ a saída calculada pela rede com uma

entrada n . O erro $e_j(n)$ na camada de saída é obtido utilizando-se a Equação (3.1).

$$e_j(n) = yd_j(n) - y_j(n) \quad (3.1)$$

O valor do erro quadrático para o neurônio j é definido como sendo $\frac{1}{2}(e_j(n))^2$. A soma dos erros quadráticos é obtida para todos os neurônios da camada de saída pela Equação (3.2).

$$\mathcal{E}(n) = \frac{1}{2} \sum_j (e_j(n))^2 \quad (3.2)$$

Seja N o número total de pares entrada/saída desejada contidos no conjunto de dados de treinamento. O erro quadrático médio (MSE) é obtido pela soma do erro $E(n)$ sobre todo n , normalizado com relação ao número de padrões N , conforme a Equação (3.3).

$$E = \frac{1}{N} \sum_{n=1}^N \mathcal{E}(n) \quad (3.3)$$

O objetivo do processo de treinamento é ajustar os parâmetros livres (pesos) da rede, minimizando uma função objetivo representada pelo erro quadrático médio, como mostrado na Equação (3.4).

$$\min E = \min \frac{1}{N} \sum_{n=1}^N \mathcal{E}(n) \quad (3.4)$$

Para a derivação do algoritmo de retropropagação, é considerado, inicialmente um método de treinamento em que os pesos são ajustados entrada-a-entrada, ou seja, o ajuste dos pesos é realizado de acordo com o erro calculado para cada entrada apresentada à rede. A posteriori, neste capítulo será apresentado uma outra forma de ajustar os pesos conhecida como aprendizagem por ciclo ou em lote (batch).

O nível de ativação interno do neurônio j , $v_j(n)$, é uma função linear das saídas y_i dos neurônios que estão conectados ao neurônio j por meio dos pesos w_{ji} obtidos pela Equação (3.5).

$$v_j(n) = \sum_{i=0}^p w_{ji}(n) y_i(n) \quad (3.5)$$

onde:

p - número de neurônios da camada imediatamente anterior ao neurônio j , excluindo o limiar.

Como mostrado na Figura 3.4.

O peso sináptico w_{j0} é igual ao limiar θ_0 e corresponde à entrada $y_0(n) = 1$.

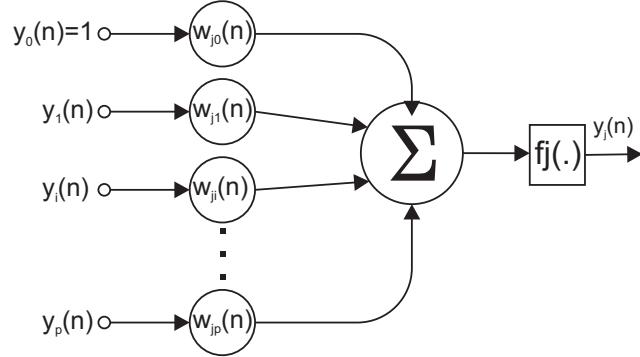


Figura 3.4: Modelo do neurônio artificial

A saída $y_j(n)$ do neurônio j é um valor real, determinado por uma função de ativação não linear, como mostrado na Equação (3.6).

$$y_j(n) = f_j(v_j(n)) \quad (3.6)$$

Para minimizar a Equação (3.4) usando o método do gradiente descendente, é necessário calcular a derivada parcial de \mathcal{E} em relação a cada peso da rede. De acordo com a regra da cadeia, a derivada parcial pode ser escrita pela Equação (3.7).

$$\frac{\partial \mathcal{E}(n)}{\partial w_{ij}(n)} = \frac{\partial \mathcal{E}(n)}{\partial e_j(n)} \frac{\partial e_j(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} \frac{\partial v_j(n)}{\partial w_{ij}(n)} \quad (3.7)$$

Diferenciando as Equações (3.1) em relação a $y_j(n)$, (3.2) em relação a $e_j(n)$, (3.5) em relação a $w_{ji}(n)$, (3.6) em relação a $v_j(n)$ e substituindo na Equação (3.7), obtém-se a Equação (3.8).

$$\frac{\partial \mathcal{E}(n)}{\partial w_{ij}(n)} = -e_j(n) f'_j(v_j(n)) y_i(n) \quad (3.8)$$

O algoritmo de retropropagação aplica uma correção $\Delta w_{ji}(n)$ aos pesos sinápticos w_{ji} proporcional à direção oposta ao gradiente $\partial \mathcal{E}(n) / \partial w_{ji}(n)$, definida pela Regra Delta, de acordo com a Equação (3.9).

$$\Delta w_{ji}(n) = -\eta \frac{\partial \mathcal{E}(n)}{\partial w_{ji}(n)} \quad (3.9)$$

onde:

η - constante que determina a taxa de aprendizagem ou velocidade de aprendizagem. Essa constante é chamada de parâmetro taxa de aprendizagem.

Substituindo-se a Equação (3.8) na Equação (3.9), a atualização dos pesos pode ser reescrita conforme a Equação (3.10).

$$\Delta w_{ji}(n) = \eta \delta_j(n) y_i(n) \quad (3.10)$$

onde:

$\delta_j(n)$ - gradiente local definido pela Equação (3.11).

$$\delta_j(n) = -\frac{\partial \mathcal{E}(n)}{\partial e_j(n)} \frac{\partial e_j(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} = e_j(n) f'_j(v_j(n)) \quad (3.11)$$

Das Equações (3.10) e (3.11), pode-se observar que a atualização dos pesos depende do sinal de erro $e_j(n)$ para o cálculo do gradiente local. Neste caso, deve ser considerado onde está localizado o neurônio j , ou seja, se o neurônio j , está na camada de saída ou se está na camada intermediária.

Considerando, primeiramente, o caso em que o neurônio j está na camada de saída e conhecendo a saída desejada, pode-se calcular o erro utilizando-se a Equação (3.1). Assim, o gradiente local, $\delta_j(n)$, é igual ao produto da derivada da função de ativação $f'_j(v_j(n))$ e o erro $e_j(n)$, como mostrado na Equação (3.12).

$$\delta_j(n) = e_j f'_j(v_j(n)) \quad (3.12)$$

Caso o neurônio j esteja localizado na camada intermediária, não existe nenhuma saída desejada específica atribuída a esse neurônio. Então, o sinal de erro $e_j(n)$ é calculado em termo dos erros de todos os neurônios nos quais o neurônio j está conectado.

Redefinindo o gradiente local $\delta_j(n)$ para o neurônio j , a Equação (3.11) pode ser reescrita de acordo com a Equação (3.13).

$$\delta_j(n) = -\frac{\partial \mathcal{E}(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} = -\frac{\partial \mathcal{E}(n)}{\partial y_j(n)} f'_j(v_j(n)) \quad (3.13)$$

Para calcular a derivada parcial $\partial\mathcal{E}(n)/\partial y_j(n)$, o erro quadrático do neurônio k é obtido pela Equação (3.14).

$$\mathcal{E}(n) = \frac{1}{2} \sum_k (e_k(n))^2 \quad (3.14)$$

Diferenciando a Equação (3.14) em relação a $y_j(n)$, obtém-se a Equação (3.15).

$$\frac{\partial\mathcal{E}(n)}{\partial y_j(n)} = \sum_k e_k(n) \frac{\partial e_k(n)}{\partial y_j(n)} \quad (3.15)$$

E usando-se a regra da cadeia para o cálculo da derivada parcial $\partial e_k(n)/\partial y_j(n)$, a Equação (3.15) pode ser reescrita como mostrado na Equação (3.16).

$$\frac{\partial\mathcal{E}(n)}{\partial y_j(n)} = \sum_k e_k(n) \frac{\partial e_k(n)}{\partial v_k(n)} \frac{\partial v_k(n)}{\partial y_j(n)} \quad (3.16)$$

O sinal de erro é obtido pela Equação (3.17).

$$e_k(n) = yd_k(n) - y_k(n) = yd_k(n) - f_k(v_k(n)) \quad (3.17)$$

E o nível de ativação do neurônio k é encontrado utilizando-se a Equação (3.18).

$$v_k(n) = \sum_{j=0}^q w_{kj}(n) y_j(n) \quad (3.18)$$

onde:

q - número de entradas aplicadas ao neurônio k .

Diferenciando as Equações (3.17) em relação a $v_k(n)$ e (3.18) em relação a $y_j(n)$ e substituindo na Equação (3.15), a derivada parcial pode ser reescrita como mostrado na Equação (3.19).

$$\frac{\partial\mathcal{E}(n)}{\partial y_j(n)} = - \sum_k e_k(n) f'_k(v_k(n)) w_{kj}(n) = - \sum_k \delta_k(n) w_{kj}(n) \quad (3.19)$$

onde:

$\delta_k(n)$ - gradiente local do neurônio k .

Finalmente, substituindo a Equação (3.19) na Equação (3.13), o gradiente local $\delta_j(n)$ para o neurônio intermediário j é calculado pela Equação (3.20).

$$\delta_j(n) = f'_j(v_j(n)) \sum_k \delta_k(n) w_{kj}(n) \quad (3.20)$$

Assim, se o neurônio j é uma unidade intermediária, o gradiente local $\delta_j(n)$ é igual ao produto da derivada da função de ativação, associada a esse neurônio, e a soma ponderada dos gradientes locais calculados para os neurônios na próxima camada ou camada de saída que estão conectados ao neurônio j .

Portanto, na aplicação do algoritmo de retropropagação, na primeira fase (fase *forward*) os pesos sinápticos permanecem inalterados por meio da rede e a saída é obtida pelas Equações (3.5) e (3.6). Os erros são calculados para cada unidade de saída (Equações (3.1) e (3.2)). Assim, a fase *forward* inicia na primeira camada com a apresentação das entradas, e termina na camada de saída pelo cálculo do erro para cada neurônio nessa camada.

A fase *backward* inicia na camada de saída para a camada de entrada, por meio da propagação dos gradientes locais para cada neurônio da rede. Para os neurônios localizados na camada de saída, o gradiente é obtido pela Equação (3.12) e os pesos são atualizados usando a Equação (3.9). A seguir, são calculados os gradientes de todos os neurônios da próxima camada (Equação (3.19)) e são realizadas as mudanças nos pesos de todas as conexões dessa camada (Equação (3.9)). O cálculo recursivo é realizado, camada por camada, propagando as mudanças de todos os pesos sinápticos até a camada de entrada.

3.5 Função de Ativação

Para o cálculo dos gradientes locais de cada neurônio da rede MLP é preciso conhecer a derivada da função de ativação. A Figura 3.5 mostra as funções de ativação mais comuns (SILVA, 1998). A diferenciabilidade da função de ativação é, portanto, uma condição necessária. Uma das funções de ativação mais utilizadas é a função logística, definida pela Equação (3.21).

$$y_j(n) = f_j(v_j(n)) = \frac{1}{1 + \exp^{-v_j(n)}} \quad (3.21)$$

onde:

$v_j(n)$ - nível de ativação do neurônio j no instante n .

A função de ativação logística é limitada, assumindo valores no intervalo $(0,1)$, como mostra a Figura 3.5(c).

Diferenciando a Equação (3.21) em relação a $v_j(n)$, obtém-se a Equação (3.22).

$$f'_j(v_j(n)) = \frac{\exp(-v_j(n))}{[1 + \exp(-v_j(n))]^2} = y_j(n)[1 - y_j(n)] \quad (3.22)$$

Pode-se concluir que o cálculo da derivada requer poucos recursos computacionais.

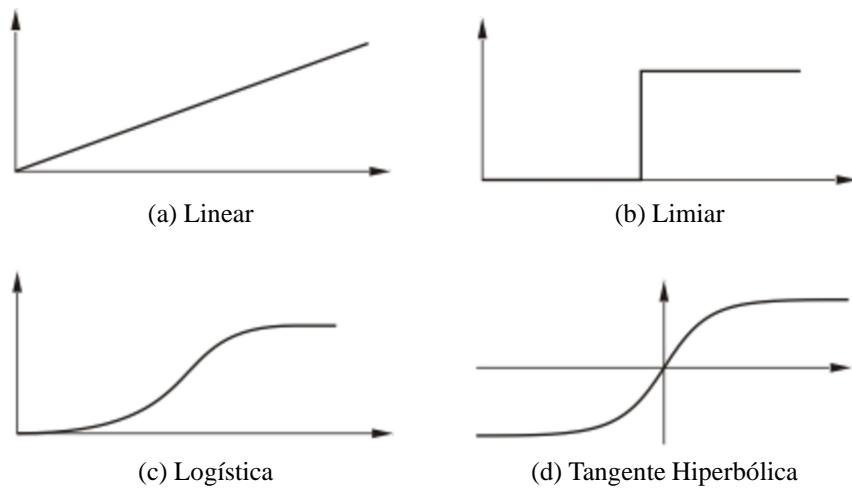


Figura 3.5: Funções de ativação mais comuns

3.6 Taxa de Aprendizagem

A taxa de aprendizagem η é uma constante de proporcionalidade, que assume valores no intervalo $(0, 1]$. Essa taxa determina a natureza de adaptação dos pesos.

Um alto valor de η produzirá uma rápida aprendizagem, resultando em grandes alterações nos pesos. Entretanto, aumentará o risco da rede tornar-se instável, podendo oscilar ao redor da solução e provocar a saturação dos neurônios.

Por outro lado, se a taxa de aprendizagem assumir valores pequenos, as mudanças nos pesos sinápticos serão menores de uma iteração para outra e as trajetórias no espaço definido pelos pesos serão mais suaves. Este benefício é alcançado com um alto custo no processo de treinamento, pois esse torna-se mais lento por requerer muito mais iterações até a convergência (NG, 1997).

Assim, um método simples para aumentar a velocidade de aprendizagem é modificar a Regra Delta, Equação (3.23), adicionando um termo *momentum*, obtém-se a Equação (3.23)

(RUMELHART; HINTON; WILLIAMS, 1986b).

$$\Delta w_{ji}(n) = \alpha \Delta w_{ji}(n-1) + \eta \delta_j(n) y_i(n) \quad (3.23)$$

onde:

α - número positivo restrito ao intervalo $[0, 1]$, chamado constante *momentum*.

A Equação (3.23) é conhecida como Regra Delta Generalizada, pois inclui a Regra Delta (Equação (3.10)) como sendo um caso especial quando $\alpha = 0$.

O termo *momentum* relaciona as alterações dos pesos sinápticos na interação n com as alterações realizadas na interação $(n-1)$. A utilização dessa constante dificulta a mudança de tendência na atualização dos pesos, podendo ainda ser utilizada para reduzir a possibilidade de ocorrer mínimos locais.

3.7 Inicialização dos Pesos

O primeiro passo no algoritmo de retropropagação é a inicialização dos pesos da rede. Uma boa escolha dos parâmetros iniciais é fundamental para um bom desempenho desse algoritmo. Caso a inicialização dos pesos seja realizada inadequadamente, pode ocorrer um fenômeno chamado “saturação prematura”. Este fenômeno corresponde a um ponto de sela na superfície de erro pois a soma dos erros quadráticos permanece constante por algum período, continuando a decrescer após esse período durante o processo de aprendizagem (LEE; OH; KIM, 1991).

Quando existe alguma informação a priori sobre os dados, esta informação pode ser utilizada para inicializar os pesos. Quando essa informação não é utilizada, recomenda-se que a inicialização dos parâmetros seja realizada aleatoriamente, com distribuição uniforme e magnitude pequena (HAYKIN, 2001).

3.8 Aprendizagem Entrada-a-Entrada e Aprendizagem por Ciclo

As aplicações práticas do algoritmo de retropropagação consistem na apresentação dos padrões (pares entrada/saída) pertencentes ao conjunto de treinamento repetidas vezes. Denomina-se época a apresentação de todos os N pares do conjunto de treinamento durante o processo de aprendizagem.

O processo de aprendizagem é repetido até que os pesos e os limiares estejam estáveis e o Erro Médio Quadrático (MSE) converja para um valor mínimo aceitável.

Segundo (RIDMILER, 1994), existem basicamente dois possíveis métodos para se calcular e executar a atualização dos pesos durante o processo de aprendizagem: aprendizagem entrada-a-entrada e aprendizagem por ciclo.

3.8.1 Aprendizagem entrada-a-entrada

A aprendizagem entrada-a-entrada atualiza os pesos da rede depois de cada apresentação de um par entrada-saída do conjunto de treinamento e do cálculo do respectivo gradiente, isto é, a atualização é realizada imediatamente após a obtenção do gradiente referente a um único par apresentado à rede. Para um conjunto de treinamento contendo N pares entrada-saída são realizadas N correções de pesos em uma época. Cada correção é baseada somente no erro do par apresentado naquela iteração. Este tipo de método, também é conhecido como aprendizagem *on-line* ou aprendizagem local, ele produz melhores resultados para os conjuntos de amostras apresentados aleatoriamente a cada época, pois a ordem de apresentação local, produz melhores resultados para os conjuntos de amostras apresentados aleatoriamente a cada época, pois a ordem de apresentação das amostras não deve representar nenhuma informação significativa para condicionar o ajuste dos pesos.

3.8.2 Aprendizagem por ciclo

Na aprendizagem por ciclo, apenas uma correção dos pesos é realizada por época. Primeiramente, todas as amostras do conjunto de treinamento são propagadas pela rede e então o erro é calculado. Em seguida, calcula-se o MSE, para os N pares utilizando a Equação (3.24).

$$E = \frac{1}{2N} \sum_{n=1}^N \sum_j (e_j(n))^2 \quad (3.24)$$

Para uma taxa de aprendizagem η , o ajuste do peso sináptico, w_{ji} é obtido pela regra delta conforme a Equação (3.25).

$$\Delta w_{ji}(n) = -\eta \frac{\partial E}{\partial w_{ji}} = -\frac{\eta}{N} \sum_{n=1}^N \frac{\partial \mathcal{E}(n)}{\partial w_{ji}(n)} \quad (3.25)$$

A derivada parcial $\partial \mathcal{E}(n)/\partial w_{ji}(n)$ é calculada da mesma forma como descrito na derivação do algoritmo de retropropagação. Esse método também é conhecido como aprendizagem *off-*

line ou aprendizagem em lote (*batch*).

O modo de aprendizagem entrada-a-entrada apresenta melhores resultados para grandes conjuntos de treinamento que contenham quantidades significativas de informação redundantes. Como as amostras são apresentadas aleatoriamente, o uso desse método transforma em estocástica a busca no espaço de pesos. A busca estocástica reduz a possibilidade do algoritmo de retropropagação ficar preso em um mínimo local. A utilização do método de aprendizagem por ciclo fornece informações mais seguras com relação ao vetor gradiente (MØLLER, 1993). A eficiência dos dois métodos depende do problema a ser tratado (HERTZ; KROGH; PALMER, 1991).

3.9 Critério de Parada

O critério de parada do algoritmo de retropropagação não é bem definido e a convergência não é garantida. Um critério de parada é interromper o treinamento após um número fixo de iterações, mas esta forma não é recomendável por não levar em conta as informações sobre o estado do processo de aprendizagem. Então deve-se formular um critério de convergência que considere a existência dos mínimos locais (KRAMER; SANGIOVANNI-VINCENTELLI, 1989).

Um dos critérios discutidos em (HAYKIN, 2001) e que considera essa propriedade é o fato de que a função objetivo (erro quadrático médio) é estacionária no ponto $w = w^*$, onde w^* é um vetor peso que denota o mínimo, podendo ser local ou global. Este critério de parada pode ser definido da seguinte forma: o algoritmo de retropropagação converge se a variação do erro quadrático médio de uma época para outra assumir um valor suficientemente pequeno.

Um outro critério de parada é testar, após cada iteração, o desempenho de generalização do algoritmo. O treinamento é encerrado quando esse desempenho apresentar tendência de piora. Este critério será discutido na seção 3.11 neste capítulo quando será apresentada a técnica estatística conhecida como validação cruzada.

3.10 Generalização

A generalização é uma das mais importantes características das redes neurais. A generalização pode ser influenciada por três fatores:

1. O tamanho e a eficiência do conjunto de treinamento, que deve ser muito bem escolhido,

pois deve expressar todas as características relevantes do problema no universo considerado;

2. A arquitetura da rede neural: números de camadas e neurônios intermediários; e
3. A complexidade do problema a ser tratado.

A rede neural considera ter uma boa generalização se, fornecidos os conjuntos de dados de treinamento e teste, a relação entre os dados de entrada-saída calculada pela rede já treinada está correta ou tão próxima quanto desejável para os padrões pertencentes ao conjunto de teste, podendo ser obtida por meio da validação cruzada.

3.11 Validação Cruzada

O processo de aprendizagem consiste de uma seleção adequada dos parâmetros livres da rede para um determinado conjunto de dados de treinamento. A determinação desses parâmetros pode ser baseada em um conjunto de arquiteturas de redes neurais candidatas a serem os “melhores” modelos para realizar o ajuste dos parâmetros.

Uma técnica estatística utilizada para determinar os parâmetros da rede é a chamada validação cruzada (STONE, 1974), descrita como segue.

Primeiramente, um conjunto de dados é aleatoriamente particionado em um conjunto de treinamento e um conjunto de teste. O conjunto de treinamento é então particionado em dois subconjuntos distintos:

1. Um subconjunto usado durante a aprendizagem da rede para a estimação do modelo, denominado de subconjunto de treinamento; e
2. Um subconjunto utilizado para avaliar a evolução do desempenho do modelo, ou seja, para a validação da rede, denominado de subconjunto de validação. Este subconjunto corresponde a uma parte pequena do conjunto de treinamento, variando entre 10% a 20% do seu tamanho.

A validação cruzada consiste em validar o modelo em um conjunto diferente do usado para estimar os parâmetros da rede, podendo, assim, verificar o desempenho de vários modelos e escolher o que apresentar melhor desempenho. Após encontrada a melhor arquitetura, a rede é novamente treinada com todo o conjunto de treinamento. Só, então, o conjunto de teste é

utilizado para verificar a capacidade de generalização da rede. Esses resultados auxiliam na escolha da melhor topologia, em termos de generalização.

Uma outra forma na qual a validação cruzada pode ser utilizada é para decidir quando o processo de aprendizagem pode ser encerrado. Essa decisão é tomada com base no desempenho do erro quadrático médio correspondente ao ponto de erro mínimo em relação ao número de épocas.

A validação cruzada foi utilizada neste trabalho para a escolha da arquitetura mais adequada para as classes diamétricas das árvores e para determinar o fim do processo de treinamento.

3.12 Aproximação de Funções

Uma rede MLP com algoritmo retropropagação realiza um mapeamento de entrada-saída não-linear que é continuamente diferenciável. Para esse mapeamento, é considerada a seguinte questão:

Qual é o número mínimo de camadas intermediárias em um perceptron multi-camadas com um mapeamento entrada-saída que fornece uma realização aproximada de algum mapeamento contínuo?

(CYBENCO, 1989) demonstrou pela primeira vez e de forma rigorosa que uma única camada intermediária é suficiente para aproximar uniformemente qualquer função contínua em um hipercubo unitário. Em 1989, (FUNAHASHI, 1989) publicou que os modelos perceptron multi-camadas são aproximadores universais. Esse trabalho foi denominado teorema da aproximação universal. Este teorema é diretamente aplicável às redes MLP.

O teorema da aproximação universal é um teorema de existência, pois é uma justificativa matemática para a aproximação de uma função arbitrária. Os resultados desse teorema permitem demonstrar que uma única camada intermediária é suficiente para um perceptron multi-camadas realizar uma aproximação uniforme para um determinado conjunto de treinamento, representado por um conjunto de entradas x_1, x_2, \dots, x_m e uma saída desejada $f(x_1, x_2, \dots, x_m)$. Entretanto, o teorema não afirma que uma única camada intermediária é ótima no sentido de tempo de aprendizagem e custo computacional, além de não indicar um valor adequado para o número de neurônios na camada intermediária.

3.13 Algoritmo de Levenberg-Marquardt

O algoritmo de Levenberg-Marquardt (LMA) utiliza o treinamento em lote e consiste em um aperfeiçoamento do método de Gauss-Newton, que é uma variante do método de Newton. O método de Newton utiliza a informação da derivada parcial de segunda ordem do índice de desempenho utilizado para corrigir os pesos. Isso permite que além da informação do gradiente, seja usada a informação sobre a curvatura da superfície do erro. O LMA corresponde a uma variante do método de Newton, e é cerca de 10 a 100 vezes mais rápido do que o método do gradiente (HAGAN; MENHAJ, 1994).

A retropropagação com a técnica do gradiente descendente é um algoritmo da maior desida, enquanto o algoritmo de Levenberg-Marquardt é uma aproximação para o Método de Newton (MARQUARDT, 1963).

O método de Newton é um processo iterativo que visa a minimização de uma função $f(w)$ utilizando a equação de atualização como mostrado na Equação (3.26).

$$\Delta w = -[\nabla^2 f(w)]^{-1} \nabla f(w) \quad (3.26)$$

onde:

w - vetor de pesos;

$\nabla^2 f(w)$ - matriz Hessiana; e

$\nabla f(w)$ - vetor gradiente.

Assumindo que a função $f(w)$ é a soma dos quadrados dos erros. Essa função é obtida pela Equação (3.27).

$$f(w) = \sum_{i=1}^N e_i^2(w) \quad (3.27)$$

Seja e o vetor dos erros e J a matriz Jacobiana encontrada pela Equação (3.28).

$$J(w) = \begin{bmatrix} \frac{\partial e_1(w)}{\partial w_1} & \frac{\partial e_1(w)}{\partial w_2} & \dots & \frac{\partial e_1(w)}{\partial w_i} \\ \frac{\partial e_2(w)}{\partial w_1} & \frac{\partial e_2(w)}{\partial w_2} & \dots & \frac{\partial e_2(w)}{\partial w_i} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial e_N(w)}{\partial w_1} & \frac{\partial e_N(w)}{\partial w_2} & \dots & \frac{\partial e_N(w)}{\partial w_i} \end{bmatrix} \quad (3.28)$$

Dessa forma tem-se a Equação (3.29).

$$\nabla f(w) = J^T(w)e(w) \quad (3.29)$$

$$\nabla^2 f(w) = J^T(w)J(w) + S(w) \quad (3.30)$$

onde:

$J(w)$ - matriz Jacobiana; e

S - matriz, obtida pela Equação (3.31).

$$S(w) = \sum_{i=1}^N e_i(w) \nabla^2 e_i(w) \quad (3.31)$$

Para o método de Gauss-Newton supõe-se que $S(w) \approx 0$, e atualizando-se a Equação (3.26), obtém-se a Equação (3.32).

$$\Delta w = - \left[J^T(w)J(w) \right]^{-1} J^T(w)e(w) \quad (3.32)$$

A vantagem do método de Gauss-Newton comparativamente ao método de Newton é o fato de evitar o cálculo das segundas derivadas do vetor dos erros, que podem ser difíceis de serem obtidas. Contudo, uma desvantagem é a matriz $J^T J$ não ser inversível. Essa desvantagem é superada pelo método de Levenberg-Marquardt, cuja equação modificada para o Gauss-Newton é a Equação (3.33).

$$\Delta w = - \left[J^T(w)J(w) + \mu I \right]^{-1} J^T(w)e(w) \quad (3.33)$$

onde:

I - matriz identidade.

O parâmetro μ é convenientemente modificado durante as iterações.

Como

$$w_{i+1} = w_i + \Delta w \quad (3.34)$$

então

$$w_{i+1} = w_i - [J^T(w_i)J(w_i) + \mu I]^{-1} J^T(w_i)e(w_i) \quad (3.35)$$

O parâmetro μ é multiplicado por algum fator (β) onde o passo resulta em uma $f(w)$ incrementada. Quando μ é grande o algoritmo torna-se o método de maior descida (com passo $1/\mu$), enquanto para μ pequeno o algoritmo aproxima-se o método de Gauss-Newton. O algoritmo de Levenberg-Marquardt pode ser considerado uma modificação da região de confiança para o Gauss-Newton. O passo chave nesse algoritmo é a computação da matriz Jacobiana. Para as redes neurais mapeadas o termo na matriz Jacobiana pode ser computado por uma simples modificação do algoritmo de retropropagação (HAGAN; MENHAJ, 1994).

Essencialmente, o algoritmo de Levenberg-Marquardt (XU; HO, 2006) é um algoritmo de ajuste de comportamentos não-lineares baseado no método dos mínimos-quadrados que procura encontrar o melhor ajuste para um conjunto de dados tentando minimizar a soma dos quadrados das diferenças entre a curva ajustada e os dados (tais diferenças são chamadas de resíduos). Na Equação (3.14), $\mathcal{E}(n)$ é uma função erro objetiva construída a partir de n termos de erros individuais sobre todo n , normalizado com relação ao número de padrões N .

Assim, $e_i^2(n) = (yd_i - y_i)^2$ e yd_i é o valor desejado como saída para o i -ésimo neurônio, y_i é o valor de saída referente ao i -ésimo neurônio e $e(w_k)$ representa a função contendo os termos de erro individuais.

Assume-se que $e(w)$ e seu Jacobiano J são conhecidos no ponto n . O objetivo do algoritmo de Levenberg-Marquardt é calcular o vetor de pesos (w); tal que $\mathcal{E}(w)$ seja mínimo. Usando o algoritmo de Levenberg-Marquardt, um novo vetor composto por uma camada de pesos w_{k+1} pode ser obtido a partir do vetor de pesos anterior w_k como mostrado na Equação (3.36).

$$w_{k+1} = w_k + \delta w_k \quad (3.36)$$

onde:

δw_k - definido pela Equação (3.37) (CHEN; MANRY; CHANDRASEKARAN, 1999; TAN; VAN CAUWENBERGHE, 1996).

$$\delta w_k = -(J_k^T J_k + \mu I)^{-1} (J_k^T e(w_k)) \quad (3.37)$$

onde:

J_k - Jacobiano de $e(w_k)$ avaliado tomando-se a derivada primeira de $e(w_k)$ em relação à w_k ;

μ - parâmetro de Marquardt; e

I - matriz identidade.

Quando $\mu = 0$, esse é somente o método de Newton, usando a matriz Hessiana aproximada. Quando μ assume valores maiores, verifica-se uma descida em gradiente com pequenos valores incrementais. O método de Newton é mais rápido e preciso ao aproximar-se do erro mínimo, então o objetivo é mudar para o método de Newton tão rápido quanto possível. Deste modo, μ é diminuído após cada etapa bem sucedida e é aumentado somente quando após uma nova tentativa ocorrer um aumento da diferença entre a saída da rede e o alvo a ser considerado. Baseado nesse procedimento, a diferença é reduzida a cada nova iteração do algoritmo.

O método de *Levenberg-Marquardt Algorithm* (LMA) pode ser sintetizado da seguinte forma:

1. Atribuição inicial de pesos;
2. Cálculo da atualização dos pesos de acordo com a Equação (3.33); e
3. Avaliação do erro, propagando os padrões na rede:
 - Se o erro aumentou desfaça a atualização de w e diminua μ ;
 - Senão valide a atualização w e incremente μ ;
 - Se convergir para um valor de MSE pré-determinado, encerre;
 - Senão volte para 2.

3.14 Rede de Funções de Base Radial

Uma rede neural de funções de base radial (RBF) consiste em três camadas; a camada de entrada, a camada oculta e a camada de saída (LEE; KO, 2009). Segundo (LIMA; GUER-REIRO, 2011) na camada de entrada, os neurônios não realizam qualquer computação, servindo apenas como unidades sensoriais de captação dos dados de entrada. A camada intermediária ou oculta realiza o mapeamento não-linear do espaço de entrada utilizando a função gaussiana

e a camada de saída que fornece a resposta da rede ao padrão apresentado (THEODORIDIS; KOUTROUMBAS, 2006).

Cada neurônio da camada oculta é totalmente conectado aos neurônios de entrada e de saída. As conexões entre os neurônios ocultos e os neurônios de entrada não possuem pesos sinápticos. A camada de saída é linear e fornece o somatório das saídas dos neurônios da camada oculta.

A função de transferência dos neurônios da camada oculta são funções não lineares gaussianas. O conhecimento de cada neurônio oculto é determinado pelo seu centro, ou seja, um vetor com dimensão igual ao dos vetores de entrada.

Assim, uma rede geral RBF é simplesmente uma combinação ponderada linear de um conjunto de funções de base normalmente Gaussiana (ASIRVADAM; MCLOONE; IRWIN, 2003), conforme a Equação 3.38.

$$\hat{y} = \sum_{i=1}^m w_i G_i + b = \sum_{i=1}^m w_i \exp\left(-\frac{\|x - c_i\|^2}{2\sigma_i^2}\right) + b \quad (3.38)$$

onde:

\hat{y} - saída com o sinal predito;

w_i e G_i - peso e função Gaussiana do neurônio i , respectivamente;

$x = [x_1, \dots, x_n]$ vetor de entrada com n entradas;

i e m - i -ésimo centro e números de centros, respectivamente;

b - bias opcional;

c_i e σ_i - centro e a largura da função G_i , respectivamente; e

$\|\cdot\|$ - norma Euclideana.

As redes neurais RBF são muitas vezes referidas como estimadores livres de modelo uma vez que elas podem ser utilizadas para aproximar as saídas desejadas sem a necessidade de uma descrição matemática de como as saídas funcionalmente dependem das entradas (YUN et al., 2008). No entanto, otimizar a estrutura da RBF é ainda um trabalho desafiador.

Neste trabalho foi adotado que ao apresentar cada amostra à rede, se a amostra não estivesse no raio de algum dos centros, seria então criado um novo centro com aquela amostra. A primeira amostra apresentada cria um centro.

Existem vários métodos para a escolha do número m de centros. Eles incluem a seleção aleatória de centros fixos, a seleção auto-organizada de centros, a seleção supervisionada dos centros e a interpolação regularizada explorando a conexão entre a rede RBF e a regressão de núcleo de Watson-Nadaraya (HAYKIN, 2001; ASIRVADAM; MCLOONE; IRWIN, 2003).

3.15 Considerações Finais Deste Capítulo

Este capítulo apresentou uma breve introdução dos conceitos da teoria de redes neurais, o modelo de rede neural perceptron multi-camadas e a rede de funções de base radial utilizadas neste trabalho.

O próximo capítulo apresenta uma revisão das aplicações de RNA na gestão de recursos florestais. São mostradas diversas aplicações que vão desde as estimativas de medidas de árvores, manejo florestal, detecção de doenças até previsões climáticas.

REDES NEURAIS NA ÁREA FLORESTAL

“A natureza esconde seu segredo porque
é sublime, não por astúcia.”

Albert Einstein

4.1 Introdução

Por muitos anos, os pesquisadores e os gestores de recursos florestais utilizaram modelos estatísticos empíricos ou modelos matemáticos complicados para prever as consequências dos regimes de manejo ou ações, e para auxiliar na tomada de decisão. Esses modelos são expressos como equações matemáticas. No entanto, alguns processos de tomada de decisão contêm componentes qualitativos que não se prestam a ser integrados em equações matemáticas.

A tomada de decisão em recursos naturais, muitas vezes leva à complexidade fora do alcance das técnicas estatísticas empíricas e requer abordagens que são às vezes mais do que heurística de algoritmos. Em muitos casos, os modelos estatísticos não podem ser usados para resolver os problemas mais estruturados na gestão de recursos florestais.

A aplicação da inteligência artificial (IA) na floresta e manejo dos recursos naturais começou com o desenvolvimento de sistemas especialistas para a resolução de problemas e tomada de decisão.

Nos últimos anos, o interesse na utilização de redes neurais artificiais (RNA) tem crescido em vários campos, e também emergiu como uma abordagem alternativa para a modelagem de fenômenos não-lineares e complexos das ciências florestais.

A capacidade potencial preditiva da RNA, com base em algum aprendizado supervisionado e treinamento, pode oferecer soluções ótimas para os problemas de manejo de recursos florestais.

Este capítulo apresenta uma revisão das aplicações de RNA na gestão de recursos florestais. São mostradas diversas aplicações que vão desde as estimativas de medidas de árvores, manejo florestal, detecção de doenças até previsões climáticas. Finalmente, são realizadas as considerações finais deste capítulo.

4.2 Estimativa de Diâmetros, Alturas e Volumes de Árvores

As Redes Neurais Artificiais (RNA) têm sido utilizadas na modelagem florestal para estimar diversos parâmetros das árvores tais como diâmetro, altura, volume e outros.

Em (LEDUC et al., 2001) as RNAs foram utilizadas para gerar uma distribuição de probabilidade de Diâmetro na Altura do Peito (DAP) para classificar as árvores. Como entrada foram utilizados idade, altura média das árvores dominantes, número de árvores por acre e identificador de sítio.

(HUANG et al., 2009) utilizaram as RNAs para encontrar uma distribuição de frequência de classes de diâmetros do tronco a partir dos diâmetros máximo relativo e médio e do coeficiente de variação.

(XIAO; CARANDE; GHIGLIA, 1998; BRANDÃO, 2007; RANSON et al., 2007; SILVA et al., 2008) previram as alturas das árvores a partir do DAP, da idade e de outras estatísticas utilizando as redes neurais artificiais.

No trabalho de (DIAMANTOPOULOU, 2005a) foram realizadas previsões de diâmetros das árvores *fir*¹ utilizando redes neurais artificiais. Foram usados como entradas os diâmetros do toco e da altura do peito e a altura total das árvores. A rede possui 8 saídas que forneciam os diâmetros entre 5,3 a 33,3 em intervalos de 4 em 4 metros. Os resultados obtidos foram satisfatórios, pois as árvores *fir* possuíam formas bastante regulares muito próximas de cones.

Nos trabalhos de (DIAMANTOPOULOU, 2005b; DIAMANTOPOULOU, 2006; GÖRGENS, 2006; BALEIRO, 2007; GÖRGENS et al., 2009; SILVA et al., 2009, 2009; DIAMANTOPOULOU; MILIOS, 2010; ÖZÇELIK et al., 2010) as redes neurais foram utilizadas

¹As árvores *fir*, também chamadas de pinheiros, são coníferas do gênero *Pinus*, da família Pinaceae. A maioria são nativas do Hemisfério Norte, porém, são cultivadas desde as Américas até a Eurásia. No Brasil também são chamados pinheiros, espécies que na verdade não fazem parte da família Pinaceae, como a Araucária. (RICHARDSON; RUNDEL, 1998)

para estimar os volumes de árvores. Nesses trabalhos, as entradas utilizadas foram os DAPs e as alturas totais das árvores. Um inconveniente nesses trabalhos é que as árvores possuíam formas mais cilíndricas, com o DAP e a altura total semelhantes, mas com características de afilamento diferentes, resultaram em volumes iguais.

4.3 Classificação das Áreas e Mapeamento

Uma das aplicações mais comuns de redes neurais em sensoriamento remoto é a classificação. Mapeamento de áreas ecológicas e classificação desempenham um papel importante na gestão dos recursos naturais.

As RNAs são uma alternativa para a construção de um sistema de simulação baseado em computador para a classificação das áreas (HUANG; LIPPMANN, 1987; HEPNER; RITTER, 1990; HEPNER et al., 1990; CIVCO, 1993; GONG; CHEN, 1996).

(DECATUR, 1989) aplicou redes neurais para classificar terrenos a partir de imagens de Radar de Abertura Sintética (SAR).

(CAMPBELL; HILL; CROMP, 1989; MCCLELLAND et al., 1989; HEPNER et al., 1990; DOWNEY et al., 1992) utilizaram as redes neurais para classificar a cobertura do solo a partir dos dados de Satélites Mapeadores Temáticos *LandSat*. Eles encontraram em diferentes graus que a abordagem de redes neurais foi mais precisa do que a classificação estatística tradicional.

(ATKINSON; TATNALL, 1997) apontaram que uma vantagem significativa das redes neurais é a habilidade de combinar os dados de diferentes fontes para a mesma classificação.

Vários estudos testaram a habilidade das redes neurais para classificar os dados espaciais multi-fonte. Por exemplo, (BENEDIKTSSON; SWAIN; ESROY, 1990) utilizaram imagens de redes de digitalizadores multi-espectrais Landsat (MSS) e três conjuntos de dados topográficos (inclinação, elevação e de aspecto) para classificar a cobertura vegetal.

(PEDDLE et al., 1994) aplicaram a abordagem de rede neural para classificar a cobertura do solo nas regiões dos Alpes a partir dos dados de sensoriamento remoto multi-fonte.

(GONG; CHEN, 1996) testaram a viabilidade da aplicação de uma MLP para sistemas de mapeamento de terras utilizando dados digitais de elevação e cobertura florestal.

4.4 Crescimento de Floresta e Modelagem Dinâmica

Modelos de crescimento florestal que descrevem a dinâmica florestal (por exemplo, a regeneração, o crescimento, a sucessão, a mortalidade e a sobrevivência) têm sido amplamente utilizados no manejo florestal para atualizar o inventário, prever o rendimento de futuras florestas e avaliar a composição de espécies e a estrutura e função do ecossistema sob as mudanças das condições ambientais.

Apesar dos diversos avanços em desenvolvimento e em modelos de crescimento individuais de árvores, os componentes da mortalidade de árvores foram simplificados (usando distribuições de probabilidade aleatória), produzindo modelos de crescimento e rendimento, com grande variabilidade e viés de projeção maior em suas previsões (GERTNER, 1989).

Muito progresso tem sido realizado desde o início da utilização de RNA para modelar a mortalidade individual de árvores no trabalho de Guan e Gertner (1991b). No mesmo ano, (GUAN; GERTNER, 1991a) desenvolveram com sucesso um modelo, baseado em RNA, para prever a sobrevivência de pinheiros vermelhos (*Pinus resinosa*). Eles descobriram que o modelo de sobrevivência do pinheiro vermelho baseado em RNA não só se ajustou melhor aos dados do que um modelo estatístico, mas também tiveram melhor desempenho em dados novos. O modelo foi também flexível o suficiente para modelar os pinheiros vermelhos pequenos e grandes e de crescimento lento. Sua abordagem foi melhorada por (GUAN; GERTNER, 1991a) com a integração de um algoritmo de treinamento adequado e uma plataforma computacional para modelar a probabilidade de sobrevivência individual da árvore.

Por outro lado, (HASENAUER; MERKL, 1997) demonstraram uma aplicação de redes neurais não supervisionadas para prever a mortalidade de árvores individuais dentro de modelos de crescimento e rendimento na Áustria. Eles descobriram que as redes neurais foram ligeiramente melhores do que um modelo de mortalidade estatística convencional com base na abordagem **LOGIT**².

(GUAN; GERTNER; PARYSOW, 1997) propuseram um *framework*³ para avaliar a qualidade de previsão de processos baseados em modelagem automatizada de crescimento de florestas. O método consiste de quatro passos:

1. assumir distribuições para valores de parâmetros;
2. parametrizar critérios de seleção;

²Modelo de Regressão Logística, também chamado de modelo logístico.

³Um *framework* ou arcabouço em desenvolvimento de software é uma abstração que une códigos comuns entre vários projetos de software provendo uma funcionalidade genérica.

3. descrever modelos de comportamento por meio de amostragem; e
4. aproximar o modelo baseado em comportamento aos pontos amostrados.

Esse método proposto foi aplicado a um modelo de crescimento florestal baseado em equilíbrio de carbono desenvolvido por (VALENTINE, 1988) e tem demonstrado ser efetivo em analisar modelos grandes e complexos.

(MOOSAVIZADEH-MOJARRAD; SEPASKHAH, 2011) desenvolveram um modelo com RNA para prever a curva de retenção de água pelo solo.

4.5 Análise de Dados Espaciais e Modelagem de Sistemas de Informação Geográfica (GIS)

A aplicação mais geral de GIS⁴ é a análise de dados espaciais de várias fontes. Há mais de 23 anos desde que (RITTER; LOGAN; BRYANT, 1988) propuseram pela primeira vez a idéia de integrar técnicas de rede neural artificial com Sistemas de Informação Geográfica (GIS). Desde então, uma grande variedade de pesquisas tem sido realizadas para explorar o potencial de aplicabilidade de redes neurais para a análise de dados espaciais (GONG, 1996; SUI, 1994).

(SUI, 1994) forneceu uma visão abrangente da utilização de RNA no manuseio de dados espaciais e agrupou as aplicações recentes em duas categorias principais:

1. aplicações de redes neurais para sensoriamento remoto; e
2. aplicações que integram redes neurais com GIS para a modelagem espacial.

4.5.1 Processamento de imagens de satélite

Durante a última década tem aumentado consideravelmente a disponibilidade de grandes quantidades de dados de sensoriamento remoto e utilização de redes neurais.

Isso proporciona a oportunidade de testar a capacidade das redes neurais, em particular a Perceptron Multi-Camadas (MLP) e comparar o desempenho de determinadas redes neurais com outros métodos tradicionais de processamento de imagem de satélite (ATKINSON; TAT-NALL, 1997).

⁴GIS - *Geographic Information System*, do acrônimo inglês ou SIG - Sistema de Informação Geográfica

(RYAN et al., 1991) desenvolveram uma rede MLP para delinear linhas costeiras do Landsat-TM (mapeador temático) de dados. Eles demonstraram que a rede neural poderia ser treinada para distinguir a terra da água utilizando os dados Power Ring Espectral (PRS).

Os trabalhos anteriores de Heermann e Khazenie (HEERMANN; KHAZENIE, 1992), Pierce, Sarabandi e Ulaby (PIERCE; SARABANDI; ULABY, 1992), (WILKINSON et al., 1992; JAN, 1997) mostraram que as Redes Neurais Artificiais (RNA) têm sido aplicadas com sucesso à classificação de dados de sensoriamento remoto multi-espectral.

A abordagem de RNA também tem sido usada para obter os comprimentos de correlação e variância de superfície áspera (YOSHITOMI et al., 1993); para reconstruir os parâmetros de neve (TSANG et al., 1992); para estimar o Índice de Área Foliar (LAI) e para recuperar a biomassa, incluindo a altura do dossel⁵, o teor de água do dossel e a fração de matéria seca de dados de sensoriamento remoto de alta dimensionalidade ativa/passiva (JIN; 1997, 1997).

(ZHANG; LI; YUAN, 1997) relataram a utilização de uma rede neural *back-propagation* supervisionada (BPNN) para identificar os tipos de vegetação a partir de imagens de satélite mapeador temático (TM) na parte norte da área das montanhas brancas no Arizona. Eles descobriram que a rede neural produziu uma média correta de cerca de 94% nas áreas do terreno mais complexo, e o custo e o tempo associado com a abordagem de rede neural foi muito menor do que das técnicas tradicionais.

(PIJANOWSKI et al., 2002) usaram os dados de Landsat-TM, acoplados a um sistema de informações geográficas (GIS) e de redes neurais para prever as mudanças de utilização de terra.

As RNAs foram aplicadas por (PRADHAN; LEE; BUCHROITHNER, 2010) para estimar a ocorrência de deslizamentos de terra na Malásia. Foi usado um banco de dados espacial relacionado com o deslizamento de terra que foi construído a partir de dados do solo, topografia, geologia e mapas de cobertura da terra.

4.5.2 Modelagem espacial com GIS

Uma pesquisa recente mostrou que o acoplamento de RNA com GIS tem melhorado significativamente a capacidade de modelagem de GIS para a tomada de decisão espacial (Peuquet 1991; Sui 1993).

No trabalho pioneiro de (WANG, 1992), ele melhorou com sucesso a capacidade de mode-

⁵Dossel florestal é o estrato superior das florestas, onde atinge de 30 a 60 m de altura, e diversos autores indicam guardar as maiores biodiversidades do planeta, contendo segundo estimativas, até 65% das formas de vida das florestas tropicais (RIBEIRO; CORBARA, 2005).

lagem de dados espaciais de GIS para a análise de sustentabilidade de terras, integrando uma rede neural em um ambiente GIS.

Em um estudo semelhante ao de Wang, (SUI, 1993) foi integrada uma rede neural artificial *back-propagation* padrão com GIS para desenvolver uma análise de sustentabilidade. Ele demonstrou que a rede neural baseada em abordagem de modelagem GIS pode aproximar de uma decisão de especialista sem a elicitação explícita do conhecimento de especialistas na produção de regras se-então. Para a análise de sustentabilidade, foi relatado por (ZHOU; CIVCO, 1996) um trabalho adicional de acoplamento de redes neurais de aprendizagem genética com GIS.

(DEADMAN; GIMBLETT, 1997) forneceram um exemplo da utilização de redes neurais e GIS para o desenvolvimento de planos de manejo de vegetação.

Como concluiu (SUI, 1994):

“Embora a plena integração de redes neurais com GIS ainda está muito distante, essas investigações iniciais têm demonstrado o impacto profundo que as redes neurais podem ter sobre o GIS. Obviamente, a integração de redes neurais com o GIS para a análise espacial e a modelagem é uma área muito importante de pesquisa que irá contribuir significativamente para o desenho da próxima geração de GIS”.

Masa et al. (2004) pesquisaram uma abordagem baseada em RNAs para modelar desmatamento a partir de dados de GIS do estado de Campeche, sudeste do México.

4.6 Dinâmica de Doenças de Plantas e Manejo de Insetos-Pragas

Doenças de plantas e insetos-pragas são questões importantes para os gestores de recursos. Para reduzir as perdas causadas por doenças de plantas, os gestores de recursos florestais precisam de informações sobre a dinâmica da doença.

Tradicionalmente, os epidemiologistas botânicos têm desenvolvido modelos de simulação para prever doenças utilizando métodos estatísticos (por exemplo, modelos de crescimento logístico) e modelos de simulação matemática.

Esses modelos são baseados em relacionamentos que descrevem processos-chave da diversidade dos sistemas biológicos. O grande desafio para os modelos de simulação tradicional é que as relações matemáticas que descrevem cada processo do sistema de simulação têm que ser conhecidas. Esta limitação afeta o progresso de previsão de doenças e se incorreto pode causar

erros nos modelos de simulação. Novas técnicas de Inteligência Artificial (IA) como RNA pode ajudar a ultrapassar esse problema. Por exemplo, (YANG; BATCHELOR, 1997) têm utilizado com sucesso redes neurais *feed-forward* de três camadas para prever a dinâmica de doenças de plantas. Eles concluíram que as redes neurais podem ser uma ferramenta poderosa para a previsão de doenças de plantas e detectar padrões de doenças em diferentes escalas espaciais e temporais.

Outros estudos similares usando técnicas de RNA para prever o desenvolvimento da doença (YANG; BATCHELOR; TSCHANZ, 1995; BATCHELOR; YANG; TSCHANZ, 1997), umidade foliar (FRANCL; PANIGRAHI; PAHDI, 1995; FRANCL; PANIGRAHI, 1997) e manejo de insetos-pragas (MCCLENDON; BATCHELOR, 1995) apareceram na literatura científica.

Em (FROSSYNIOTIS et al., 2008) utilizaram uma RNA baseada em perceptron multi-camadas para detectar vírus em plantas. A rede utilizou dados de um sistema baseado no método de reconhecimento de ensaio bioelétrico (BERA) para a detecção de vírus, desenvolvido por sua equipe. Sensores BERA detectam a resposta elétrica de culturas de células suspensas em uma matriz de gel, como resultado de sua interação com as células do vírus, tornando assim possível a sua identificação (FROSSYNIOTIS et al., 2008).

Nos trabalhos de (BASHISH; BRAIK; BANI-AHMAD, 2011; AL-HIARY et al., 2011) foram desenvolvidos métodos de classificação de doenças foliares de diversas plantas.

(N.A; KHALID; BORHAN, 2011) utilizaram uma abordagem de rede neural dinâmica hierárquica para classificar doenças em plantas a partir de imagens filtradas com regressores de núcleo.

4.7 Pesquisa em Mudanças Climáticas

Embora a mudança climática seja uma área de pesquisa muito ativa no conteúdo da mudança global e sustentabilidade, foi somente nas últimas décadas que os pesquisadores começaram a usar as redes neurais para prever eventos climáticos, avaliar os impactos das mudanças climáticas sobre o crescimento das árvores, e reconstruir os padrões climáticos prévios. Por exemplo, (COOK; WOLFE, 1991) desenvolveram pela primeira vez uma rede neural *back-propagation* para predizer a temperatura média do ar, com três meses de antecedência. Eles obtiveram bons resultados utilizando pequenos conjuntos de dados em locais específicos.

(COOK; WOLFE, 1991) também demonstraram o potencial das redes neurais para fornecer as entradas estocásticas de clima necessárias para muitas aplicações de modelagem. Na

escala global, (DERR; SLUTZ, 1994) aplicaram uma rede neural *back-propagation* para prever as temperaturas da superfície do mar como um indicador de eventos do *El Niño* usando grandes conjuntos de dados de oceanos e atmosfera de 1884 até o presente. Os resultados mostraram que para prazos de um a seis meses, a temperatura tem previsão melhor com precisão de 1°C . Relatos semelhantes podem ser encontrados em (TANGANG; HSIEH; TANG, 1997; TANGANG et al., 1998). A rede neural também forneceu melhores previsões para prazos mais curtos em relação ao poderoso método de persistência.

(YI; PRYBUTOK, 1996) testaram um modelo de rede neural para a previsão da concentração máxima diária de ozônio em uma área urbana industrializada e descobriram que o modelo de rede neural é superior a dois modelos de regressão que eles utilizaram para a previsão.

(KELLER, 1994) propôs a utilização de uma rede neural para aumentar a capacidade dos tradicionais métodos estatísticos para a modelagem não-linear das relações anéis-árvore/clima.

Em um estudo semelhante ao de Keller, (GUIOT et al., 1996) desenvolveram uma rede neural *back-propagation* de três camadas para calibrar as relações não-lineares entre os escores de biomas e as variáveis climáticas, que podem melhorar a precisão do mapeamento de biomassa terrestre a partir de dados de pólen.

Esse método não-linear flexível foi ainda usado para interpolar as variáveis climáticas em dados atuais de pólen utilizando longitude, latitude, altitude e elevação como entradas (PEYRON et al., 1998)

(KNUTTI et al., 2003) usaram uma RNA para estimar os intervalos para a sensibilidade climática e a força radiativa a partir de dados de aquecimento da superfície observada ao longo do período industrial e estimativas da absorção de calor do oceano global como restrições para o conjunto de dados.

(ELGAALI; GARCIA, 2004) investigaram os possíveis efeitos das mudanças climáticas nas águas superficiais de suprimentos para a irrigação na bacia do rio Arkansas com rede neural artificial (RNA).

Usando um conjunto de redes neurais, (FOX-RABINOVITZ; KRASNOPOLSKY; BELOCHITSKI, 2006) emularam os modelos físicos em modelos numéricos complexos de clima.

Em (LEE et al., 2010) foram descritos o desenvolvimento e a validação de uma RNA com a finalidade de analisar os efeitos das alterações climáticas na fonte difusa (NPS) de cargas poluidoras de pequenas bacias hidrográficas agrícolas.

Recentemente, as redes neurais foram utilizadas para avaliar e estimar a concentração de

pólen no ar (AZNARTE M. et al., 2007) e na atmosfera (RODRÍGUEZ-RAJO et al., 2010).

4.8 Outras Aplicações

No entanto, existe uma série de outras aplicações potenciais e RNAs no manejo dos recursos naturais, incluindo o uso de redes neurais para prever a qualidade da água (MAIER; DANDY; BURCH, 1998), a condutividade hidráulica do solo (TAMARI; WÖSTEN; RUIZ-SUÁREZ, 1996), o carbono do solo em molissolos (LEVINE; KIMES, 1997) e as mudanças do *pH* nos lagos canadenses orientais acidificados (EHRMAN; CLAIR; BOUCHARD, 1996).

Por exemplo, (VEGA-GARCIA et al., 1996) usaram uma rede neural *back-propagation* para prever a ocorrência de incêndio causado pelo homem na Floresta Provincial Whitecourt de Alberta, no Canadá. Eles descobriram que a RNA foi capaz de prever 85% de observações não-fogo e 87% das observações fogo. Recentemente, (SAFI; BOUROUMI, 2011) utilizaram uma rede neural *back-propagation* para prever incêndios em florestas no parque natural português de Montesinho.

Técnicas de RNAs também têm sido aplicadas em ecossistemas aquáticos (RECKNAGEL et al., 1997; MAIER; DANDY; BURCH, 1998), bem como na agricultura (VERDENIUS; TIM-MERMANS; SCHOUTEN, 1997; FRANCL; PANIGRAHI, 1997).

4.9 Considerações Finais Deste Capítulo

Este capítulo apresentou uma revisão de aplicações de RNA na gestão de recursos florestais e ambientais. Foram mostradas diversas aplicações que vão desde as estimativas de medidas de árvores, manejo florestal, detecção de doenças até previsões climáticas.

O próximo capítulo apresenta o modelo proposto neste trabalho. São apresentados alguns métodos tradicionais da engenharia florestal para comparação, bem como os métodos estatísticos utilizados para validar o modelo proposto.

MODELO DE ESTIMATIVA DE DIÂMETROS COM REDES NEURAIS

“Nenhum cientista pensa com fórmulas.”

Albert Einstein

5.1 Introdução

Como foi citado no Capítulo 2 deste trabalho, os troncos de muitas espécies de árvores apresentam formas semelhantes a algum sólido geométrico definido - os protótipos dendrométricos. Entretanto, (LOETSCH; ZOHRER; HALLER, 1973) afirmam que os troncos nunca se identificam com um único protótipo dendrométrico, pois em um mesmo tronco podem ocorrer várias formas, além disso, a transição de uma forma para outra não pode ser exatamente determinada.

Assim, diversas metodologias foram desenvolvidas com a finalidade de estimar os diâmetros das árvores sem a necessidade de determinar os tipos de protótipos dendrométricos que elas se aproximariam. Neste capítulo é apresentado o modelo proposto neste trabalho. É apresentado também alguns dos métodos tradicionais que são utilizados para fins comparativos, bem como os métodos estatísticos usados para validar o modelo proposto.

5.2 Predição de Diâmetros

A predição de diâmetros pode ser tratada como um problema de predição de séries, comumente utilizadas em séries temporais (JI et al., 2005). Assim, pode ser considerada como

um problema de modelagem. Para a predição, um modelo é construído entre as entradas e as saídas. Este modelo é utilizado para prever os próximos valores baseados nos valores prévios. A predição direta e a recursiva são alguns dos métodos aplicados na predição de longa duração (JI et al., 2005).

Na predição direta são construídos $M + 1$ modelos diferentes para estimar os valores de uma série. A Equação (5.1) apresenta uma representação de modelos de predição direta.

$$\hat{d}_{i+m} = f_m(d_{i-1}, d_{i-2}, \dots, d_{i-n}), \quad (5.1)$$

onde:

f_m - modelo f para a predição m ;

d_i - diâmetro na altura i ;

m - $0, 1, \dots, M$;

M - horizonte máximo da predição;

i - altura específica; e

n - tamanho do regressor.

As variáveis de entrada do lado direito da Equação (5.1) definem o regressor.

A predição recursiva é realizada primeiro fazendo a predição um passo adiante, conforme a Equação (5.2).

$$\hat{d}_i = f(d_{(i-1)}, d_{(i-2)}, \dots, d_{(i-n)}) \quad (5.2)$$

Para prever o próximo valor da série, utiliza-se também a Equação (5.2), porém o primeiro valor dessa equação é o resultado dela no passo anterior, como mostrado na Equação (5.3).

$$\hat{d}_{(i+1)} = f(\hat{d}_i, d_{(i-1)}, d_{(i-2)}, \dots, d_{(i-n+1)}). \quad (5.3)$$

Assim, pode-se verificar que as principais diferenças entre a predição direta e a predição recursiva são:

- Na predição direta

- as entradas são fixas em todas as previsões;
- é necessário construir tantos modelos quantos sejam o número de valores a serem preditos; e
- os valores da série são comumente estimados todos de uma só vez;
- Na previsão recursiva
 - as entradas são substituídas a cada nova previsão;
 - é necessário construir apenas um único modelo para todos os valores a serem preditos; e
 - os valores da série são estimados um a um, uma vez que a estimativa de um valor depende do conhecimento dos valores anteriores.

As previsões direta e recursiva apresentam vantagens e desvantagens. Na previsão direta, como cada passo estimado possui um modelo específico, e suas entradas são fixas, um erro de estimativa em um passo não interfere nos demais. Porém, como existe a necessidade de criar um modelo para cada passo, existe a necessidade de definir o horizonte de previsão para estabelecer o número de modelos que serão criados. Outro aspecto é que as estimativas estão sempre baseadas nas mesmas entradas, e portanto, séries com valores iniciais com poucas diferenças poderão ter estimativas muito semelhantes uma vez que o modelo poderá ter uma tendência pré-determinada.

Na previsão recursiva, como todos os passos são estimados utilizando apenas um único modelo e as entradas são modificadas a cada estimativa de modo ao usar os valores recém preditos para estimar o valor do próximo passo, não existe necessidade de limitar o horizonte de previsão, além das séries com valores iniciais com poucas diferenças a serem tratadas de formas diferentes, já que não existe uma tendência pré-determinada. Porém, como os valores de entrada do modelo são substituídos por valores estimados ao longo da estimativa da série, erros de previsão em um passo são repassados aos demais passos gerando um efeito cascata.

No trabalho de (DIAMANTOPOULOU, 2005a) foi apresentado um método de estimativa de diâmetros de Pinheiros (*fir*) com uma MLP. O método consiste em construir uma rede perceptron multi-camadas com 8 saídas que forneciam os diâmetros entre 5,3 a 33,3 em intervalos de 4 em 4 metros. As entradas utilizadas foram o diâmetro do toco ($d_{0,3}$), o diâmetro na altura do peito - DAP ($d_{1,3}$) e a altura total (H_t).

Os resultados obtidos no trabalho de Diamantopoulou foram muito satisfatórios. Porém, é importante ressaltar que os Pinheiros (*fir*) possuem formas cônicas muito bem definidas. Assim,

entre cada par de diâmetros estimados é possível encontrar a formação de retas. Com isto, intervalos de 4 metros não causariam erros perceptíveis e permitiria reduzir significativamente o número de saídas da rede neural. Deve-se considerar ainda que, a MLP proposta com 8 saídas limita a estimativa de diâmetros mais altos das árvores a 33,3 metros. Além disso, a rede com 8 saídas, equivale a 8 modelos de entradas fixas, ou seja, um modelo de predição direta, e portanto, incorre em estimar valores semelhantes para árvores com parâmetros semelhantes.

Assim, para os Pinheiros (*fir*) o método de Diamantopoulou mostrou-se muito eficiente, uma vez que o protótipo dendrométrico enquadrou-se bem nesse tipo de abordagem. Porém, sua aplicação em eucaliptos, infelizmente não proporcionaria os mesmos resultados, considerando-se que os eucaliptos possuem formas muito diferentes, mesmo com os parâmetros iniciais semelhantes. Outro problema é que existe uma variedade muito grande de altura entre os eucaliptos. Assim, para algumas árvores, com alturas inferiores a 33,3 algumas saídas da MLP ofereceriam valores sem utilidade, e para árvores com alturas superiores a 33,3 existiria uma porção da árvore que não seria estimada e por exemplo, inviabilizaria algumas atividades como obter o volume total da árvore, por exemplo.

5.3 O Modelo Proposto

Diante da variedade de formas dos eucaliptos mesmo com diâmetros iniciais e altura total semelhantes, da variedade das formas geométricas existentes em uma só árvore, a variedade de altura total das árvores de um povoamento e a necessidade de mais diâmetros para a captura do neilóide da árvore este trabalho propõe a utilização da MLP de forma recursiva para estimar os diâmetros de eucaliptos.

Como o modelo proposto é recursivo, as entradas são substituídas ao longo da predição por valores recém estimados. As entradas iniciais da MLP utilizadas foram os diâmetros $d_{0,3}$ (diâmetro do toco), $d_{0,7}$ e $d_{1,3}$ (*DAP*). As medidas de diâmetros iniciais são usadas para prever o diâmetro $d_{2,0}$. Em seguida, as medidas $d_{0,7}$, $d_{1,3}$ e a $d_{2,0}$ estimada são utilizadas para prever a medida $d_{3,0}$, e assim sucessivamente. Todas as estimativas foram realizadas obedecendo o espaçamento de 1 em 1 metro como recomendado por (SCOLFORO; MELLO; LIMA, 1994). A predição dos diâmetros é realizada até que seja atingida a altura total da árvore. São adotadas neste trabalho duas abordagens para o critério de parada do processo de estimativa de diâmetros para cada árvore. A primeira abordagem estima os diâmetros até que a altura máxima da árvore seja atingida. A segunda abordagem estima os diâmetros até que o valor de uma estimativa seja menor ou igual a um valor pré-determinado.

5.4 Materiais e Métodos

5.4.1 Localização e caracterização da área de coleta dos dados

A área onde foram coletados os dados para este estudo é de propriedade da Empresa Aracruz Celulose S.A., localizada no município de Aracruz na região metropolitana do estado do Espírito Santo, como mostrado na Figura 5.1. De acordo com (GOLFARI; CASER; MOURA, 1978) na região do município de Aracruz, predominam solos do tipo Latossolo Amarelo, com horizonte A moderado, textura média e relevo plano. O clima segundo a classificação de Köppen é, AW, clima tropical úmido, com estação chuvosa no verão e seca no inverno.

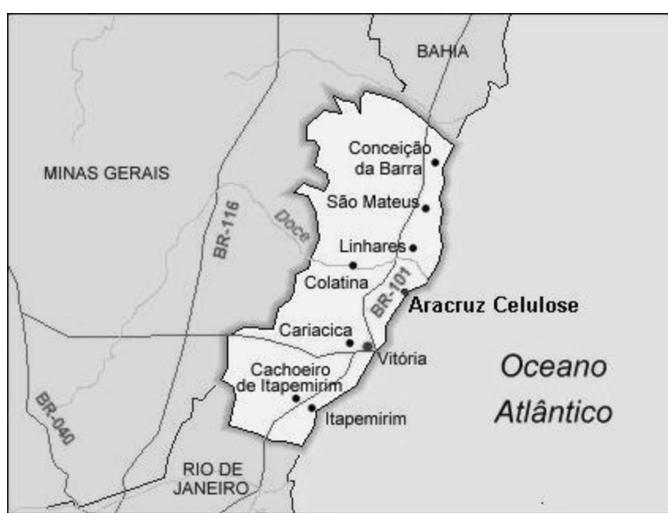


Figura 5.1: Mapa do estado do Espírito Santo mostrando a localização da empresa Aracruz Celulose S.A. Fonte: (CABACINHA, 2003).

5.4.2 Dados

Os dados utilizados neste estudo foram obtidos em 16 parcelas circulares de $360\ m^2$ lançadas aleatoriamente em um sítio florestal plantado com clones de eucalipto, com espaçamento $3 \times 3\ m$. As 615 árvores amostradas nas parcelas foram cubadas rigorosamente pelo método de Smalian (CABACINHA, 2003). Durante a cubagem foram medidos, com sutas, os diâmetros nas alturas 0,10; 0,30; 0,50; 0,70; 0,90, 1,10; 1,30; 2,00 m em relação ao solo, no restante do tronco em intervalos de 1 em 1 m e o diâmetro no topo da árvore é considerado igual a zero cm. Os diâmetros nas alturas $h_{0,3}$ e $h_{1,3}$ são conhecidos como diâmetro do toco e diâmetro na altura do peito (*DAP*), respectivamente.

A Figura 5.2 ilustra como as árvores foram medidas.

Vários autores afirmam que diversas características das árvores variam de acordo com o

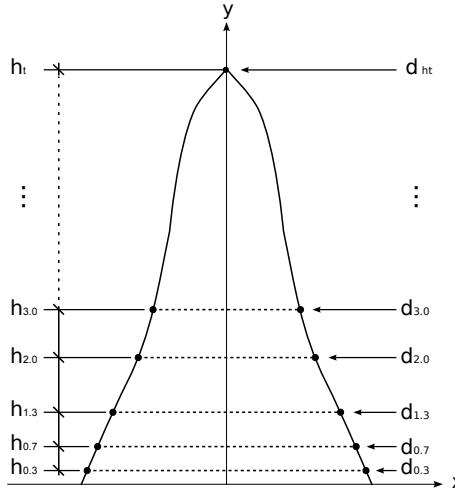


Figura 5.2: As alturas medidas e seus respectivos diâmetros.

DAP. Devido a isso, vários trabalhos têm separado as árvores em classes diamétricas baseadas no *DAP* em amplitudes de 4 ou 5 cm (SCHNEIDER et al., 1996; PIRES; CALEGARIO, 2007).

Neste trabalho, as árvores foram separadas de acordo com a medida do *DAP* em 5 classes em intervalos de 3 cm e criou-se uma MLP para treino e predição de cada uma dessas classes diamétricas. Apenas a classe 5 foi ampliada para inserir uma única árvore que estava isolada. A Tabela 5.1 mostra a frequência de indivíduos, as estatísticas dos *DAPs* e as alturas das árvores por classe utilizadas nesta tese.

Tabela 5.1: Estatísticas descritivas das árvores do gênero *Eucalyptus*.

Classe	Limites		n ¹	Autocorr(d_i)		DAP(cm)				Altura Total (H_t) (m)					
	Inf.	Sup.		Min	Max	Média	Var ²	DP ³	Min	Max	Média	Var ²	DP ³	Min	Max
1	7,15	10,15	14	0,63	0,84	8,68	0,95	0,97	7,15	10,10	17,60	3,49	1,87	14,20	19,70
2	10,15	13,15	106	0,77	0,87	12,01	0,54	0,73	10,32	13,14	22,83	2,75	1,66	18,00	26,70
3	13,15	16,15	302	0,78	0,89	14,62	0,68	0,82	13,15	16,14	25,74	1,57	1,25	18,40	29,40
4	16,15	19,15	178	0,83	0,90	17,23	0,64	0,80	16,15	19,14	27,52	1,39	1,18	24,20	30,10
5	19,15	25,15	15	0,82	0,90	20,21	1,7	1,31	19,31	24,55	29,23	1,06	1,03	27,20	30,60

¹Número de árvores na classe, ²Variância, ³Desvio Padrão

O modelo de MLP proposto neste trabalho baseou-se na relação entre os 3 diâmetros vizinhos utilizados como entrada e a rede prevê o próximo diâmetro em sua saída. Com a finalidade de verificar a relação da medida de um diâmetro com seus diâmetros vizinhos, foi calculado o coeficiente de autocorrelação utilizando-se a Equação (5.8). O cálculo da autocorrelação foi realizado para cada árvore com deslocamentos de 1 a 3. A Tabela 5.1 mostra o menor e o maior coeficientes de autocorrelação para 1 deslocamento em cada classe.

Os resultados obtidos nos testes de autocorrelação realizados para 1 deslocamento apresentaram valores bastante altos. Pode-se verificar na Tabela 5.1 que a menor e a maior au-

Tabela 5.2: Recursos computacionais utilizados neste trabalho.

Processador	Intel Core i5 - 1ª Geração
Memória RAM	4 GB
Disco Rígido	500 GB
Sistema Operacional	Ubuntu Linux 11.10 (Oneiric Ocelot)
Ferramenta de Programação	Matlab R2011b (7.13.0.564) 32-bit (glnx86)

tocorrelação para 1 intervalo foram de 0,63 e 0,90, respectivamente. Enquanto no teste para 3 intervalos a menor e a maior autocorrelação foram de 0,55 e 0,81, respectivamente. Assim os testes comprovaram que existe um forte relacionamento entre os 3 diâmetros vizinhos e o próximo diâmetro a ser previsto. Observe que nas classes menores a autocorrelação é menor.

Para uma maior confiabilidade e rapidez no treinamento da MLP, os dados de diâmetros das árvores foram normalizados no intervalo de $[-1, 1]$, utilizando-se a Equação (5.4). Neste intervalo o -1 indica os diâmetros iguais a 0, o 1 é o maior diâmetro disponível na base e nesse intervalo estão os demais diâmetros (ZANCHETTIN; LUDELMIR, 2005). A normalização foi realizada em todas as árvores independente de sua classe.

$$X_{NORM} = (b - a) \cdot \left(\frac{X - \min(X)}{\max(X) - \min(X)} \right) + a \quad (5.4)$$

onde:

X_{NORM} - valor do diâmetro normalizado;

X - diâmetro da árvore;

$\min(X)$ - menor diâmetro das árvores;

$\max(X)$ - maior diâmetro das árvores; e

a e b - limites do intervalo de normalização.

Neste trabalho os valores adotados para a e b são -1 e 1 , respectivamente.

Após a MLP predizer os diâmetros das árvores, estes diâmetros foram denormalizados usando os valores de $\min(X)$ e $\max(X)$ utilizados na normalização.

A Tabela 5.2 mostra os recursos computacionais utilizados neste trabalho.

5.4.3 Arquitetura perceptron de múltiplas camadas

Como foi citado anteriormente no Capítulo 3 deste trabalho, a rede neural Perceptron de Múltiplas Camadas (MLP) é composta de uma camada de entrada, uma ou mais camadas ocultas

e uma camada de saída. O sinal de entrada propaga-se pela rede em direção à saída, camada por camada (HAYKIN, 2001). A Figura 5.3 mostra a MLP utilizada neste trabalho.

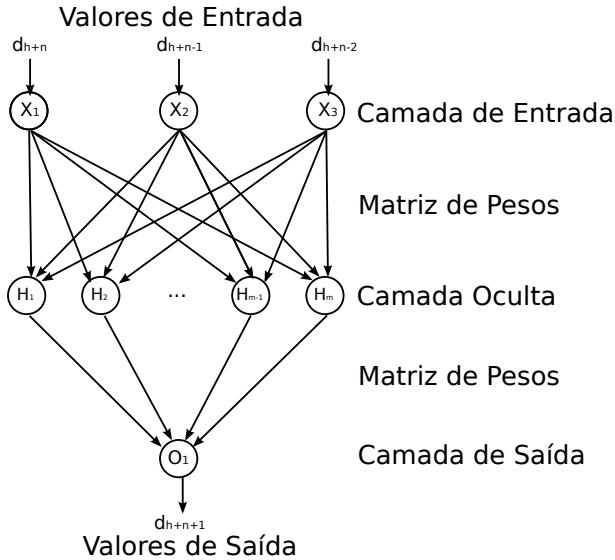


Figura 5.3: Arquitetura da MLP de três camadas.

A estrutura da MLP que mais se adequou para a predição de diâmetros das árvores foi determinada de forma empírica. A arquitetura adotada para a MLP tem uma camada de entrada com três neurônios que correspondem aos diâmetros conhecidos, uma camada oculta e a camada de saída com um neurônio cuja saída é o diâmetro a ser estimado. Todos os neurônios possuem um bias.

Diversas funções de ativação podem ser utilizadas na rede MLP (HAYKIN, 2001). (KARLIK; OLGAC, 2010) comparou o desempenho de diversas funções de ativação e os resultados das simulações mostraram que a função tangente hiperbólica apresentou maior precisão. Segundo (KARLIK; OLGAC, 2010) a rede neural obteve bons resultados quando combinadas funções de ativação tangentes hiperbólicas foram usadas para ambos os neurônios (ou nós) das camadas ocultas e de saída. Assim, a função de ativação utilizada neste trabalho nos neurônios das camadas oculta e de saída é a tangente hiperbólica. Esta função também é chamada de tan-sigmóide ou tansig e é calculada conforme a Equação (5.5).

$$\varphi(a) = \tanh(a) = \frac{2}{1 + e^{-2a}} - 1 \quad (5.5)$$

5.4.4 Treinamento da rede MLP

Neste trabalho foram realizados vários testes para encontrar a estrutura da MLP que mais se adequava à predição de diâmetro das árvores. A estrutura utilizada nesta tese possui uma

camada de entrada com três variáveis, que representam três medidas de diâmetros, uma camada oculta com $m = 20$ neurônios e uma camada de saída com um neurônio, que resulta em um valor de diâmetro estimado, como mostrado na Figura 5.3.

Para escolher o número de neurônios da camada oculta, no início, foi adotado a quantidade de 5 neurônios nessa camada. Então, esse valor foi incrementado a cada teste até que não ocorresse melhora significativa nos valores da raiz quadrada do erro médio quadrático e da correlação. A estabilização desses valores foi atingida com 20 neurônios na camada oculta.

O algoritmo de treino utilizado na MLP foi o Levenberg-Marquardt (MARQUARDT, 1963) com 1.000 épocas. Para se reduzir o espaço de busca da arquitetura ideal para o modelo proposto, todos os treinos da MLP foram realizados com pesos iniciais aleatórios e não foram utilizados parâmetros adaptativos de taxa de aprendizado e momentum.

Para evitar o *overfit*, neste trabalho foi utilizado uma adaptação do método *early stopping* (CARUANA; LAWRENCE; GILES, 2001; DOAN; LIONG, 2004; LODWICH; RANGONI; BREUEL, 2009). Nessa adaptação a heurística adotada foi estabelecer o erro médio quadrático (MSE) em 1×10^{-10} e treinar a MLP até que por 5 épocas seguidas o MSE não apresentasse redução significativa ou aumentasse. Nos testes realizados, a MLP convergiu abaixo de 150 épocas. Assim, visando simplificar o processo de treinamento, uma vez identificada a quantidade de épocas necessárias para treinar a MLP para cada classe, não foi mais necessário monitorar os valores de MSE .

A Tabela 5.3 mostra os valores de MSE e o número médio de épocas para a convergência em cada classe de árvore.

Tabela 5.3: Quantitativo de árvores e amostras para treino e estatísticas dos treinamentos da MLP por classe.

Classe	Total		Amostras		Treino	
	Árvores	Conjuntos	Árvores	Conjuntos	Épocas	MSE
1	14	231	10	155	35	$3,0 \times 10^{-4}$
2	106	2405	11	239	45	$3,0 \times 10^{-4}$
3	302	8025	31	792	120	$3,5 \times 10^{-4}$
4	178	5105	18	498	110	$3,5 \times 10^{-4}$
5	15	462	10	298	130	$5,0 \times 10^{-4}$
Total	615	16228	80	1982	-	-

Para o treino das MLP, em cada classe foram selecionadas aleatoriamente 10% das árvores ou no mínimo 10 árvores para a geração dos conjuntos de amostras de entrada e saída. Para cada uma dessas árvores foram geradas as amostras de entradas $[d_{i-2}, d_{i-1}, d_i]$ e a saída $[d_{i+1}]$. Por exemplo, no treinamento da rede, o par de entrada-saída foi $[d_{0,3}, d_{0,7}, d_{1,3}]$ e $[d_{2,0}]$, onde $d_{0,3}, d_{0,7}, d_{1,3}, d_{2,0}$ representam a distância do solo até as alturas de 0,3; 0,7; 1,3 e 2,0 metros.

O próximo par de entrada e saída foi $[d_{0,7}, d_{1,3}, d_{2,0}]$ e $[d_{3,0}]$, onde $d_{3,0}$ representa a distância do solo até a altura de 3,0 metros, e assim sucessivamente,

5.4.5 Predição recursiva de diâmetros com a utilização da altura total

Na etapa de teste das MLP foram utilizadas apenas as medidas iniciais de diâmetro $d_{0,3}$, $d_{0,7}$ e $d_{1,3}$ para prever as demais medidas de diâmetros de cada árvore. Essa etapa é realizada para cada árvore individualmente, conforme o procedimento de predição recursiva descrito na Equação (5.3). Portanto, essas medidas iniciais são utilizadas para prever o diâmetro $\hat{d}_{2,0}$. Em seguida, as medidas $d_{0,7}$, $d_{1,3}$ e a $\hat{d}_{2,0}$ (estimada) são utilizadas para prever a medida $\hat{d}_{3,0}$, e assim sucessivamente até que se atinja a altura total da árvore. Este procedimento está descrito no Algoritmo 1 apresentado na Tabela 5.4 e a Tabela 5.5 ilustra as definições utilizadas nesse algoritmo (SOARES et al., 2010; SOARES et al., 2011a; SOARES et al., 2011c).

Tabela 5.4: Algoritmo 1 de predição de diâmetros de árvore.

```

function PREVERARVORE( $d_{0,3}, d_{0,7}, d_{1,3}, H_t$ )
     $X \leftarrow [d_{0,3}, d_{0,7}, d_{1,3}]$ 
     $D \leftarrow []$ 
     $i \leftarrow 2,0$ 
    while  $i < H_t$  do
         $D_i \leftarrow \text{MLP.PREVERDIAMETRO}(X)$ 
         $X_1 \leftarrow X_2$ 
         $X_2 \leftarrow X_3$ 
         $X_3 \leftarrow D_i$ 
         $i \leftarrow i + 1.0$ 
    end while
    return  $D$ 
end function

```

5.4.6 Predição recursiva de diâmetros sem a utilização da altura total

Na predição recursiva de diâmetros sem a utilização da altura total o modelo é usado para realizar as estimativas de forma semelhante ao método mostrado na sub-seção 5.4.5 deste capítulo, porém, a diferença é que não é utilizada a altura total da árvore como critério de parada. Essa altura é uma medida que é difícil de ser obtida no campo, e geralmente ela acaba sendo estimada durante o processo de inventário florestal. Como a altura total é medida ou estimada, ela é uma medida que está sujeita a erros humanos e sua obtenção no campo acaba por tornar a atividade de inventário mais lenta e onerosa.

Tabela 5.5: Definição formal do algoritmo de predição do modelo 1.

X	O vetor de entradas da MLP;
X_1	entrada 1 da MLP;
X_2	entrada 2 da MLP;
X_3	entrada 3 da MLP;
i	altura que está sendo predita;
$d_{0,3}$	diâmetro na altura 0,3 (Diâmetro do Toco);
$d_{0,7}$	diâmetro na altura 0,7;
$d_{1,3}$	diâmetro na altura 1,3 (DAP);
D	vetor de diâmetros preditos até a altura total, na altura total o diâmetro é adotado como zero;
D_i	diâmetro estimado na altura i ;
H_t	altura total da árvore predita.

Um aspecto importante a ser considerado é que em um processo de cubagem rigorosa, os diâmetros são medidos até encontrar-se um diâmetro mínimo, e o restante da árvore, também chamado de ponta, é considerado como um cone. Esse diâmetro é chamado de diâmetro mínimo comercial. Essa medida é importante pois, ela indica o diâmetro mínimo para uma máquina manipular a madeira em suas aplicações, e o restante da ponta é utilizado frequentemente para a geração de energia. No Brasil, essa medida é frequentemente adotada como 4 cm pela indústria madeireira.

Com a finalidade de reduzir o tempo, o custo e os erros na realização dos inventários foi experimentada uma abordagem do método de estimativa recursiva sem a utilização da altura total da árvore. Nesse método, foi substituído o critério de parada da altura total da árvore pelo diâmetro mínimo comercial. Assim, as estimativas são realizadas até que seja encontrado um diâmetro menor ou igual a 4 cm (SOARES et al., 2011b; SOARES et al., 2012a; SOARES et al., 2012b).

Nessa etapa de teste da MLP, como nos testes da abordagem com a altura total, são utilizadas apenas as medidas iniciais de diâmetro $d_{0,3}$, $d_{0,7}$ e $d_{1,3}$ para prever as demais medidas de diâmetros de cada árvore. Essa etapa é realizada para cada árvore individualmente, conforme o procedimento de predição recursiva descrito na Equação (5.3). Portanto, essas medidas iniciais são utilizadas para prever o diâmetro $\hat{d}_{2,0}$. Em seguida, as medidas $d_{0,7}$, $d_{1,3}$ e a $\hat{d}_{2,0}$ estimada são usadas para prever a medida $\hat{d}_{3,0}$, e assim sucessivamente até que o diâmetro previsto seja menor ou igual a 4 cm.

A altura do diâmetro mínimo da árvore é assumida como sendo a altura do último diâmetro predito. As Tabelas 5.6 e 5.7 ilustram o algoritmo de predição com base na Equação (5.3) e as definições utilizadas nesse algoritmo, respectivamente.

Tabela 5.6: Algoritmo 2 de predição de diâmetros de árvore.

```

function PREVERARVORE( $d_{0,3}, d_{0,7}, d_{1,3}, D_{min}$ )
   $X \leftarrow [d_{0,3}, d_{0,7}, d_{1,3}]$ 
   $D \leftarrow []$ 
   $i \leftarrow 1,0$ 
  repeat
     $i \leftarrow i + 1,0$ 
     $D_i \leftarrow \text{MLP.PREVERDIAMETRO}(X)$ 
     $X_1 \leftarrow X_2$ 
     $X_2 \leftarrow X_3$ 
     $X_3 \leftarrow D_i$ 
  until ( $D_i \leq D_{min}$ )
   $\hat{H}_{D_{min}} \leftarrow i$ 
  return  $[D, \hat{H}_{D_{min}}]$ 
end function

```

5.5 Método de Avaliação de Desempenho do Modelo

5.5.1 Estimativa dos diâmetros com a rede neural de funções de base radial

Com o objetivo de comparar o modelo proposto neste trabalho, todos os experimentos realizados para a predição de diâmetros com a utilização da altura total (método 1) e na predição de diâmetros sem a utilização da altura total (método 2) foram repetidos substituindo-se a rede MLP por uma rede neural de Função de Base Radial (RBF) (SOARES et al., 2012b).

Ao construir uma rede neural RBF é importante determinar a estrutura da rede e seus parâmetros: pesos (w_i), número de centros (m) e a largura da função Gaussiana (σ_i), conforme a Equação (3.38), apresentada na seção 3.14 do Capítulo 3 deste trabalho.

Neste trabalho foi usado o valor de σ_i fixado em 1,0 para todos os centros. O algoritmo utilizado para o treinamento das RBFs foi obter os centros e ajustar os pesos h_i dessa rede. Inicialmente, a camada oculta da rede possui nenhum neurônio. A primeira amostra de entrada gera um centro. Os passos descritos abaixo são repetidos até que o erro médio quadrático (MSE) da rede atinja um limiar estabelecido, conforme ilustrado na Tabela 5.8:

1. Uma amostra de entrada é apresentada à rede;
2. O vetor de entrada com o maior erro é encontrado;
3. Um neurônio com base radial é adicionado com pesos iguais aos do vetor; e

Tabela 5.7: Definição formal do algoritmo de predição do modelo 2.

X	Vetor de entradas da MLP;
X_1	entrada 1 da MLP;
X_2	entrada 2 da MLP;
X_3	entrada 3 da MLP;
i	altura que está sendo predita;
$d_{0,3}$	diâmetro na altura 0,3 m (Diâmetro do toco);
$d_{0,7}$	diâmetro na altura 0,7 m;
$d_{1,3}$	diâmetro na altura 1,3 m (Diâmetro na Altura do Peito - DAP);
D	Conjunto de diâmetros preditos, o diâmetro no topo da árvore é considerado como sendo zero;
D_i	diâmetro estimado na altura i ;
D_{min}	diâmetro mínimo comercial, 4,0 cm;
$\hat{H}_{D_{min}}$	altura estimada do diâmetro mínimo comercial (D_{min}).

4. Os pesos w_i da camada de saída são redefinidos para minimizar o erro.

A Tabela 5.8 mostra os valores de MSE e o número médio de épocas para a convergência em cada classe de árvore. Nos treinamentos as RBFs convergiram abaixo de 51 épocas.

Tabela 5.8: Quantitativo de árvores, de amostras para treino e estatísticas dos treinamentos da RBF por classe.

Classe	Total		Amostras		Treino	
	Árvores	Conjuntos	Árvores	Conjuntos	Épocas	MSE
1	14	231	10	155	40	$4,5 \times 10^{-4}$
2	106	2405	11	239	17	$4,0 \times 10^{-4}$
3	302	8025	31	792	11	$4,5 \times 10^{-4}$
4	178	5105	18	498	7	$5,5 \times 10^{-4}$
5	15	462	10	298	51	$5,0 \times 10^{-4}$
Total	615	16228	80	1982	-	-

5.5.2 Cálculo dos erros dos diâmetros preditos com a MLP e a RBF

Com a finalidade de verificar o comportamento da MLP e da RBF na estimativa de todos os diâmetros de cada árvore, foram utilizados o Root Mean Square Error ($RMSE\%$) e a correlação linear (R), conforme as Equações (5.7) e (5.8) (ÖZÇELIK et al., 2010), respectivamente.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i^a - y_i^e)^2}{n}} \quad (5.6)$$

$$RMSE\% = \left(\frac{RMSE}{\bar{y}^a} \right) 100 \quad (5.7)$$

$$R = \frac{\sum_{i=1}^n [(y_i^a - \bar{y}^a)(y_i^e - \bar{y}^e)]}{\sqrt{\sum_{i=1}^n (y_i^a - \bar{y}^a)^2} \sqrt{\sum_{i=1}^n (y_i^e - \bar{y}^e)^2}} \quad (5.8)$$

onde:

y^a - vetor dos diâmetros reais;

y^e - vetor dos diâmetros estimados;

\bar{y}^a - valor médio do diâmetro real;

\bar{y}^e - valor médio do diâmetro estimado; e

n - número de medidas de diâmetros estimadas a partir das medidas de entrada da rede.

5.5.3 Cálculos dos volumes das árvores a partir dos diâmetros estimados e utilizando as equações volumétricas

Com o objetivo de verificar a eficiência do modelo proposto neste trabalho utilizando a MLP e a RBF foram calculados os volumes de todas as árvores a partir do método de Smalian, conforme as Equações (5.9) e (5.10), também apresentadas anteriormente na seção 2.4.3 do Capítulo 2 desta tese.

Esses volumes foram comparados com os respectivos volumes reais calculados a partir dos diâmetros medidos diretamente das árvores e também com os volumes obtidos utilizando-se o modelo de Schumacher e Hall em sua forma logaritmizada.

$$v = \left(\sum_{i=1}^{n-1} \frac{g_i + g_{i+1}}{2} l_i \right) + \frac{g_n l_n}{3} \quad (5.9)$$

$$g_i = \frac{(d_i/2)^2 \pi}{10.000} \quad (5.10)$$

onde:

v - volume total da árvore;

g_i - área basal da i -ésima posição;

l_i - comprimento da seção na i -ésima posição;

g_n - área basal do cone (ponta da árvore);

l_n - comprimento do cone; e

d_i - diâmetro da i -ésima posição.

Na Equação (5.10) a área de cada g_i é dividida por 10.000 para converter de cm^2 para m^2 .

O modelo de Schumacher e Hall (log) é um modelo volumétrico que estima o volume das árvores a partir do DAP e da altura total (H_t), conforme a Equação (5.11). Esse modelo é ajustado com os parâmetros obtidos de árvores cubadas rigorosamente (CABACINHA, 2003).

$$\ln v = \beta_0 + \beta_1 \ln DAP + \beta_2 \ln H_t + \varepsilon \quad (5.11)$$

onde:

v - volume;

DAP - diâmetro na altura do peito;

β_0 , β_1 e β_2 - parâmetros a serem ajustados; e

H_t - altura total.

O modelo de Schumacher e Hall (log), neste trabalho, estava ajustado para aplicar na estimação do volume total da árvore. Como a abordagem sem a altura total estima diâmetros até atingir o diâmetro mínimo comercial, o volume obtido é apenas devido a porção do volume comercial, e não o volume total, e portanto, não corresponde à mesma porção de volume estimada com o modelo de Schumacher e Hall (log) estava ajustado. Assim, por motivos de coerência, a equação de Schumacher e Hall (log) foi utilizada apenas para a comparação com os resultados obtidos com o método de estimativa que usa a altura total.

5.5.4 Cálculo dos erros de estimativa de volume

Com o objetivo de verificar a exatidão dos volumes calculados a partir dos diâmetros estimados utilizando a MLP e a RBF, foram calculados os seguintes erros percentuais: Desvio Médio ($MAE\%$), Bias ($Bias\%$) (LEITE; ANDRADE, 2002), Raiz do Erro Médio Quadrático ($RMSE\%$) e Correlação Linear (R) (ÖZÇELIK et al., 2010), a partir das Equações (5.12), (5.13), (5.7) e (5.8), respectivamente.

$$MAE\% = \frac{1}{n} \sum_{i=1}^n \left(\frac{y_i^e - y_i^a}{y_i^a} \right) 100 \quad (5.12)$$

$$Bias\% = \frac{\sum_{i=1}^n y_i^e - \sum_{i=1}^n y_i^a}{\sum_{i=1}^n y_i^a} 100 \quad (5.13)$$

onde:

y^a - vetor dos diâmetros reais;

y^e - vetor dos diâmetros estimados; e

n - número de diâmetros estimados a partir das medidas de diâmetros de entrada.

Todas as estatísticas calculadas quando foi utilizada a MLP foram também calculadas quando foi utilizada a RBF e para os volumes obtidos usando-se o modelo de Schumacher e Hall (log), quando este foi utilizado.

5.5.5 Análise de variância (ANOVA)

Com a finalidade de verificar se ocorrem diferenças estatísticas de acuidade entre a MLP, RBF e o modelo de Schumacher e Hall (log) foi realizada uma análise de variância (ANOVA) de 2-critérios.

Na ANOVA é definida a chamada hipótese nula (H_0) que considera que não existem diferenças estatísticas entre os métodos que estão sendo analisados. Quando a probabilidade (p) encontrada é menor do que 0,05 a hipótese nula (H_0) da ANOVA pode ser rejeitada, caso contrário não se pode afirmar que existam diferenças estatísticas entre os métodos.

Para a utilização de uma ANOVA é necessário que os dados estudados possuam:

- independência de resíduos;
- normalidade de resíduos; e
- igualdade (ou “homogenidade”) de variâncias.

Então, para a realização da ANOVA foram realizadas as verificações de hipóteses com os testes de Lilliefors e Cochran, que produzem uma probabilidade (p) para indicar se há normalidade e homogenidade de variâncias. Nos testes realizados o valor de (p) encontrado para os testes de Lilliefors e Cochran foram inferiores a (0,05) revelando normalidade e homogenidade de variâncias. Como os métodos comparados são completamente diferentes e foi

respeitado o princípio da randomização não foi necessário verificar a independência dos casos. Assim, a ANOVA pode ser usada na análise dos experimentos.

A ANOVA foi realizada entre os volumes calculados utilizando os diâmetros reais (medidos no campo) das árvores, preditos usando a MLP, a RBF e o modelo de Schumacher e Hall (log). Essa análise foi realizada para todos os dados de forma separada (treino e teste) e de forma conjunta (*treino + teste*). No cálculo da ANOVA, as classes de diâmetros foram utilizadas como controle.

5.6 Considerações Finais Deste Capítulo

Este capítulo apresentou o modelo proposto neste trabalho. Foi apresentado também alguns dos métodos tradicionais que são utilizados para fins comparativos, bem como os métodos estatísticos usados para validar o modelo proposto.

O próximo capítulo apresenta os resultados obtidos na predição recursiva de diâmetros com a utilização da altura total (método 1) e na predição recursiva de diâmetros sem a utilização da altura total (método 2), nas comparações com outros modelos e os estudos estatísticos utilizados na validação dos modelos.

RESULTADOS OBTIDOS

“Nenhum número de experiências, por muitas que sejam, poderão provar que tenho razão. Mas será suficiente uma só experiência para demonstrar que estou equivocado.”

Albert Einstein

6.1 Introdução

Como afirmado no Capítulo 5 deste trabalho, a predição dos diâmetros é realizada até que seja atingido o fim da árvore. Nesta tese são adotadas duas abordagens para o critério de parada do processo de estimativa de diâmetros para cada árvore.

Este capítulo apresenta os resultados obtidos na predição recursiva de diâmetros com a utilização da altura total (método 1) e na predição de diâmetros sem a utilização da altura total (método 2), suas comparações com outros modelos e os estudos estatísticos utilizados na validação dos modelos.

6.2 Experimentos Realizados Com o Método 1

No método 1 os diâmetros das árvores são estimados utilizando como critério de parada a altura máxima de cada árvore. Assim, os diâmetros estimados estão limitados ao intervalo da altura 2,0 ($H_{2,0}$) até a Altura Total (H_t) de cada árvore e o diâmetro na Altura Total (H_t) é

considerado zero.

6.2.1 Predição de diâmetros

Devido à grande quantidade de árvores preditas, a Tabela 6.1 mostra de forma resumida os valores de $RMSE\%$ e Correlação (R) dos testes realizados para a predição dos diâmetros das árvores utilizando a MLP e a RBF.

Tabela 6.1: Erros de predição de diâmetros por classe - $RMSE\%$ (menor, maior, médio e desvio padrão) e correlação - R (menor e maior).

Classe	Árvores	MLP						RBF					
		$RMSE\%$				Correlação (R)		$RMSE\%$				Correlação (R)	
		Mín	Máx	Média	DP	Mín	Máx	Mín	Máx	Média	DP	Mín	Máx
1	4	3,05	9,98	6,21	3,40	0,97	0,99	4,28	7,08	5,68	1,43	0,99	0,99
2	95	1,83	22,94	7,31	4,20	0,98	0,99	2,48	36,26	7,88	5,15	0,99	0,99
3	271	1,69	21,37	6,68	3,70	0,97	0,99	1,98	23,31	7,18	4,16	0,98	0,99
4	160	1,67	22,83	7,41	4,43	0,99	0,99	2,05	22,71	7,09	4,33	0,99	0,99
5	5	2,07	6,21	4,35	1,65	0,99	0,99	2,89	5,56	4,28	0,96	0,99	0,99

Pode-se observar na Tabela 6.1 que nas classes 1 e 5, onde a quantidade de árvores é muito pequena, o maior valor de $RMSE\%$ é menor do que 10%. E que nas classes 2, 3 e 4, onde a quantidade de árvores é bem maior do que nas classes 1 e 5, o maior valor de $RMSE\%$ está em torno de 22% para a MLP e 36% para a RBF. Para a classe 2, o maior valor de $RMSE\%$ é 36,26%. Embora os valores sejam grandes, a média dos $RMSE\%$ (erros) das classes 2, 3 e 4 ficou em torno de 7%, mostrando que os diâmetros preditos pela MLP e pela RBF estão bastante próximos dos diâmetros reais medidos nas árvores. Essa tabela também ilustra o menor e o maior coeficientes de correlação linear entre os diâmetros preditos e os medidos. Praticamente, todos esses coeficientes estão no intervalo de 0,97 a 0,99. Assim, existe uma fortíssima correlação linear entre os diâmetros reais medidos e os preditos pela MLP e pela RBF.

As Figuras 6.1(a) a 6.1(f) mostram com linhas sólidas e pontilhadas os valores de diâmetros reais e estimados utilizando-se a MLP para os melhores e piores casos, respectivamente.

As Figuras 6.2(a) a 6.2(f) mostram também com linhas sólidas e pontilhadas os valores de diâmetros reais e estimados utilizando-se RBF para os melhores e piores casos, respectivamente.

E as Figuras 6.3(a) a 6.3(c) e 6.4(a) a 6.4(c) ilustram os histogramas dos $RMSE\%$ calculados para as classes de 2 a 4 utilizando-se a MLP e a RBF, respectivamente.

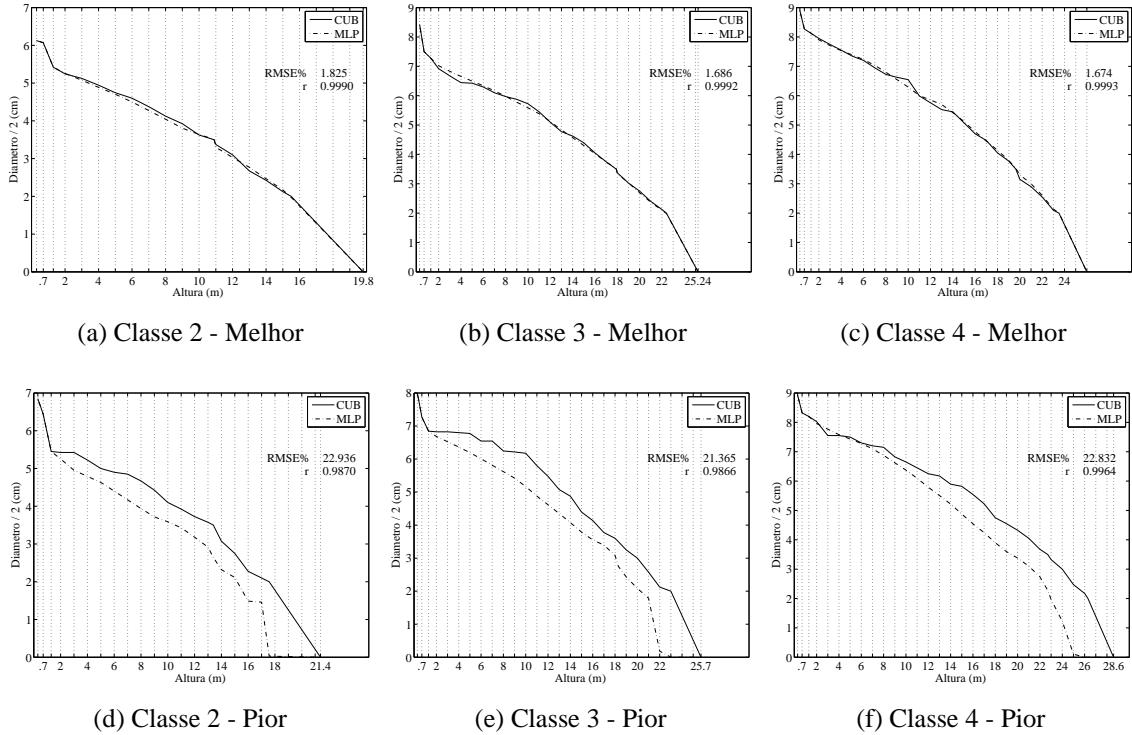


Figura 6.1: Exemplos de curvas preditas com a MLP (melhor e pior caso)

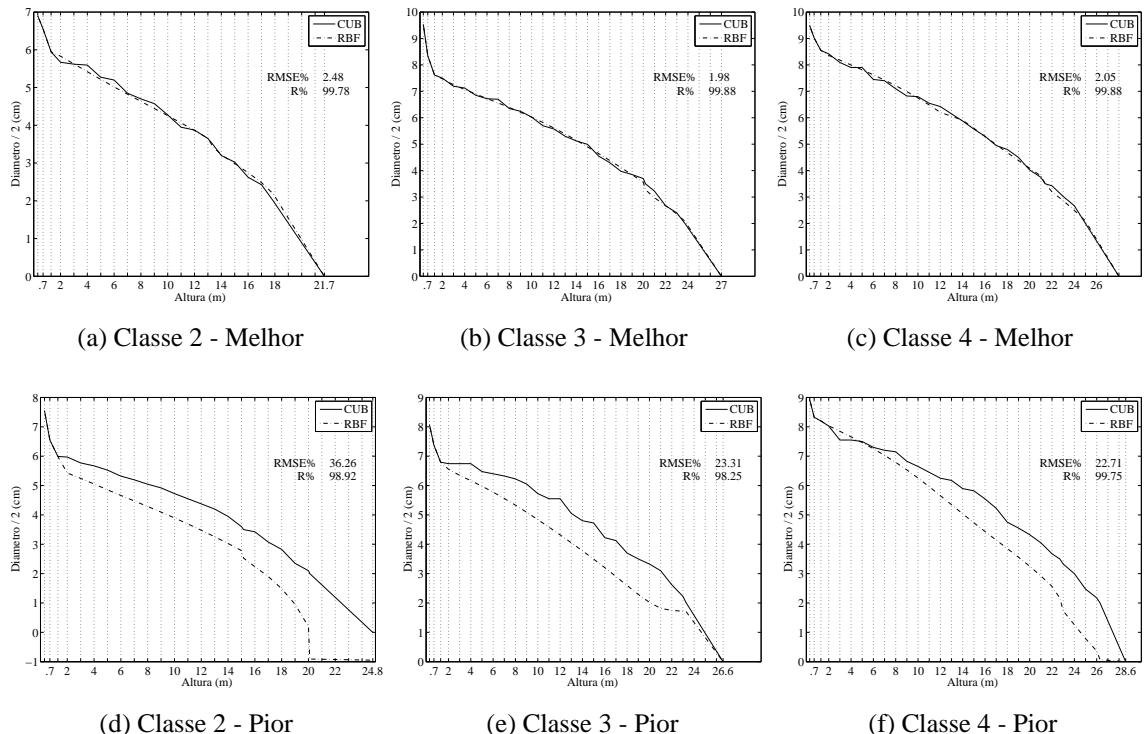


Figura 6.2: Exemplos de curvas preditas com a RBF (melhor e pior caso)

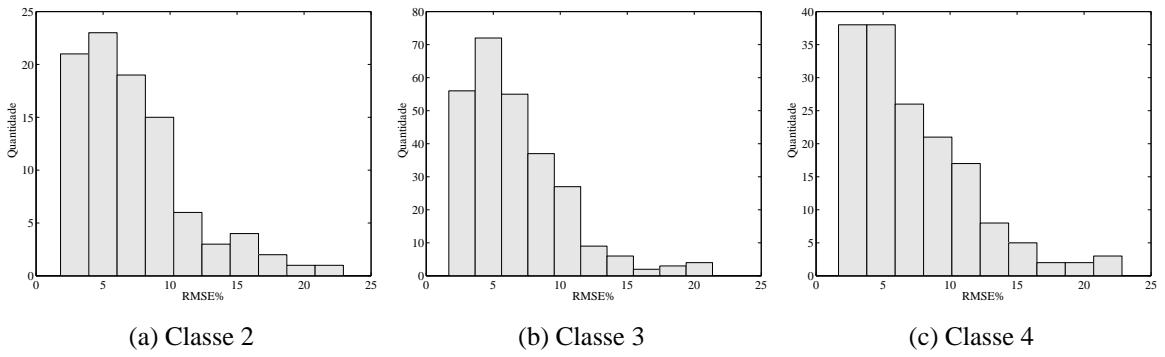


Figura 6.3: Histograma de $RMSE\%$ entre os diâmetros real e estimado com a MLP.

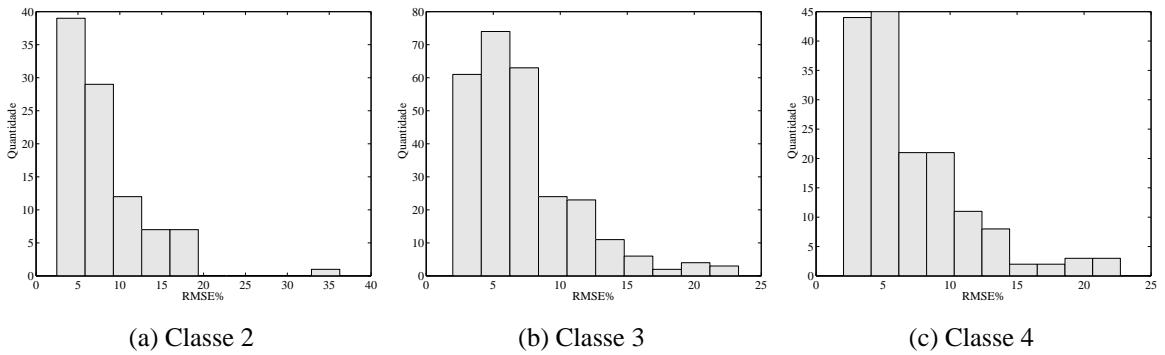


Figura 6.4: Histograma de $RMSE\%$ entre os diâmetros real e estimado com a RBF.

As Figuras 6.1(a), 6.1(b) e 6.1(c) mostram os menores $RMSE\%$ utilizando-se as classes 2, 3 e 4 para a MLP e as Figuras 6.2(a), 6.2(b) e 6.2(c) mostram para a RBF. Pode-se observar nessas figuras que os valores dos diâmetros reais e estimados pela MLP e pela RBF são bastante coincidentes uns com os outros. Verifica-se também que as redes possuem uma alta aproximação para os casos em que as árvores apresentam um perfil regular e mesmo quando o perfil das árvores é menos regular a MLP e a RBF acompanharam satisfatoriamente as variações bruscas de diâmetros.

Os maiores $RMSE\%$ são mostrados nas Figuras 6.1(d), 6.1(e) e 6.1(f) para a MLP e nas Figuras 6.2(d), 6.2(e) e 6.2(f) para a RBF. Pode-se verificar nessas figuras que ambas as redes subestimaram os valores reais dos diâmetros das árvores. Nos experimentos realizados com as classes 1 e 5, verificou-se que para a classe 1, repetiu-se a subestimação dos valores dos diâmetros reais, porém, para a classe 5 ocorreu uma pequena superestimação desses diâmetros.

Embora as Figuras 6.1 e 6.2 ilustrem os diâmetros reais e preditos de algumas árvores, o comportamento de todas as árvores utilizadas para teste mostraram que a MLP e a RBF tiveram dificuldade para prever os diâmetros mais próximos do topo das árvores. Isso já era esperado pois o modelo proposto neste trabalho realiza previsões recursivas e o erro em um determinado

diâmetro é repassado para a predição do próximo diâmetro. Portanto, quanto mais predições recursivas forem realizadas maior é o valor da diferença entre os diâmetros real e o predito utilizando a MLP e a RBF. No entanto, essa diferença influencia muito pouco no cálculo do volume de cada árvore.

As Figuras 6.3(a) a 6.3(c) e 6.4(a) a 6.4(c) mostram os histogramas de $RMSE\%$ para as classes de 2 a 4 para a MLP e a RBF, respectivamente. Pode-se verificar nessas figuras que a maior parte dos valores de $RMSE\%$ estão abaixo de 10% nessas classes que é um valor bastante satisfatório. Como a quantidade de árvores de teste nas classes 1 e 5 é muito pequena não existe um acumulo de $RMSE\%$ em torno da média, porém, foram observados que todos os valores de $RMSE\%$ estão abaixo de 10% e 6,3% nas classes 1 e 5, respectivamente, que também são valores bastante satisfatórios.

6.2.2 Comparação entre os volumes das árvores calculados utilizando os diâmetros reais e os preditos pela MLP e RBF e os volumes estimados usando o método de Schumacher e Hall (log)

Os volumes das árvores calculados usando os diâmetros reais e os preditos pela MLP foram obtidos utilizando a fórmula de Smalian (Equação (5.9)) e o modelo de Schumacher e Hall (log) (Equação (5.11)).

Os valores utilizados para os β 's e o ε no cálculo do volume das árvores utilizando o modelo de Schumacher e Hall (log), ajustados por (CABACINHA, 2003), foram $\beta_0 = -10,79449927$, $\beta_1 = 1,942384069$, $\beta_2 = 1,226015699$ e $\varepsilon = 0$. Com $R^2(\%) = 99,44$, erro padrão residual $S_{yx} = 0,011993\text{ m}$, e $S_{yx\%} = 5,81$.

A Tabela 6.2 mostra os volumes das árvores totalizados por classes utilizando diâmetros reais, preditos pela MLP e pela RBF e estimados pelo modelo de Schumacher e Hall (log). Essa tabela está dividida em Treino (10%), Teste (90%) e Treino + Teste. Em todas essas divisões da tabela são mostrados os volumes obtidos usando os diâmetros reais, preditos pela MLP, preditos pela RBF e estimados pelo método de Schumacher e Hall (log). O cálculo dos volumes na divisão Treino (10%) foi realizado com as árvores do treino da MLP e da RBF. A divisão Teste (90%) da tabela mostra os volumes calculados com as árvores dos testes da MLP e da RBF. E a divisão Treino + Teste da tabela apresenta a soma dos volumes das outras divisões da tabela.

Tabela 6.2: Volumes (m^3) calculados utilizando-se os diâmetros reais, preditos pela MLP, pela RBF e pelo método de Schumacher e Hall (log).

Classe	Treino (10%)				Teste (90%)				Treino + Teste			
	Real	MLP	RBF	Schumacher e Hall (log)	Real	MLP	RBF	Schumacher e Hall (log)	Real	MLP	RBF	Schumacher e Hall (log)
1	0,4268	0,4265	0,4049	0,4318	0,2293	0,2321	0,2158	0,2319	0,6561	0,6585	0,6207	0,6636
2	1,2513	1,2551	1,2247	1,2464	11,5382	11,3273	11,1095	11,4700	12,7896	12,5823	12,3342	12,7164
3	6,6344	6,6348	6,6234	6,5809	55,2320	54,2328	53,5001	54,6750	61,8663	60,8675	60,1235	61,2559
4	5,3274	5,3347	5,2482	5,3945	47,7756	48,0092	46,8128	48,3938	53,1030	53,3438	52,0610	53,7882
5	4,2240	4,3165	4,2920	4,4264	2,2226	2,2007	2,2002	2,2382	6,4466	6,5172	6,4922	6,6646
Total	17,8639	17,9676	17,7932	18,0800	116,9977	116,0021	113,8384	117,0089	134,8616	133,9693	131,6316	135,0887

Pode-se observar na Tabela 6.2 que as diferenças são muito pequenas entre os volumes das árvores calculados utilizando-se os diâmetros reais, preditos pela MLP e estimados pelo método de Schumacher e Hall (log). Em alguns casos essas diferenças são nas primeiras, segundas e terceiras casas decimais. Em poucos casos essas diferenças foram na parte inteira do valor do volume e quando ocorreram foram de apenas uma unidade. Para a RBF, pode-se observar que houve uma subestimação dos valores reais de Teste e consequentemente nos valores de Treino + Teste.

Na divisão Treino + Teste da Tabela 6.2, a diferença percentual entre os volumes totais das árvores calculados utilizando-se os diâmetros reais e os preditos pela MLP foi de 0,66%, usando-se os diâmetros reais e os preditos pela RBF foi de 2,36%, e entre os volumes calculados utilizando-se os diâmetros reais e os estimados pelo método de Schumacher e Hall (log) foi de 0,17%. Portanto, a diferença percentual entre os dados reais e os estimados pela MLP e pelo método de Schumacher e Hall (log) é menor do que 1%, porém, para a RBF a diferença ficou acima de 2%. Nas colunas referentes apenas ao teste, a diferença percentual entre os volumes totais das árvores calculados usando-se os diâmetros reais e os preditos pela MLP foi de 0,85% e de 2,70%, respectivamente.

A Tabela 6.3 ilustra as estatísticas dos erros de estimativa de volume por classe.

Tabela 6.3: Comparação entre os volumes das árvores reais e os estimados.

(a) MLP				(b) RBF				(c) Schumacher e Hall (log)					
Classe	MAE%	Bias%	R	Classe	MAE%	Bias%	R	Classe	MAE%	Bias%	R	RMSE%	
1	3,99	1,21	0,96	5,86	1	5,65	5,87	0,96	8,14	1	6,30	1,14	0,97
2	6,65	1,83	0,92	8,05	2	8,42	3,72	0,85	11,58	2	4,90	0,59	0,96
3	6,20	1,81	0,89	7,80	3	7,25	3,14	0,88	8,83	3	4,51	1,01	0,94
4	6,35	0,49	0,82	7,66	4	6,35	2,02	0,81	7,71	4	4,34	1,29	0,91
5	2,77	0,99	0,71	3,42	5	3,65	1,01	0,54	3,88	5	3,37	0,70	0,68

Pode-se verificar na Tabela 6.3(a), que os valores de $MAE\%$ entre 2,77% e 6,65%, $Bias\%$ entre 0,43% e 1,83% e $RMSE\%$ entre 3,42% e 8,05%, podem ser considerados valores bastante

satisfatórios para o desempenho da MLP. Para a RBF, os valores de $MAE\%$ entre 3,7% e 8,4%, $Bias\%$ entre 1,0% e 5,9% e $RMSE\%$ entre 3,9% e 11.6%, podem ser considerados valores ainda satisfatórios, porém bastante superiores aos da MLP. Os valores de R das classes de 1 a 4 ficaram entre 0,82 e 0,92 para a MLP e entre 0,81 e 0,96 para a RBF, que é considerada uma forte correlação entre os volumes calculados com os diâmetros reais e com os diâmetros preditos pelas redes. Para a classe 5, o valor de R para a MLP foi de 0,71 que é uma forte correlação, porém, para a RBF esse valor foi de 0,54 que já apresenta uma correlação moderada.

Pode-se observar na Tabela 6.3(c), que para as classes de 2 a 4, os erros percentuais para o método de Schumacher e Hall (log) foram cerca de 2% menores do que os erros percentuais da MLP e um pouco maior para a RBF. Porém, para as classes 1 e 5, os resultados foram o inverso. Os erros para o método de Schumacher e Hall (log) foram cerca de 2% maiores do que os erros da MLP. A correlação linear (R) para as classes de 1 a 4 para o modelo de Schumacher e Hall (log) apresentou valores entre 0,91 e 0,97 e para a classe 5 o valor foi de 0,68.

Pode-se considerar que o $Bias\%$ quando possui valores altos revelam alguma tendência indesejável nos resultados, que não foi o caso para a MLP, pois os valores ficaram abaixo de 1,5%. Para a RBF os valores do $Bias\%$ ficaram em um intervalo de 1% a 6% que embora não seja grande, este valor deve ser investigado.

É importante ressaltar, que embora, ocorram uma diferença de aproximadamente 2% entre os erros, mas tanto no método de estimação com o uso da MLP como com a RBF tiveram erros que podem ser considerados bastante pequenos.

A Figura 6.5 ilustra os gráficos de dispersão por classe entre os volumes reais e os estimados pela MLP, estimados pela RBF e pelo modelo de Schumacher e Hall (log).

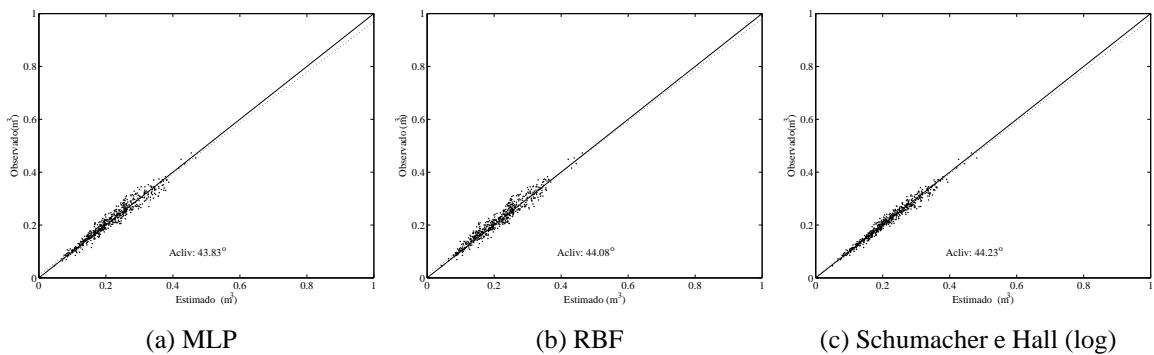


Figura 6.5: Gráfico de dispersão dos volumes estimados.

A Figura 6.5(a) mostra o gráfico de dispersão entre os volumes reais e os estimados pela MLP, das classes de 1 a 5, a Figura 6.5(b) mostra o gráfico de dispersão entre os volumes reais

e os estimados pela RBF e a Figura 6.5(c) ilustram o gráfico de dispersão entre os volumes reais e os estimados pelo método de Schumacher e Hall (log).

Ao comparar os gráficos de dispersão entre os volumes reais e os volumes estimados pela MLP, pela RBF e pelo modelo de Schumacher e Hall (log) pode-se verificar que os métodos de estimação têm uma pequena dispersão. O modelo de Schumacher e Hall (log) teve uma dispersão um pouquinho menor na região das classes 2, 3 e 4, do que as redes neurais, porém essa diferença de dispersão entre esses métodos não é significativa no cálculo do volume total do inventário florestal.

As ANOVAs de 2-critérios realizadas para os conjuntos de *treino*, *teste* e *treino + teste* apresentaram os valores de $p = 0,5568$; $0,5575$ e $0,5362$, respectivamente. A hipótese nula (H_0) não pode ser rejeitada, ou seja não existem diferenças estatísticas entre a MLP, a RBF, o modelo de Schumacher e Hall (log) e a cubagem rigorosa.

6.3 Experimentos Realizados Com o Método 2

No método 2 os diâmetros são estimados até que o valor de uma estimativa tenha sido menor ou igual a um valor pré-determinado.

6.3.1 Predição de diâmetros das árvores

A Tabela 6.4 mostra de forma resumida os valores de $RMSE\%$ e R dos testes realizados para a predição dos diâmetros das árvores para as classes de 1 a 5 utilizando-se a MLP e a RBF.

Tabela 6.4: Erros de predição de diâmetros por classe - $RMSE\%$ (menor, maior, médio e desvio padrão) e correlação - R (menor e maior)

Classe	Árvores	MLP						RBF					
		$RMSE\%$				Correlação (R)		$RMSE\%$				Correlação (R)	
		Mín	Máx	Média	DP	Mín	Máx	Mín	Máx	Média	DP	Mín	Máx
1	4	0,99	20,57	7,17	9,13	0,96	0,99	1,30	12,50	5,70	4,99	0,95	0,99
2	95	0,52	7,50	2,69	1,49	0,97	0,99	0,49	7,37	3,16	1,57	0,96	0,99
3	271	0,41	6,14	2,20	1,07	0,98	0,99	0,48	5,80	2,40	1,17	0,98	0,99
4	160	0,43	6,01	1,87	0,89	0,99	0,99	0,40	5,28	1,92	0,90	0,98	0,99
5	5	1,27	2,02	1,74	0,30	0,99	0,99	0,80	2,85	1,86	0,73	0,99	0,99

Pode-se observar na Tabela 6.4 que nas classes 1 e 5, onde a quantidade de árvores é muito pequena, o maior valor de $RMSE\%$ para a MLP é aproximadamente 21% e 2%, respectivamente, e para a RBF é aproximadamente 12,5% e 3%, respectivamente. Verifica-se também

que nessas classes a média dos valores de $RMSE\%$ para a MLP ficaram em torno de 7,17% para a classe 1 e 1,74% para a classe 5. Para a RBF a média dos valores de $RMSE\%$ ficaram em torno de 5,70% para a classe 1 e 1,86% para a classe 5. Os desvios padrões para a MLP das classes 1 e 5 foram de 9,1% e 0,29%, respectivamente, e para a RBF foram de 4,99% e 0,73%.

É importante salientar que na classe 5, embora a quantidade de árvores seja tão pequena quanto na classe 1, os valores de $RMSE\%$ foram bem menores. Como pode ser observado na Tabela 5.3, isto ocorre porque as árvores da classe 5 são bem mais altas do que as da classe 1 e consequentemente fornecem mais amostras para o treino das redes.

Pode-se verificar ainda na Tabela 6.4 que nas classes 2, 3 e 4, onde a quantidade de árvores é bem maior do que nas classes 1 e 5, o maior valor de $RMSE\%$ é aproximadamente 7,5%. Nessas classes as médias dos valores de $RMSE\%$ ficaram entre 1,87% e 2,69% para a MLP e entre 1,92% e 3,16% para a RBF. Os desvios padrões foram entre 0,89% e 1,49% para a MLP e 0,90% e 1,57% para a RBF. Esses valores mostram que os erros de predição das redes nas classes de 2 a 5 foram significativamente menores do que na classe 1 e portanto a MLP e a RBF para essas classes foram mais precisas.

A Tabela 6.4 mostra que o R ficou no intervalo de 0,95 a 0,99 mostrando uma fortíssima correlação linear entre os diâmetros reais medidos e os preditos pela MLP e pela RBF.

As Figuras de 6.6(a) a 6.6(f) ilustram alguns exemplos de valores de diâmetros reais e estimados utilizando-se a MLP e as Figuras 6.7(a) a 6.7(f) ilustram alguns exemplos de valores de diâmetros reais e estimados usando-se a RBF.

As Figuras de 6.8(a) a 6.8(c) e de 6.9(a) a 6.9(c) mostram os histogramas dos valores de $RMSE\%$ calculados para cada árvore das classes exemplificadas para a MLP e a RBF, respectivamente.

As Figuras 6.6(a) a 6.6(c) e 6.7(a) a 6.7(c) mostram para as classes 2, 3 e 4, árvores com conicidade regular. Pode-se observar nessas figuras que os diâmetros reais e preditos foram bastante coincidentes, consequentemente seus valores de $RMSE\%$ foram muito pequenos.

As árvores das classes 2, 3 e 4 com conicidade irregular são ilustradas nas Figuras 6.6(d) a 6.6(f) e 6.7(d) a 6.7(f). Pode-se observar nessas figuras que os diâmetros preditos utilizando-se a MLP tenderam a superestimar os reais e a RBF superestimou no exemplo da classe 4 e subestimou nos demais exemplos. Consequentemente os valores de $RMSE\%$ foram mais altos.

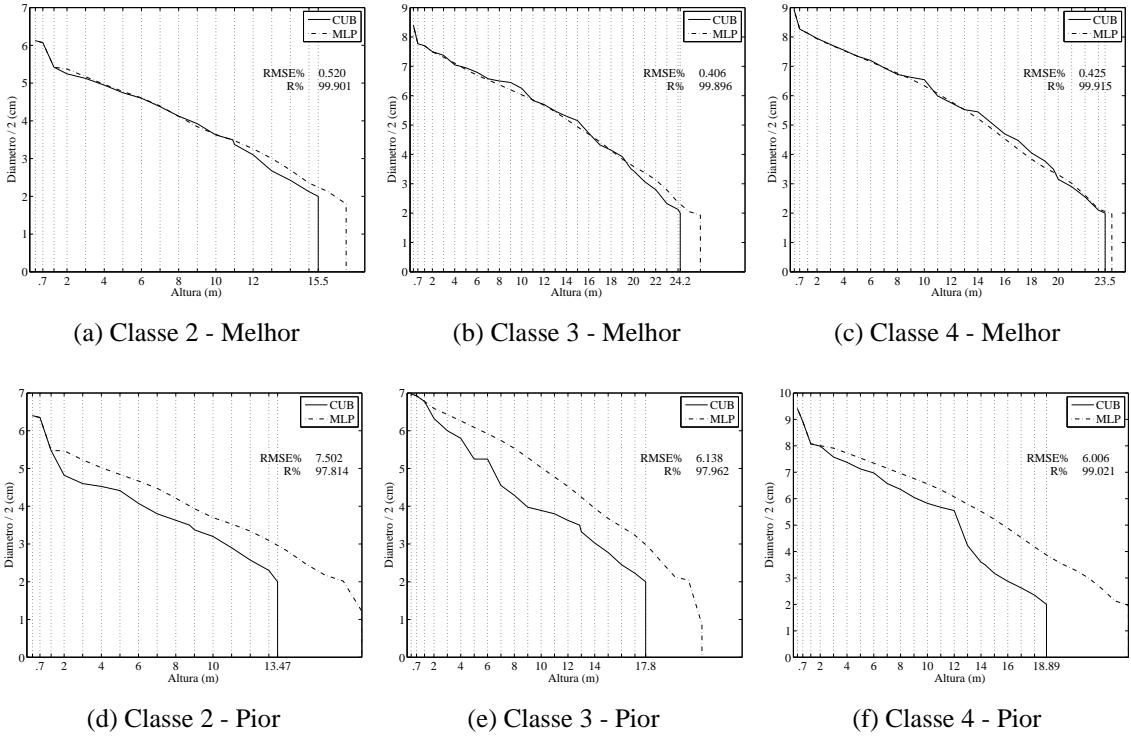


Figura 6.6: Exemplos de curvas preditas com a MLP (melhor e pior caso).

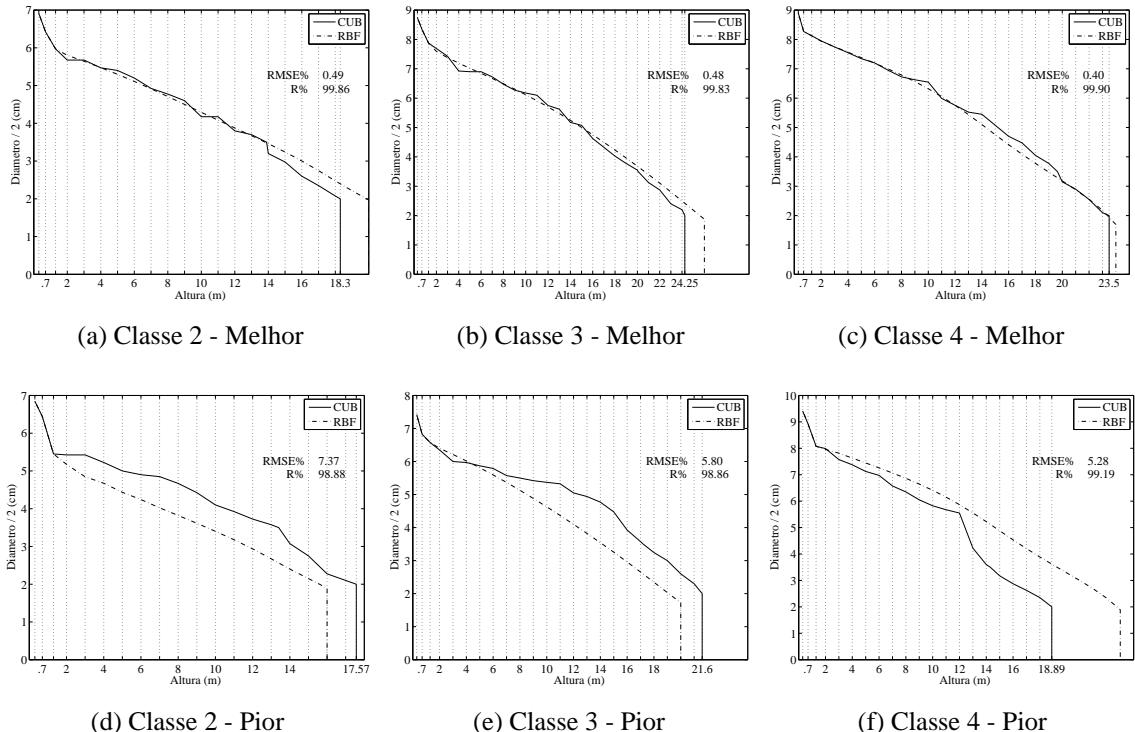


Figura 6.7: Exemplos de curvas preditas com a RBF (melhor e pior caso).

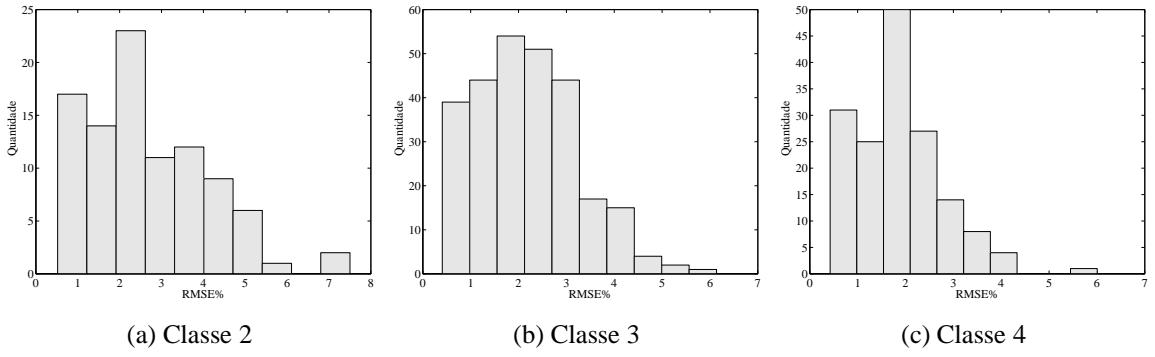


Figura 6.8: Histograma de $RMSE\%$ entre os diâmetros real e estimado com a MLP.

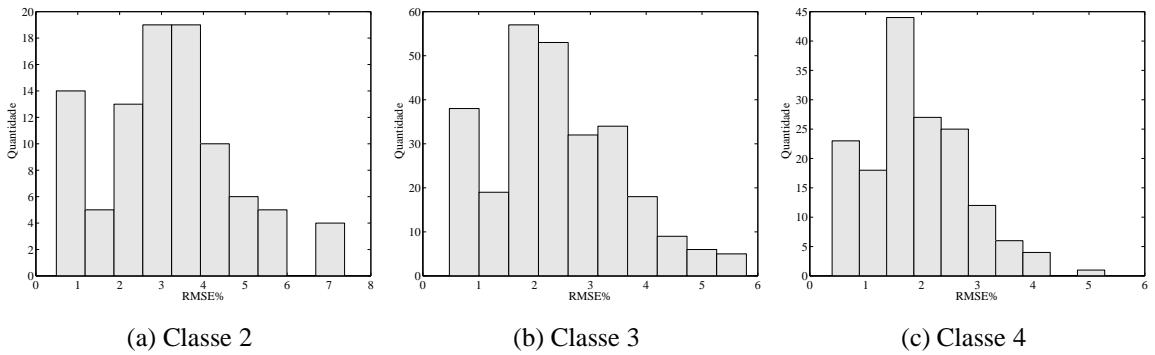


Figura 6.9: Histograma de $RMSE\%$ entre os diâmetros real e estimado com a RBF.

As Figuras 6.8(a) a 6.8(c) e 6.9(a) a 6.9(c) ilustram os histogramas de $RMSE\%$ entre os diâmetros estimado e real para as classes de 2 a 4 para a MLP e a RBF, respectivamente. Pode-se observar nessas figuras que a maior parte dos valores de $RMSE\%$ da classe 2 estão abaixo de 5% e nas classes 3 e 4 a maior parte dos valores de $RMSE\%$ estão abaixo de 3%. Estes valores de $RMSE\%$ dessas classes ilustram que o modelo proposto estimou de maneira satisfatória os diâmetros das árvores. Como a quantidade de árvores de teste nas classes 1 e 5 é muito pequena não existe um acúmulo de $RMSE\%$ em torno da média e portanto não foram mostrados seus respectivos histogramas.

A Tabela 6.5 apresenta a média, a menor e a maior diferença entre a altura real e a estimada do diâmetro mínimo comercial adotado de 4 cm. Pode-se verificar nessa tabela que a menor diferença é 0,00 cm para ambas as redes e 7,60 cm e 7,20 cm, para a MLP e a RBF, respectivamente. Pode-se observar também que as médias estão abaixo de 3,00 cm.

Embora, em algumas classes a diferença tenha sido alta, esses valores são muito pequenos pois, representam uma porção muito pequena das árvores e portanto, não influenciaram no volume final de cada árvore.

Tabela 6.5: Diferenças entre as alturas reais e estimadas do diâmetro mínimo (4 cm).

Classe	MLP			RBF		
	Mín	Máx	Média	Mín	Máx	Média
1	0,00	7,60	2,82	0,30	4,40	2,32
2	0,00	5,00	1,97	0,00	5,20	1,78
3	0,00	5,70	1,37	0,00	6,70	1,66
4	0,00	4,30	1,18	0,00	4,80	1,31
5	0,00	6,20	1,30	0,00	7,20	1,36

6.3.2 Comparação entre os volumes das árvores calculados utilizando-se diâmetros reais e preditos pela MLP e pela RBF

Os volumes das árvores calculados usando os diâmetros reais e obtidos pela MLP e pela RBF foram encontrados utilizando-se a fórmula de Smalian (Equação (5.9)).

Tabela 6.6: Volumes comerciais (m^3) calculados utilizando-se os diâmetros reais, preditos pela MLP e pela RBF.

Classe	Treino (10%)			Teste (90%)			Treino + Teste		
	Real	MLP	RBF	Real	MLP	RBF	Real	MLP	RBF
1	0,4645	0,5120	0,5105	0,1585	0,1693	0,1481	0,6231	0,6813	0,6586
2	1,3671	1,3816	1,4249	11,2354	11,3198	11,4788	12,6026	12,7014	12,9037
3	6,2486	6,4109	6,3092	55,1970	55,3233	54,2112	61,4456	61,7343	60,5204
4	5,3795	5,3519	5,3094	47,5008	47,8619	47,5718	52,8804	53,2138	52,8812
5	4,2832	4,3444	4,5659	2,1463	2,0820	2,2095	6,4296	6,4264	6,7754
Total	17,7429	18,0008	18,1199	116,2380	116,7563	115,6194	133,9813	134,7572	133,7393

A Tabela 6.6 mostra os volumes comerciais das árvores totalizados por classes utilizando-se os diâmetros reais e preditos pela MLP e pela RBF. O cálculo dos volumes comerciais das árvores de treino foi realizado com as árvores do treino da MLP (10%) e os volumes calculados com as árvores dos testes da MLP (90%). As classes 1 e 5 possuem poucas árvores e foi adotado um mínimo de 10 árvores. Portanto, foi usado mais de 10% das amostras para treinamento dessas classes.

Pode-se observar na Tabela 6.6 que as diferenças são muito pequenas entre os volumes das árvores calculados utilizando-se os diâmetros reais e preditos pela MLP e um pouco maior para a RBF. Em alguns casos essas diferenças são nas primeiras e nas segundas casas decimais. Em poucas classes essas diferenças foram na parte inteira do valor do volume e quando elas ocorreram foram de apenas uma unidade.

Nas colunas referentes à soma do treino e de teste a diferença percentual entre os volumes totais das árvores calculados utilizando-se os diâmetros reais e preditos pela MLP foi de -0,58% e de 0,18%, respectivamente. Porém, nas colunas referentes apenas ao teste a diferença percen-

tual entre os volumes totais das árvores calculados usando-se os diâmetros reais e preditos pela MLP foi de -0,44% e de 0,53%, respectivamente.

A Tabela 6.7 ilustra as estatísticas dos erros de estimativa dos volumes das classes de 1 a 5 para os modelos com as redes neurais.

Tabela 6.7: Comparação entre os volumes das árvores reais e os estimados.

(a) MLP					(b) RBF				
Classe	MAE%	Bias%	R	RMSE%	Classe	MAE%	Bias%	R	RMSE%
1	12,53	6,79	0,99	12,29	1	22,05	17,11	0,99	19,60
2	7,15	0,75	0,90	8,76	2	8,56	0,67	0,87	10,38
3	6,99	0,23	0,86	8,84	3	7,33	2,46	0,87	8,90
4	6,51	0,76	0,81	7,67	4	6,46	0,27	0,81	7,63
5	4,82	2,99	0,87	5,55	5	4,39	2,67	0,91	6,90

Pode-se observar na Tabela 6.7 que os valores de $MAE\%$ e $RMSE\%$ para as classes de 2 a 5 são pequenos. Esses valores para a MLP estão nos intervalos de 5 a 7% e 5 a 9%, respectivamente e para a RBF estão nos intervalos de 5 a 9% e de 7 a 11%, respectivamente. Somente na classe 1 os valores do $MAE\%$ e de $RMSE\%$ para o modelo foi maior do que 10% para a MLP e maior do que 19% para a RBF. Porém, essa classe possui uma quantidade de árvores muito pequenas, que proporcionou uma quantidade de amostras de treino muito pequena.

Verifica-se na Tabela 6.7 que nas classes de 2 a 4 o valor do $Bias\%$ do modelo ficou abaixo de 1%, porém, esse valor foi 2,46% para a classe 3 com a RBF. Apenas nas classes 1 e 5, o valor do $Bias\%$ para a MLP ficou aproximadamente 7% e 3%, respectivamente e para a RBF ficou aproximadamente 17% e 3%. Para o treino dessas classes foi utilizado um percentual de amostras para treino muito superior à quantidade de amostras de teste, e consequentemente isso gerou uma tendência nos resultados.

Pode-se verificar ainda na Tabela 6.7 que os coeficientes de correlação (R) ficaram aproximadamente entre 0,81 e 0,99. Pode-se observar que quanto maior a classe de diâmetro das árvores menor foi o valor de R . Isto mostra que quanto maior o tamanho da árvore mais erros podem ocorrer na estimativa do volume pois, a predição recursiva de séries muito longas tendem a aumentar o erro ao longo da predição e isto incidiu sobre o cálculo do volume.

A Figura 6.10 ilustra o gráfico de dispersão para as classes de 1 a 5 entre os volumes reais e estimados pela MLP e pela RBF. Pode-se observar nos gráficos que os modelos de estimativa tiveram uma pequena dispersão. Os volumes obtidos com a RBF foram um pouco mais dispersos. A RBF apresentou ainda alguns pontos em que o erro foi muito grande. Porém,

essa dispersão não se mostrou significativa quando observados os volumes totais do inventário florestal na Tabela 6.6. Ressalta-se que nos gráficos de dispersão enquanto a reta de regressão da MLP possui uma inclinação de $44,22^\circ$, para um valor desejado de $45,00^\circ$, para a RBF a inclinação foi de $33,75^\circ$.

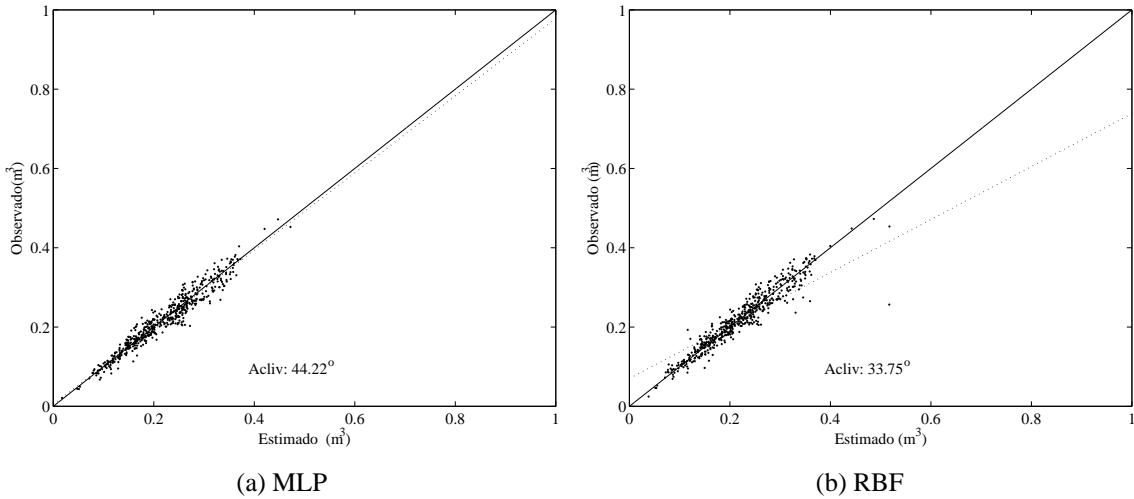


Figura 6.10: Gráfico de dispersão dos volumes estimados.

As ANOVAs de 2-critérios realizadas para os conjuntos de *treino*, *teste* e *treino + teste* apresentaram os valores de $p = 0,3441; 0,5176$ e $0,6210$, respectivamente. A hipótese nula (H_0) não pode ser rejeitada, ou seja não existem diferenças estatísticas entre a MLP e a RBF.

6.4 Conclusões

Este capítulo apresentou os resultados obtidos na predição recursiva de diâmetros com a utilização da altura total (método 1) e na predição recursiva de diâmetros sem a utilização da altura total (método 2) e as comparações com outros modelos e os estudos estatísticos utilizados na validação do modelo.

Em todos os testes realizados pôde-se observar que independente da conicidade de cada árvore ser regular ou não, os valores dos diâmetros preditos pela MLP foram bastante satisfatórios em relação aos valores dos diâmetros reais. Porém, as redes tiveram dificuldade para prever os diâmetros mais próximos do topo das árvores. Isso já era esperado pois o modelo proposto neste trabalho realiza as predições recursivas e os erros em um determinado diâmetro são repassados para a predição dos próximos diâmetros. No entanto, essa diferença influenciou muito pouco no cálculo do volume total de cada árvore. Nos testes realizados verificou-se que as diferenças entre os diâmetros estimados pela MLP e os reais foram muito pequenas.

É importante destacar que ao comparar os volumes calculados com os diâmetros reais e com os preditos, a diferença do volume total para o método 1 foi de 0,66% e 2,35% para a MLP e a RBF, respectivamente e para o método 2 -0,58% e 0,18% para a MLP e a RBF, respectivamente. Esses valores além de muito satisfatórios, estão bastante abaixo do percentual de erro tolerado, que pode ser de até 10%.

Para o método 1 usando a MLP foi realizada a comparação com esse método utilizando a RBF e com a equação de Schumacher e Hall (log), e os resultados mostraram-se próximos, porém a MLP mostrou-se um pouco melhor.

Para o método 2 usando a MLP foi realizada apenas a comparação com esse método utilizando-se a RBF e os resultados obtidos mostraram-se muito semelhantes. Não foi realizada a comparação com as equações volumétricas pois, essas equações disponíveis durante a realização deste trabalho foram ajustadas para volume total das árvores e o volume calculado com os diâmetros estimados com o método 2 correspondem apenas ao volume comercial.

O próximo capítulo apresenta as contribuições deste trabalho, os trabalhos futuros e as publicações originadas nesta tese.

CONCLUSÕES E CONTRIBUIÇÕES DESTE TRABALHO, TRABALHOS FUTUROS E AS PUBLICAÇÕES ORIGINADAS NESTA TESE

“Toda decisão acertada é proveniente de experiência. E toda experiência é proveniente de uma decisão não acertada.”

Albert Einstein

7.1 Introdução

Este capítulo apresenta as conclusões e as contribuições deste trabalho, os trabalhos futuros e as publicações originadas nesta teste.

7.2 Conclusões e Contribuições

Durante décadas, extensivas pesquisas têm sido voltadas para o desenvolvimento de métodos para a análise das características da forma das árvores. Ao longo dos anos foram construídos modelos para ajustar as equações para a predição dos diâmetros, também chamadas de equa-

ções de *taper*. Estas equações baseiam-se no ajuste de bons protótipos dendrométricos que descrevem a população em que se encontram. Porém, a determinação do protótipo além de não ser uma tarefa trivial, diversos estudos demonstraram que os eucaliptos podem possuir uma variedade de protótipos em uma só árvore.

Um dos modelos mais utilizados são as equações volumétricas que estimam o volume das árvores a partir de dados como a altura total e o *DAP*. Uma das equações volumétricas bastante utilizadas é a de Schumacher e Hall (log). Embora os resultados desse modelo sejam bastante interessantes, por estimar diretamente o volume da árvore, ele não permite conhecer os diversos diâmetros das árvores. Com isto, a indústria madeireira perde o controle de muitas características como o afilamento, por exemplo. Esta informação é muito útil na comercialização pois é determinante no tipo de aplicação para a qual a madeira poderá ser destinada. É importante ressaltar que tanto as equações volumétricas quanto as equações de *taper* necessitam de uma quantidade de amostras muito grande do povoamento para serem ajustadas e que resultaria em um abate prematuro de árvores, e um custo muito alto do procedimento de inventário.

A integração da engenharia florestal com as redes neurais vem sendo investigada atualmente. Alguns modelos propostos visaram substituir as equações volumétricas estimando os volumes diretamente. Outras propostas visaram estimar os diâmetros de forma direta. Este último, embora tenha encontrado bons resultados, foram aplicados a árvores de espécies que se ajustavam a protótipos dendrométricos muito simples, como por exemplo, cones.

Os principais objetivos deste trabalho foram a simplificação da atividade de inventário florestal em campo e evitar a necessidade de se adequar um ou mais protótipos dendrométricos durante as estimativas. Assim, a base do modelo proposto é a estimativa dos diâmetros das árvores utilizando uma rede neural Perceptron de Múltiplas Camadas a partir de apenas três medidas na base da árvore. Estas medidas são os diâmetros a 0,3, 0,7 e 1,3 metros do solo. Elas são muito fáceis de serem obtidas sem equipamentos especiais ou escadas o que torna um inventário não só mais fácil, mas também rápido e consequentemente mais barato. Como o modelo proposto baseou-se na recursividade para a estimativa dos diâmetros, isto dispensa a necessidade de se estimar os protótipos dendrométricos já que ao invés de tentar descobri-los, o modelo recursivo permite que sejam estimados.

Visando facilitar ainda mais o processo de inventário, neste trabalho foram apresentadas duas abordagens do modelo proposto para estimar os diâmetros. A primeira utilizou a altura total da árvore para determinar o fim da árvore e finalizar o processo de estimativa. A segunda abordagem utilizou como critério de parada do processo de estimativa encontrar um diâmetro menor do que uma medida de diâmetro mínimo comercial.

O desempenho de cada abordagem do modelo foi comparado à metodologia de cubagem rigorosa. O modelo proposto também foi comparado com uma variação desse em que a MLP foi substituída por uma RBF. Como a abordagem com a altura total como critério de parada proporciona o volume total da árvore, esse modelo foi também comparado com a equação volumétrica baseada no modelo de Schumacher e Hall (log). Foram realizadas as comparações dos resultados obtidos por meio da raiz do erro quadrático médio, correlação linear, desvio médio e viés (*Bias*).

Em todos os testes realizados pôde-se observar que independente da variação dos diâmetros em cada árvore ser regular ou não, os valores dos diâmetros preditos pela MLP foram bastante satisfatórios em relação aos valores dos diâmetros reais. Porém, a MLP teve dificuldade para prever os diâmetros mais próximos do topo das árvores. Isso já era esperado pois o modelo proposto neste trabalho realiza previsões recursivas e erros em um determinado diâmetro são repassados para a previsão dos próximos diâmetros. No entanto, essa diferença influenciou muito pouco no cálculo do volume total de cada árvore. Nos testes realizados verificou-se que as diferenças entre os diâmetros estimados pela MLP e os reais foram muito pequenas.

Pode-se ressaltar que em todos os experimentos realizados com a RBF, embora ocorram resultados diferentes, o comportamento dos modelos com a MLP e a RBF foi bastante semelhante. Isto já era esperado pois a MLP e a RBF são arquiteturas de redes neurais bastante competitivas nos problemas de mesma natureza. É importante salientar que o objetivo principal deste trabalho era propor uma abordagem recursiva usando a MLP para a previsão de diâmetros. Ressalta-se ainda que embora ambas as redes possuam resultados semelhantes e as ANOVAs realizadas indicam que não existe diferenças estatísticas entre os métodos, a MLP é muito mais difundida do que a RBF e existe muito mais suporte da comunidade científica para a construção de modelos com a MLP.

Como o método 1 utiliza como critério de parada a altura total da árvore e o método 2 usa como critério de parada o diâmetro mínimo comercial, a diferença entre estes métodos é basicamente o critério de parada da previsão e portanto não foi possível fazer a comparação entre eles, pois, não compartilham a mesma porção das árvores para estudo. Tentou-se estabelecer alturas ou diâmetros como critério de parada comum para ambos os métodos, para que eles tratassesem da mesma parte da árvore e então comparar os métodos. Porém, isto acabou por transformar esses dois métodos em métodos idênticos, obtendo os mesmos resultados.

A aplicação do modelo à previsão dos diâmetros apresentou resultados satisfatórios, tanto para as abordagens com a altura total e com o diâmetro mínimo comercial. Esse modelo além de reduzir significativamente o custo e o tempo de realização de um inventário está menos

susceptível a erros humanos. Assim, a MLP de forma recursiva mostrou que pode ser utilizada para auxiliar os inventários florestais.

7.3 Trabalhos Futuros

A área de inventário florestal mostrou-se bastante desafiadora e motivante. E assim, ao finalizar este trabalho diversos novos problemas puderam ser identificados.

Dinte disto, como trabalhos futuros incluem-se as seguintes linhas para pesquisa:

- Pesquisar métodos para a seleção de árvores no campo que serão utilizadas para treinar os modelos de inventários florestais e definição do número de árvores para o treino;
- desenvolver e testar um modelo para prever as alturas de árvores usando informações da base, especialmente a altura total e a altura do diâmetro mínimo comercial;
- testar os modelos propostos com plantações de eucaliptos diferentes para verificar a sua capacidade de generalização; e
- testar novos métodos de classificação das árvores para verificar a necessidade de criar ou reduzir o número de classes; e
- testar os modelos para obter o volume dos sortimentos.

7.4 Publicações Originadas Deste Trabalho

- Conferências Locais e Regionais
 - SOARES, F. A. A. M. N., FLÔRES, E. L., CABACINHA, C. D., CARRIJO, G. A., VEIGA, A. C. P., CARNEIRO, M. B. P. “Multi-Layer perceptron na predição recursiva de Diâmetros de clone de eucalipto”. *VIII Conferência de Estudos em Engenharia Elétrica (CEEL’2010)*, Uberlândia, Minas Gerais, Brasil, outubro 2010.
- Conferências Nacionais
 - SOARES, F. A. A. M. N., FLÔRES, E. L., CABACINHA, C. D., CARRIJO, G. A., VEIGA, A. C. P. “Multi-layer Perceptron na predição recursiva de clone de eucalipto”. *X Simpósio Brasileiro de Automação Inteligente (SBAI’2011)*, São João Del-Rey, MG, Brasil, setembro 2011.

- Conferências Internacionais
 - SOARES, F. A. A. M. N., FLÔRES, E. L., CABACINHA, C. D., VEIGA, A. C. P., ALEN-CAR, W. S., FREITAS, M. S. “Predição recursiva de diâmetros utilizando perceptron de múltiplas camadas para o cálculo de volume comercial de clones de eucalipto”. *Congresso de Métodos Numéricos em Engenharia* (CMNE’2011), Coimbra, Portugal, junho 2011.
- Periódicos
 - SOARES, F. A. A. M. N., FLÔRES, E. L., CABACINHA, C. D., CARRIJO, G. A., VEIGA, A. C. P. “Recursive diameter prediction and volume calculation of eucalyptus trees using Multilayer Perceptron Networks”. *Computers and Electronics in Agriculture*, Vol. 78 Issue. 1, pg. 19-27, 2011. ISSN: 0168-1699, doi:[10.1016/j.compag.2011.05.008](https://doi.org/10.1016/j.compag.2011.05.008), Elsevier.
 - SOARES, F. A. A. M. N., FLÔRES, E. L., CABACINHA, C. D., CARRIJO, G. A., VEIGA, A. C. P. “Recursive diameter prediction for calculating merchantable volume of eucalyptus clones using Multilayer Perceptron”. *Neural Computing and Applications*, Online First, pg. 1-12, 2012. ISSN: 0941-0643, doi:[10.1007/s00521-012-0823-7](https://doi.org/10.1007/s00521-012-0823-7), Springer Verlag.
 - SOARES, F. A. A. M. N., FLÔRES, E. L., CABACINHA, C. D., CARRIJO, G. A., VEIGA, A. C. P. “Recursive diameter prediction for calculating merchantable volume of Eucalyptus clones without previous knowledge of total tree height using artificial neural networks”. *Applied Soft Computing*, Online First, 2012. ISSN: 1568-4946, doi:[10.1016/j.asoc.2012.02.018](https://doi.org/10.1016/j.asoc.2012.02.018), Elsevier.

Referências Bibliográficas

- ABRAF. *Anuário Estatístico da ABRAF 2009 ano base 2008*. Brasília, 2009.
- ABRAF. *Anuário Estatístico da ABRAF 2010 ano base 2009*. Brasília, 2010.
- ABRAF. *Anuário estatístico da ABRAF 2012 ano base 2011*. Brasília, 2012.
- AHRENS, S. Análise de componentes principais e a simulação da forma do tronco. In: . Curitiba - PR: EMBRAPA, URPFCS, 1982. (Anais do SEMINÁRIO SOBRE ATUALIDADES E PERSPECTIVAS FLORESTAIS: o uso de funções de forma de tronco em estudos de volumetria de espécies florestais, v. 5), p. 77–92.
- AHRENS, S. *Funções de forma: sua conceituação e sua utilidade*. [S.l.], 2009.
- AL-HIARY, H.; BANI-AHMAD, S.; REYALAT, M.; BRAIK, M.; ALRAHAMNEH, Z. Fast and Accurate Detection and Classification of Plant Diseases. *International Journal of Computer Applications*, v. 17, n. 1, p. 31–38, 2011.
- ALFENAS, A. C.; ZAUZA, A. A. V.; MAFIA, R. G.; ASSIS, T. F. de. *Clonagem e doenças do eucalipto*. [S.l.]: Editora UFV, 2009. 500 p.
- ANDERSON, J. A.; SILVERSTEIN, J. W.; RITZ, S. A.; JONES, R. S. Distinctive features, categorical perception, and probability learning: some applications of a neural model. In: _____. Cambridge, MA: MIT Press, 1988. (Neurocomputing: foundations of research).
- ANDRADE, V. C. L.; CALEGARIO, N.; SCOLFORO, J. R. S. Análise de algumas alternativas para obter o coeficiente angular da reta no método da altura relativa. *Ciência Florestal*, v. 16, n. 3, p. 303–337, 2006.

ASIRVADAM, V.; MCLOONE, S. F.; IRWIN, G. W. Fast and Efficient Sequential Learning Algorithms using Direct-Link RBF Networks. In: *Neural Networks For Signal Processing XIII - NNNSP'03*. [S.l.]: IEEE Press, 2003. p. 209–218. ISBN 0-7803-8178-5.

ATKINSON, P.; TATNALL, A. Introduction: neural networks in remote sensing. *International Journal of Remote Sensing*, v. 18, n. 4, p. 699–709, 1997.

AVERY, T. E.; BURKHART, H. E. *Forest measurements*. 4th. ed. New York, NY, USA: McGraw-Hill, 1997. (McGraw-Hill series in forest resources).

AZNARTE M., J. L.; SÁNCHEZ, J. M. B.; LUGILDE, D. N.; FERNÁNDEZ, C. de L.; GUARDIA, C. D. de la; SÁNCHEZ, F. A. Forecasting airborne pollen concentration time series with neural and neuro-fuzzy models. *Expert Systems with Applications*, v. 32, n. 4, maio 2007.

BALEIRO, G. B. *Modelagem Neuro-Fuzzy na Estimativa de Volume de EUCALYPTUS sp.* Dissertação (Mestrado) — Universidade Federal de Lavras, Lavras - MG, 2007.

BALLINI, R.; SOARES, S.; ANDRADE, M. G. Previsão de vazões médias mensais usando redes neurais nebulosas. *Sba Controle & Automação*, Campinas, SP, v. 14, n. 3, jul. 2003.

BARBALHO, V. M. D. S. *Sistemas baseados em conhecimento e lógica difusa para simulação do processo chuva-vazão*. Tese (Doutorado) — COPPE/UFRJ, Eng. Civil, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2001.

BASHISH, D. A.; BRAIK, M.; BANI-AHMAD, S. Detection and classification of leaf diseases using K-means based segmentation and neural-networks-based classification. *Information Technology Journal*, v. 10, n. 2, p. 267–275, 2011.

BATCHELOR, W.; YANG, X.; TSCHANZ, A. Development of a neural network for soybean epidemics. *Transactions ASAE*, v. 40, p. 247–252, 1997.

BATISTA, J. L. F. *Mensuração de árvores: Uma introdução à Dendrometria*. 45 p. Dissertação (Mestrado) — Escola Superior de Agricultura "Luiz de Queiroz", Piracicaba - SP, 1998.

BENEDIKTSSON, J.; SWAIN, P.; ESROY, O. Neural network approaches versus statistical methods in classification of multisource remote sensing data. *IEEE Transaction on Geoscience and Remote Sensing*, v. 28, n. 4, p. 540–552, July 1990.

BONETES, L. *Tamanho de parcelas e intensidade amostral para estimar o estoque e índices fitossociológicos em uma floresta ombrófila mista*. Dissertação (Mestrado), Curitiba - PR, 2003.

- BORGES, J. F. *Seccionamento do fuste de Pinus taeda L. para obtenção do volume de madeira serrada através da função polinomial*. Dissertação (Mestrado) — Engenharia Florestal, Universidade Federal do Paraná, 1981.
- BRAGA, A. P.; CARVALHO, A. P. de L. F. de; LUDERNIR, T. B. *Fundamentos de Redes Neurais Artificiais*. 2nd. ed. [S.l.]: Ed. LTC, 2000.
- BRANDÃO, F. G. *Estimativa da altura total de EUCALYPTUS sp. utilizando lógica fuzzy e neuro fuzzy*. Dissertação (Mestrado) — Universidade Federal de Lavras, 2007.
- CABACINHA, C. D. *Um método para a realização do inventário florestal suprimindo a caba-gem rigorosa*. Dissertação (Mestrado) — Universidade Federal de Lavras, 2003.
- CAGNANI, A. D.; RODRIGUES, V. A.; CARVALHAIS, R. O. Inventário florestal de pinus da estação experimental de itararé - SP. In: *XXI Congresso de Iniciação Científica da UNESP*. São José do Rio Preto - SP: UNESP, 2009.
- CAMPBELL, W.; HILL, S.; CROMP, R. Automatic labeling and characterization of objects using artificial neural networks. *Telematic and Informatics*, v. 6, p. 259–271, 1989.
- CAMPOS, J. C. C. Dendrometria. In: . Viçosa - MG: Universidade Federal de Viçosa, 1988.
- CAMPOS, J. C. C. *Dendrometria - Parte I*. Viçosa: Imprensa Universitária, Universidade Federal de Viçosa, 1993. (Caderno Didático, n. 151).
- CAMPOS, J. C. C.; JÚNIOR, T. L. T.; NETO, F. P. Ainda sobre a seleção de equações de volume. *Revista Árvore*, v. 9, n. 9, p. 115–126, 1985.
- CAMPOS, J. C. C.; ZUCONI, J. M.; RIBEIRO, J. C. Teste de um novo modelo para expressar “taper”. In: *Anais SEMINÁRIO SOBRE ATUALIDADES E PERSPECTIVAS FLORESTAIS: o uso de funções de forma de tronco em estudos de volumetria de espécies florestais*. Curitiba - PR: EMBRAPA, URPFCS, 1982. v. 5, p. 47–50.
- CANTO, E. L. do. *CIÊNCIAS NATURAIS: aprendendo com o Cotidiano*. 2^a edição. ed. [S.l.]: Editora Moderna, 2004.
- CARUANA, R.; LAWRENCE, S.; GILES, L. Overfitting in Neural Nets: Backpropagation, Conjugate Gradient, and Early Stopping. In: *Advances in Neural Information Processing Systems 13*. [S.l.: s.n.], 2001.
- CHEN, H.; MANRY, M.; CHANDRASEKARAN, H. A neural network training algorithm utilizing multiple sets of linear equations. *Neurocomputing*, v. 25, n. 1-3, p. 55–72, 1999.

- CIVCO, D. L. Artificial neural networks for land cover classification and mapping. *International Journal of Geographical Information Systems*, v. 7, n. 2, p. 173–186, 1993.
- COOK, D.; WOLFE, M. A back-propagation neural network to predict average air temperature. *AI Applications*, v. 5, p. 40–46, 1991.
- COUTO, H. T. Z. do; BASTOS, N. L. M. *Erros de medição de altura em povoamentos de Eucalyptus em região plana*. [S.l.], 1988. 21–31 p.
- COUTO, H. T. Z. do; BASTOS, N. L. M.; LACERDA, J. S. de. A amostragem por pontos na estimativa de área basal em povoamentos de eucalyptus. IPEF, v. 46, p. 86–95, 1993.
- CYBENCO, G. Approximation by superpositions of a sigmoidal function. *Mathematics of Control, Signals and Systems*, v. 2, n. 4, p. 303–314, 1989.
- DEADMAN, P.; GIMBLETT, H. Applying neural networks to vegetation management plan development. *AI Application*, v. 11, p. 107–112, 1997.
- DECATUR, S. E. Application of neural networks to terrain classification. In: *Proceedings of International Joint Conference on Neural Networks*. [S.l.: s.n.], 1989. v. 1, p. 283–288.
- DERR, V.; SLUTZ, R. Prediction of El Niño events in the Pacific by means of neural networks. *AI Applications*, v. 8, p. 51–63, 1994.
- DIAMANTOPOULOU, M. J. Artificial neural networks as an alternative tool in pine bark volume estimation. *Computers and Electronics in Agriculture*, v. 48, n. 3, p. 235–244, set. 2005.
- DIAMANTOPOULOU, M. J. Predicting fir trees stem diameters using Artificial Neural Network models. *Southern African Forestry Journal*, v. 205, n. 1, p. 39–44, nov. 2005.
- DIAMANTOPOULOU, M. J. Tree-Bole Volume Estimation on Standing Pine Trees Using Cascade Correlation Artificial Neural Network Models. *Agricultural Engineering International: The CIGR EJournal*, VIII, 2006.
- DIAMANTOPOULOU, M. J.; MILIOS, E. Modelling total volume of dominant pine trees in reforestation via multivariate analysis and artificial neural network models. *biosystems engineering*, v. 105, n. 3, p. 306–315, mar. 2010.
- DOAN, C. D.; LIONG, S.-Y. Generalization for multilayer neural network bayesian regularization or early stopping. In: *APHW2004 Conference*. [S.l.: s.n.], 2004.

- DOWNEY, I.; POWER, C.; KANELLOPOULOS, I.; WILKINSON, G. G. A performance comparison of Landsat Thematic mapper land cover classification based on neural network techniques and traditional maximum likelihood algorithms and minimum distance algorithms. In: *Proceeding of the Annual Conference of the Remote Sensing Society*. [S.l.: s.n.], 1992. p. 518–528.
- EHRMAN, J.; CLAIR, T.; BOUCHARD, A. Using neural networks to predict pH changes in acidified eastern Canadian lakes. *AI Applications*, v. 10, p. 1–8, 1996.
- ELGAALI, E.; GARCIA, L. Neural network Modelling of Climate Changes Impacts on Irrigation Watter Supplies in Arkansas River Basin. *Hydrology Days*, 2004.
- FIGUEIREDO FILHO, A.; BORDERS, B. E.; HITCH, K. L. Taper equations for *Pinus taeda* plantations in Southern Brazil. *Forest Ecology and Management*, v. 83, p. 39–46, 1996.
- FIGUEIREDO FILHO, A.; OLIVEIRA, C.; MOURA, J. Conservação de equações de volume em equações de forma compatíveis para *Pinus elliottii*. In: . Curitiba - PR: SBS/SBEF, 1993. (Anais do CONGRESSO FLORESTAL PANAMERICANO - 1º CONGRESSO FLORESTAL BRASILEIRO, v. 7), p. 501–504.
- FINGER, C. A. G. *Fundamentos de Biometria Florestal*. Santa Maria: UFSM/CEPEF/FATEC, 1992.
- FINGER, C. A. G.; ZANON, M. L. B.; SCHNEIDER, P. R. Funções de forma para *Eucalyptus dunnii* Maiden, implantados na depressão central e encosta do sudeste do Rio Grande do Sul. *Ciência Rural*, v. 25, n. 3, p. 399–403, 1995.
- FOX-RABINOVITZ, M. S.; KRASNOPOLSKY, V.; BELOCHITSKI, A. Ensemble of Neural Network Emulations for Climate Model Physics: The Impact on Climate Simulations. In: *International Joint Conference on Neural Networks*. Vancouver, Canadá: [s.n.], 2006.
- FRANCL, L.; PANIGRAHI, S. Artificial neural network models of wheat leaf wetness. *Agricultural and Forest Meteorology*, v. 88, p. 57–65, 1997.
- FRANCL, L.; PANIGRAHI, S.; PAHDI, T. Neural network models that predict leaf wetness. *Phytopathology*, v. 85, p. 1182, 1995.
- FRANCO, E. J. *Estudo dos métodos estimativos de volume, biomassa e níveis de produtividade para Eucalyptus camaldulensis*. Dissertação (Mestrado) — Universidade Federal de Lavras, Lavras - MG, 1995.

- FREITAG, Â. S. *Frequencias de irrigação para Eucalyptus grandis e Pinus elliotti em viveiro*. Dissertação (Mestrado), Santa Maria - RS, 2007.
- FRIEDL, R. A. *Dinâmica de forma dos fustes em povoamentos plantados de Araucaria angustifolia (Bert.) O. Ktze*. Dissertação (Mestrado) — Engenharia Florestal - Universidade Federal do Paraná, Curitiba - PR, 1989.
- FROSSYNIOTIS, D.; ANTHOPOULOS, Y.; KINTZIOS, S.; MOSCHOPPOULOU, G.; YIALOURIS, C. P. Artificial Neural Network Selection for the Detection of Plant Viruses. *World Journal of Agricultural Sciences*, v. 4, n. 1, p. 114–120, 2008.
- FUNAHASHI, K. On the approximate realization of continuous mappings by neural networks. *Neural Networks*, v. 2, p. 183–192, 1989.
- GARCIA, S. L. R.; LEITE, H. G.; YARED, J. A. G. Análise do perfil do tronco de Morototó (*Didymopanax morototoni*) em função do espaçamento. In: *Anais do CONGRESSO FLORESTAL PANAMERICANO, 1º - CONGRESSO FLORESTAL BRASILEIRO*. Curitiba - PR: SBS/SBEF, 1993. v. 7, p. 485–491.
- GERTNER, G. The need to improve models for individual tree mortality. In: *Proceedings of Seventh Central Hardwood Conference*. Carbondale, Illinois: [s.n.], 1989. v. 7, p. 59–61.
- GOLFARI, L.; CASER, L. R.; MOURA, V. P. G. *Zoneamento ecológico esquemático para reflorestamento no Brasil*. 2nd. ed. Brasília: Centro de Pesquisa Florestal da Região do Cerrado, 1978. (Série Técnica, 11 Série técnica.).
- GOMES, A. M. A. *Medição dos arvoredos*. Lisboa: Livraria Sá da Costa, 1957.
- GONG, P. Integrated analysis of spatial data from multiple sources: An overview. *Photogrammetric Engineering and Remote Sensing*, v. 62, n. 5, 1996.
- GONG, P.; CHEN, J. Mapping ecological land systems and classification uncertainties from digital elevation and forest-cover data using neural network. *Photogrammetric Engineering and Remote Sensing*, v. 62, n. 11, p. 1249–1260, novembro 1996.
- GÖRGENS, E. B. *Estimação do Volume de Árvores Utilizando Redes Neurais Artificiais*. Dissertação (Mestrado) — Universidade Federal de Viçosa, 2006.
- GÖRGENS, E. B.; LEITE, H. G.; do Nascimento, H.; GLERIANI, J. M. Estimação do volume de árvores utilizando redes neurais artificiais. *Revista Árvore*, v. 33, n. 6, dez. 2009.

- GROSSBERG, S. A prediction theory for some nonlinear functional-differential equations, I: Learning of lists. *Journal of Mathematical Analysis and Applications*, v. 21, p. 643–694, 1968.
- GROSSBERG, S. A prediction theory for some nonlinear functional-differential equations, II: Learning of patterns. *Journal of Mathematical Analysis and Applications*, v. 22, p. 490–522, 1968.
- GUAN, B. T.; GERTNER, G. Modeling red pine tree survival with an artificial neural network. *Forest Science*, v. 37, n. 5, p. 1429–1440, nov. 1991.
- GUAN, B. T.; GERTNER, G. Using a Parallel Distributed Processing System to Model Individual Tree Mortality. *Forest Science*, v. 37, n. 3, p. 871–885, ago. 1991.
- GUAN, B. T.; GERTNER, G.; PARYSOW, P. A framework for uncertainty assessment of mechanistic forest growth models: A neural network example. *Ecological Modelling*, v. 98, n. 1, p. 47–58, maio 1997.
- GUIOT, J.; CHEDDADI, R.; PRENTICE, I.; JOLLY, D. A method of biome and land surface mapping from pollen data: Application to Europe 6000 years ago. *Palaeoclimate*, v. 1, p. 311–324, 1996.
- HAGAN, M.; MENHAJ, M. Training feed forward networks with the Marquardt algorithm. In: *IEEE Transactions on Neural Networks*. [S.l.]: IEEE, 1994. v. 6, p. 861–867.
- HASENAUER, H.; MERKL, D. Forest tree mortality simulation in uneven-aged stands using connectionist networks. In: *Proceedings of International Conference on Engineering Applications of Neural Networks (EANN'97)*. Stockholm, Sweden: [s.n.], 1997. (In: Bulsari, A. B., and S. Kallio (eds.). *Neural Networks in Engineering*), p. 341–348.
- HAYKIN, S. *Redes neurais - princípios e práticas*. [S.l.]: Bookman, 2001.
- HEBB, D. *The organization behavior: A Neuropsychological Theory*. New York, NY, USA: John Wiley & Sons, 1949.
- HEERMANN, P.; KHAZENIE, N. Classification of multispectral remote sensing data using a back-propagation neural network. *IEEE Transactions on Geoscience and Remote Sensing*, v. 30, n. 1, p. 81–88, jan. 1992.
- HEPNER, G. F.; LOGAN, T.; RITTER, N.; BRYANT, N. Artificial neural network classification using a minimal training set - Comparison to conventional supervised classification. *Photogramm Eng Remote Sensing*, v. 56, n. 4, 1990.

- HEPNER, G. F.; RITTER, N. D. Application of an artificial neural network to land-cover classification of thematic mapper imagery. *Computers & Geosciences*, v. 16, n. 6, p. 873–880, 1990.
- HERTZ, J. A.; KROGH, A. S.; PALMER, R. G. *Introduction to the Theory of Neural Computation*. [S.l.]: Addison-Wesley, 1991.
- HOPFIELD, J. Neural Networks and physical systems with emergent collective computational abilities. In: *Proceedings of the National Academy of Sciences of the U.S.A.* [S.l.: s.n.], 1982. v. 79, p. 2554–2558.
- HOSOKAWA, R.; SOUZA, A. *Amostragem para fins de manejo*. [S.l.], 1987. v. 5, 25p p.
- HUANG, J.; ZHAO, J.; GAO, G.; MENG, X.; GUAN, Y. Prediction of Stand Diameter Distribution with Artificial Neural Network. In: *2009 Fifth International Conference on Natural Computation*. [S.l.: s.n.], 2009.
- HUANG, W.; LIPPMANN, R. Comparisons between neural net and conventional classifiers,. In: *IEEE First International Conference on Neural Networks*. [S.l.: s.n.], 1987.
- HUSCH, B.; MILLER, C. L.; BEERS, T. E. *Forest mesurantion*. 3rd. ed. New York, NY, USA: J. Willey & Sons, 1982.
- IMAÑA-ENCINAS, J.; REZENDE, A. V.; IMAÑA, C. R.; SANTANA, O. A. *Contribuição dendrométrica nos levantamentos fitossociológicos*. Brasília, set. 2009.
- JAN, J. F. Artificial neural networks for classification of remote sensing data. *Quarterly Journal of the Experimental Forest of National Taiwan University*, v. 11, p. 79–89, 1997.
- JI, Y.; HAO, J.; REYHANI, N.; LENDASSE, A. Direct and Recursive Prediction of Time Series Using Mutual Information Selection. In: *IWANN 2005, Lecture Notes in Computer Science*. [S.l.]: Springer Verlag, 2005. v. 3512, p. 1010–1017.
- JIN, Q.; 1997, C. L. Biomass retrieval from highdimensional active/passive remote sensing data by using artificial neural networks. *International Journal of Remote Sensing*, v. 18, p. 971–979, 1997.
- JÚNIOR, J. E. P.; AHRENS, S. *Cultura de Eucalipto - Aspectos socioeconômicos, ambientais e legais da eucaliptocultura*. 2nd. ed. Embrapa Florestas, 2003. (Sistemas de Produção, 4). ISSN 1678-8281. Disponível em: <http://sistemasdeproducao.cnptia.embrapa.br/FontesHTML/Eucalipto/CultivodoEucalipto_2ed/Aspectos_Eucaliptocultura.htm>.

- JUVENAL, T. L.; MATTOS, R. L. G. *O setor florestal no Brasil e a importância do reflorestamento*. [S.l.], set. 2002. 3–30 p.
- KARLIK, B.; OLGAC, A. V. Performance Analysis of Various Activation Functions in Generalized MLP Architectures of Neural Networks. *International Journal of Artificial Intelligence and Expert Systems*, Computer Science Journals, Malaysia, v. 1, n. 4, p. 111–122, 2010. ISSN 2180124X.
- KELLER, T. *Elaborion d'une base de données en dendroclimatologie en vue d'une reconstruction climatique dans les Alpes et la région méditerranéenne*. 33 p. Dissertação (Mestrado) — Mémoire de DEA de l'Université Aix-Marseille III, 1994.
- KNUTTI, R.; STOCKER, T. F.; JOOS, F.; PLATTNER, G.-K. Probabilistic climate change projections using neural networks. *Climate Dynamics*, v. 21, p. 257–272, 2003.
- KÖEHLER, H. S. Funções de forma em inventários florestais: implementação e processamento do sistema. In: *Anais do SEMINÁRIO SOBRE ATUALIDADES E PERSPECTIVAS FLORESTAIS: o uso de funções de forma de tronco em estudos de volumetria de espécies florestais*. [S.l.]: EMBRAPA, URPFCS, 1982. v. 5, p. 93–96.
- KOZAK, A.; MUNRO, D. D.; SMITH, J. H. G. Taper Functions and their Applications in Forest Inventory. *Forest Chronicle*, v. 45, n. 4, p. 278–283, 1969.
- KRAMER, A. H.; SANGIOVANNI-VINCENTELLI, A. *Efficient parallel learning algorithms for neural networks*. San Francisco, CA: Morgan Kaufmann Publishers, 1989. (Advances in neural information processing systems 1).
- LARSON, P. R. Stem form development of forest tree. *Washington: Forest Science Monographs*, p. 1–41, 1963.
- LEDUC, D. J.; MATNEY, T. G.; BELL, K. L.; JR., V. C. B. Book, Online. *Predicting diameter distributions of longleaf pine plantations [electronic resource] : a comparison between artificial neural networks and other accepted methodologies / Daniel J. Leduc ... [et al.]*. [S.l.]: U.S. Dept. of Agriculture, Forest Service, Southern Research Station, Asheville, NC :, 2001. 18 p. : p.
- LEE, C.-M.; KO, C.-N. Time series prediction using RBF neural networks with a nonlinear time-varying evolution PSO algorithm. *Neurocomputing*, v. 73, n. 1-3, p. 449–460, dez. 2009.

- LEE, E.; SEONG, C.; KIM, H.; PARK, S.; KANG, M. Predicting the impacts of climate change on nonpoint source pollutant loads from agricultural small watershed using artificial neural network. *Journal of Environmental Sciences*, v. 22, n. 6, p. 840–845, 2010.
- LEE, Y.; OH, S.; KIM, M. The effect of initial weights on premature saturation in back-propagation learning. In: *International Joint Conference on Neural Networks*. Seattle, WA , USA: [s.n.], 1991. v. 1, p. 765–770.
- LEITE, H. G.; ANDRADE, V. C. L. A method for conducting forest inventories without using volumetric equations. *Revista Árvore*, v. 26, n. 3, 2002.
- LEITE, H. G.; GUIMARÃES, D. P. Um novo modelo para descrever o perfil do tronco. *Revista Árvore*, v. 16, n. 2, 1992.
- LEVINE, E.; KIMES, D. Predicting soil carbon in Mollisols using neural networks. In: _____. [S.I.]: CRC Press, 1997. (Soil Processes and the Carbon Cycle, R. Lal, J.K. Kimble, and R.F. Follett (eds.)), p. 608.
- LIMA, A. G. de; GUERREIRO, A. M. G. Uso das redes neurais de função de base radial e Growing Neural Gas na classificação de imagens de sensoriamento remoto. In: *Anais XV Simpósio Brasileiro de Sensoriamento Remoto - SBSR*. São José dos Campos, SP: Instituto Nacional de Pesquisas Espaciais (INPE), 2011. p. 7247–7254.
- LITTLE, W.; SHAW, G. A statistical theory of short and long term memory. *Behavioral Biology*, v. 14, p. 115–133, 1975.
- LODWICH, A.; RANGONI, Y.; BREUEL, T. Evaluation of robustness and performance of early stopping rules with multi layer perceptrons. In: *2009 international joint conference on Neural Networks*. [S.I.: s.n.], 2009.
- LOETSCH, F.; ZOHRER, F.; HALLER, K. E. *Forest Inventory*. 2nd. ed. [S.I.]: BLV Verlagsgesellschaft, 1973. (Inventory data collected by terrestrial measurements and observations, data processing in forest inventory, II).
- MACHADO, S.; FIGUEIREDO FILHO, A. *Dendrometria*. Curitiba: UFPR, 2003.
- MACHADO, S. A.; NADOLNY, M. C. Comparação de métodos de cubagem rigorosa e de diversos comprimentos de seção. In: *CONGRESSO FLORESTAL E DO MEIO AMBIENTE DO PARANÁ*. Curitiba - PR: SBS-SBEF, 1991. v. 3.

MACHADO, S. A.; NADOLNY, M. C. Acuracidade da cubagem rigorosa de árvores pelos métodos de Hohenadl, FAO e Gráfico, comparativamente ao xilômetro. In: *CONGRESSO FLORESTAL PANAMERICANO, 1º CONGRESSO FLORESTAL BRASILEIRO*. Curitiba - PR: SBS-SBEF, 1993. v. 7, p. 478–480.

MACHADO, S. do A.; TÉO, S. J.; URBANO, E.; FIGURA, M. A.; SILVA, L. C. R. da. Comparação de métodos de cubagem absolutos com volume obtido pelo xilômetro para Bracatinga (*Mimosa scabrella* Bentham). *Cerne, Lavras*, Universidade Federal de Lavras, Lavras - MG, v. 12, n. 3, p. 239–253, jul. 2006.

MACHADO, S. do A.; URBANO, E.; CONCEICAO, M. B. da; FILHO, A. F.; FIGUEIREDO, D. J. de. *Comparação de modelos de afilamento de tronco para diferentes idades e regimes de desbaste em plantações de Pinus oocarpa Schiede*. [S.l.], 2004. 41–64 p.

MAIER, H.; DANDY, G.; BURCH, M. Use of artificial neural networks for modeling cyanobacteria *Anabaena* spp. in the River Murray, South Australia. *Ecol. Model.*, v. 105, p. 257–272, 1998.

MANASSÉS, J. P.; PEICHL, B. Medição da madeira e inventário florestal. In: _____. Campo Largo: Ingra S. A., 1986. (Manual do Técnico Florestal; Apostila do Colégio Florestal de Irati, v. 3), p. 88.

MARQUARDT, D. An algorithm for least squares estimation of non-linear parameters. *Journal of the society of Industrial and Applied Mathematics*, p. 431–441, 1963.

MASA, J.; PUIG, H.; PALACIO, J.; SOSA-LÓPEZ, A. Modelling deforestation using GIS and artificial neural networks. *Environmental Modelling & Software*, v. 19, n. 5, p. 461–471, maio 2004.

MAX, T. A.; BURKHART, H. E. Segmented polinomial regression applied to taper equations. *Forest Science*, v. 22, n. 33, p. 283–289, 1976.

MCCLELLAND, G. E.; DEWITT, R.; HEMMER, T.; MATHESON, L.; MOE, G. Multispectral image-processing with a three-layer back-propagation network. In: *Proceedings of International Joint Conference on Neural Networks*. [S.l.: s.n.], 1989. v. 1, p. 151–153.

MCCLENDON, R.; BATCHELOR, W. Insect pest management neural network. *American Society of Agricultural Engineers, St. Joseph, Michigan, ASAE Paper*, n. 95-3560, 1995.

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

- MCTAGUE, J. P.; BATISTA, J. L. F.; STEINER, L. H. *Equações de volume total, volume comercial e forma do tronco para plantações de Eucalyptus nos estados de São Paulo e Rio de Janeiro*. [S.l.], 1989. v. 41/42, 56–63 p.
- MINSKY, M.; PAPERT, S. *Perceptrons: an introduction to computational geometry*. Cambridge, MA: MIT Press, 1969.
- MINSKY, M. L. *Theory of neural-analog reinforcement systems and its application to the brain-model problem*. Tese (Doutorado) — Princeton University, Princeton, NJ, 1954.
- MØLLER, M. F. A scaled conjugate gradient algorithm for fast supervised learning. *Neural Networks*, v. 6, n. 4, p. 525–533, 1993.
- MOOSAVIZADEH-MOJARRAD, R.; SEPASKHAH, A. R. Predicting soil water retention curve by artificial neural networks. *Archives of Agronomy and Soil Science*, v. 57, n. 1, p. 3–13, 2011.
- MORA, A. L.; GARCIA, C. H. A cultura do eucalipto no Brasil. SBS-SBEF, p. 112, 2000.
- MOURA, J. B. *Estudo da forma do fuste e comparação de métodos de estimativas volumétricas de espécies florestais da Amazônia Brasileira*. Dissertação (Mestrado) — Engenharia Florestal - Universidade Federal do Paraná, Curitiba - PR, 1994.
- MUNRO, D. D.; DEMAERSCHALK, J. Taper-based versus volume based compatible estimating systems. *Forest Chronicle*, v. 50, n. 5, p. 197–199, 1974.
- N.A, L.; KHALID, F.; BORHAN, N. Classification of Herbs Plant Diseases via Hierarchical Dynamic Artificial Neural Network after Image Removal using Kernel Regression Framework. *International Journal on Computer Science and Engineering*, v. 3, n. 1, p. 15–20, jan 2011.
- NETO, F. P. Tabelas volumétricas com e sem casca para Eucalyptus grandis. *Revista Árvore*, v. 1, n. 1, p. 31–54, jan/jun 1977.
- NEUMANN, J. von. Probabilistic Logics and the Synthesis of Reliable Organisms from Unreliable Components. In: _____. [S.l.]: C.E. Shannon and J. McCarthy eds., 1956. (Automata Studies), p. 329–378.
- NG, G. W. *Application of neural networks to adaptive control of nonlinear systems*. Control System Centre, UMIST, UK: John Wiley & Sons, 1997.

ÖZÇELIK, R.; DIAMANTOPOULOU, M. J.; BROOKS, J. R.; JR., H. V. W. Estimating tree bole volume using artificial neural network models for four species in Turkey. *Journal of Environmental Management*, v. 91, n. 3, p. 742–753, 2010. ISSN 0301-4797.

PEDDLE, D.; FOODY, G.; ZHANG, A.; FRANKLIN, S.; LEDREW, E. Multisource image classification II: an empirical comparison of evidential reasoning, linear discriminant analysis, and maximum likelihood algorithms for alpine land cover classification. *International Journal of Remote Sensing*, v. 20, p. 397–408, 1994.

PEREIRA, J. E. da S.; ANSUJ, A. P.; MÜLLER, I.; AMADOR, J. P. Modelagem do volume do tronco do Eucalyptus grandis Hill ex Maiden. In: *Anais do XII SIMPEP*. Bauru - SP: [s.n.], 2009.

PEYRON, O.; GUIOT, J.; CHEDDADI, R.; TARASOV, P.; REILLE, M.; BEAULIEU, J.-L. de; BOTTEMA, S.; ANDRIEU, V. Climate reconstruction in Europe for 18,000 yr. BP from pollen data. *Quaternary Research*, v. 49, n. 2, p. 183–196, 1998.

PIERCE, L.; SARABANDI, D.; ULABY, F. T. Application of artificial neural networks in canopy scattering inversion. *IEEE Transaction on Geoscience and Remote Sensing*, v. 91, p. 1067–1069, 1992.

PIJANOWSKI, B. C.; BROWN, D. G.; SHELLITO, B. A.; MANIK, G. A. Using neural networks and GIS to forecast land use changes: a Land Transformation Model. *Computers, Environment and Urban Systems*, v. 26, n. 6, p. 553–575, nov. 2002.

PINHEIRO, G. S.; VEIGA, R. A. A. Comparação de modelos de equações de volume para espécies do gênero Pinus na estação experimental de Mogi Guaçu-SP. *Boletim Técnico do Instituto Florestal*, São Paulo - SP, v. 38, n. 1, p. 83–93, maio 1984.

PIRES, L. M.; CALEGARIO, N. Ajuste de modelos estocásticos lineares e não-lineares para a descrição do perfil longitudinal de árvores. *Revista Árvore*, v. 31, n. 5, p. 845–852, 2007.

PRADHAN, B.; LEE, S.; BUCHROITHNER, M. F. A GIS-based Back-propagation Neural Network Model and its Cross-application and Validation for Landslide Susceptibility Analyses. *Computers, Environment and Urban Systems*, mar. 2010.

RANSON, K. J.; MASEK, J.; FU, A.; WANG, D. Predicting tree height and biomass from GLAS DATA. In: *10th International Symposium on Physical Measurements and Signatures in Remote Sensing - ISPMSRS'07*. [S.l.: s.n.], 2007.

- RAVEN, P. H.; EVERT, R. F.; EICHHORN, S. E. *Biologia vegetal*. Rio de Janeiro: Guanabara Koogan, 2007.
- RECKNAGEL, F.; FRENCH, M.; HARKONEN, P.; YABUNAKA, K. Artificial neural network approach for modelling and prediction of algal blooms. *Ecol. Model.*, v. 96, p. 11–28, 1997.
- RIBEIRO, S. P.; CORBARA, B. Dossel florestal: a fronteira desconhecida. *Ciência Hoje*, Instituto Ciência Hoje, Rio de Janeiro, v. 37, n. 217, jul. 2005.
- RICHARDSON, D. M.; RUNDEL, P. Ecology and biogeography of *Pinus* - an introduction. In: _____. *Ecology and Biogeography of Pinus*. Cambridge: Cambridge University Press, 1998. p. 530.
- RIDMILER, M. Advanced supervised learning in multi-layer perceptrons - from back-propagation to adaptive learning algorithms. *Neural Networks*, v. 5, 1994.
- RITTER, N.; LOGAN, T.; BRYANT, N. Integration of neural network technologies with geographic information systems. In: *GIS Symposium - Integrating Technology and Geoscience Applications*. Denver, CO: [s.n.], 1988. p. 102–103.
- ROCHA, J. C. O. *Influência da seca de ponteiros na seleção de modelos volumétricos para Eucalyptus camaldulensis e Eucalyptus citriodora*. Dissertação (Mestrado) — Universidade Federal de Viçosa, Viçosa - MG, 1992.
- RODRÍGUEZ-RAJO, F.; ASTRAY, G.; FERREIRO-LAGE, J.; AIRA, M.; JATO-RODRIGUEZ, M.; MEJUTO, J. Evaluation of atmospheric Poaceae pollen concentration using a neural network applied to a coastal Atlantic climate region. *Neural Networks*, v. 23, n. 3, p. 419–425, 2010.
- ROSENBLATT, F. The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, v. 65, n. 6, nov. 1958.
- RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning internal representations by error propagation. In: _____. Cambridge, MA: MIT Press, 1986. (Parallel distributed processing: explorations in the microstructure of cognition, vol. 1), p. 318–362.
- RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning representations by back-propagating errors. *Nature*, v. 323, p. 533–536, out. 1986.
- RYAN, T.; SEMENTILLI, P.; YUEN, P.; HUNT, B. Extractions of shoreline features by neural nets and image processing. *Photogrammetric Engineering and Remote Sensing*, v. 57, p. 947–955, 1991.

- SAFI, Y.; BOUROUMI, A. A neural network approach for predicting forest fires. In: *International Conference on Multimedia Computing and Systems (ICMCS)*. [S.l.: s.n.], 2011.
- SCHNEIDER, P. R. *Introdução ao manejo florestal*. Santa Maria - RS: UFSM / CEPEF-FATEC, 1993.
- SCHNEIDER, P. R.; FINGER, C. A. G.; KLEIN, J. E. M.; TOTTI, J. A.; BAZZO, J. L. Forma de tronco e sortimentos de madeira de *Eucalyptus grandis* Maiden para o estado do Rio Grande do Sul. *Ciência Florestal*, v. 6, n. 1, p. 79–88, 1996.
- SCOLFORO, J. *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, 2005.
- SCOLFORO, J. R. S. *Técnica de regressão aplicada para estimar: volume, biomassa, relação hipsométrica e múltiplos produtos da madeira*. Lavras - MG: UFLA/FAEPE, 1997.
- SCOLFORO, J. R. S.; FIGUEIREDO FILHO, A. *Mensuração florestal 2: volumetria*. Lavras - MG: Lavras: ESAL/FAEPE, 1993.
- SCOLFORO, J. R. S.; MELLO, J. M.; LIMA, C. S. A. Obtenção de relações quantitativas para estimativa de volume do fuste em floresta estacional semidecídua montana. *Cerne, Lavras*, n. 1, p. 123–134, 1994.
- SEBEM, E. *Desenvolvimento e aplicabilidade de uma base de dados relacional para o inventário florestal contínuo do Rio Grande do Sul*. Dissertação (Mestrado), Santa Maria - RS, 2000.
- SERPA, P. N.; VITAL, B. R.; Della Lucia, R. M.; PIMENTA, A. S. Avaliação de algumas propriedades da madeira de *Eucalyptus grandis*, *Eucalyptus saligna* e *Pinus elliottii*. *Revista Árvore*, v. 27, n. 5, p. 723–733, 2003.
- SILVA, J. A. *Seleção de parcelas amostrais aplicadas em povoamentos de *Pinus taeda L.* para fins biométricos em Santa Maria - RS*. Dissertação (Mestrado) — Engenharia Rural - Universidade Federal de Santa Maria, 1974.
- SILVA, J. A. Funções de forma dos troncos de *Pinus taeda*, *Picea excelsa*, *Abies alba* e *Pinus sylvestris*. In: *SEMINÁRIO SOBRE ATUALIDADES E PERSPECTIVAS FLORESTAIS: o uso de funções de forma de tronco em estudos de volumetria de espécies florestais*. Curitiba - PR: EMBRAPA, URPFCS, 1982. v. 5, p. 29–45.
- SILVA, J. A. A. da; NETO, F. de P. *Princípios básicos da dendrometria*. Recife - PE: Imprensa Universitária da Universidade Federal Rural de Pernambuco, 1979.

SILVA, L. N. C. *Análise e síntese de Estratégias de Aprendizado para Redes Neurais*. Dissertação (Mestrado) — Faculdade de Engenharia Elétrica e de Computação - Unicamp, Campinas, SP, 1998.

SILVA, M. L. M.; BINOTI, D. H. B.; GLERIANI, J. M.; LEITE, H. G. Ajuste do modelo de Schumacher e Hall e aplicação de redes neurais artificiais para estimar volume de árvores de Eucaplıto. *Revista Árvore*, v. 33, n. 6, p. 1133–1139, 2009.

SILVA, R. M. A.; BRANDÃO, F. G.; BALEIRO, G. B.; VALENTIM, F. L.; MENDONCA, A. R.; PIRES, D. M. Fuzzy and neuro-fuzzy estimates of the total height of eucalyptus trees. In: *2008 ACM symposium on Applied Computing*. New York, NY, USA: ACM, 2008. p. 1772–1776. ISBN 978-1-59593-753-7.

SOARES, C. P. B.; NETO, F. P.; SOUZA, A. L. *Dendrometria e inventário florestal*. [S.l.]: Ed. UFV, 2006. 276 p.

SOARES, F. A. A. M. N.; FLÔRES, E. L.; CABACINHA, C. D.; CARRIJO, G. A.; VEIGA, A. C. P.; CARNEIRO, M. B. P. Multi-Layer perceptron na predição recursiva de Diâmetros de clone de eucalipto. In: *VIII Conferência de Estudos em Engenharia Elétrica (CEEL'2010)*. [S.l.: s.n.], 2010.

SOARES, F. A. A. M. N.; FLORES, E. L.; CABACINHA, C. D.; CARRIJO, G. A.; VEIGA, A. C. P. Multi-layer Perceptron na predição recursiva de clone de eucalipto. In: *X Simpósio Brasileiro de Automação Inteligente (SBAI'2011)*. [S.l.: s.n.], 2011.

SOARES, F. A. A. M. N.; FLORES, E. L.; CABACINHA, C. D.; CARRIJO, G. A.; VEIGA, A. C. P.; ALENCAR, W. de S.; FREITAS, M. da S. Predição recursiva de diâmetros utilizando perceptron de múltiplas camadas para o cálculo de volume comercial de clones de eucalipto. In: *Congresso de Métodos Numéricos em Engenharia (CMNE'2011)*. [S.l.: s.n.], 2011.

SOARES, F. A. A. M. N.; FLORES, E. L.; CABACINHA, C. D.; CARRIJO, G. A.; VEIGA, A. C. P. Recursive diameter prediction and volume calculation of eucalyptus trees using Multilayer Perceptron Networks. *Computers and Electronics in Agriculture*, Elsevier, v. 78, n. 1, p. 19–27, 2011.

SOARES, F. A. A. M. N.; FLORES, E. L.; CABACINHA, C. D.; CARRIJO, G. A.; VEIGA, A. C. P. Recursive diameter prediction for calculating merchantable volume of eucalyptus clones using Multilayer Perceptron. *Neural Computing and Applications (Online First)*, Springer Verlag, 2012.

- SOARES, F. A. A. M. N.; FLORES, E. L.; CABACINHA, C. D.; CARRIJO, G. A.; VEIGA, A. C. P. Recursive diameter prediction for calculating merchantable volume of Eucalyptus clones without previous knowledge of total tree height using artificial neural networks. *Applied Soft Computing (Azeito para Publicação)*, Elsevier, 2012.
- SOARES, N. S. *Análise da competitividade e dos preços da celulose e da madeira de eucalipto no Brasil*. Tese (Doutorado), Viçosa - MG, 2010.
- SOARES, N. S.; SILVA, M. L. da; REZENDE, J. L. P. de; GOMES, M. F. M. Competitividade da cadeia produtiva da madeira de eucalipto no Brasil. *Revista Árvore*, v. 34, n. 5, 2010. ISSN 0100-6762.
- STONE, M. Cross-validatory choice and assessment of Statistical Predictions. *Journal of the Royal Statistical Society*, v. 36, n. 2, 1974.
- SUI, D. A neural network-based GIS approach to spatial decision making. *The Operational Geographer*, v. 11, p. 12–20, 1993.
- SUI, D. Recent applications of neural networks for spatial data handling. *Photogrammetric Engineering and Remote Sensing*, v. 20, p. 368–380, 1994.
- TAMARI, S.; WÖSTEN, J. H. M.; RUIZ-SUÁREZ, J. Testing an artificial neural network for predicting soil hydraulic conductivity. *Soil Sci. Am. J. Soil Science Society of America journal*, v. 60, n. 6, p. 1732–1741, 1996.
- TAN, Y.; VAN CAUWENBERGHE, A. Optimization Techniques for the Design of a Neural Predictive Controller. *Neurocomputing*, v. 10, n. 1, p. 83–96, 1996.
- TANGANG, F.; B.TANG; MONAHAN, A.; HSIEH, W. W. Forecasting ENSO events: A neural network - extended EOF approach. *Journal of Climate*, v. 11, p. 29–41, 1998.
- TANGANG, F.; HSIEH, W. W.; TANG, B. Forecasting the equatorial pacific temperatures by neural network models. *Climate Dynamics*, v. 13, p. 135–147, 1997.
- THEODORIDIS, S.; KOUTROUMBAS, K. *Pattern Recognition, Third Edition*. Orlando, FL, USA: Academic Press, Inc., 2006. 856 p. ISBN 0123695317.
- TSANG, L.; CHEN, Z.; S. Oh, R.; II, M.; CHANG, A. Inversion of snow parameters from passive microwave remote sensing measurements by a neural network trained with a multiple scattering model. *IEEE Transaction on Geoscience and Remote Sensing*, n. 30, p. 1015–1024, 1992.

- VALENTINE, H. T. A carbon balance model of stand growth: A derivation employing pipe-model theory and the self-thinning rule. *Annals of Botany*, v. 62, n. 4, p. 389–396, 1988.
- VEGA-GARCIA, C.; LEE, B.; WOODARD, P.; TITUS, S. Applying neural network technology to human-caused wildfire occurrence prediction. *AI Applications*, v. 10, p. 9–18, 1996.
- VERDENIUS, F.; TIMMERMANS, A.; SCHOUTEN, R. Process models for neural network applications in agriculture. *AI Applications*. *AI Application*, p. 31–44, 1997.
- Votorantim Celulose e Papel - VCP. *Sustainable growth with value creation and solid returns*. [S.l.], jan. 2004. 28p p.
- WANG, F. J. Incorporating a neural network into GIS for agricultural land suitability analysis. In: *GIS/LIS'92*. [S.l.: s.n.], 1992. v. 2, p. 804–815.
- WERBOS, P. J. *Beyond Regression: New Tools for Prediction and Analysis in the Behavioral Sciences*. Tese (Doutorado) — Harvard University, 1974.
- WIDROW, B. Generalization and Information Storage in Networks of Adaline ‘Neurons’. In: *Self-Organizing Systems, symposium proceedings (M.C. Yovitz, G.T. Jacobi, and G. Goldstein, eds.)*. Washington, DC: Spartan Books, 1962. p. 435–461.
- WIDROW, B.; HOFF, M. E. Adaptive switching circuits. In: *IRE WESCON Convention Record*. [S.l.: s.n.], 1960. v. 4, p. 96–104.
- WILKINSON, G.; KANELLOPOULOS, I.; KONTOES, C.; MEGIER, J. A comparison of neural network and expert system methods for analysis of remotely sensed imagery. *IEEE Transaction on Geoscience and Remote Sensing*, v. 91, p. 62–64, 1992.
- WILLSHAW, D.; MALSBURG, C. von der. How pattern neural connections can be set up by self-organization. In: *Proceedings of the Royal Society of London, Series B*. [S.l.: s.n.], 1976. v. 194, p. 431–445.
- XAVIER, A. *Silvicultura clonal I: princípios e técnicas de propagação vegetativa*. Viçosa - MG: Universidade Federal de Viçosa, 2002.
- XIAO, R.; CARANDE, R.; GHIGLIA, D. A Neural Network Approach for Tree Height Estimation Using IFSAR Data. *IEEE Transactions on Geoscience and Remote Sensing*, v. 36, n. 5, p. 345–348, 1998.
- XU, J.; HO, D. W. A new training and pruning algorithm based on node dependence and Jacobian rank deficiency. *Neurocomputing*, v. 70, n. 1-3, p. 544–558, 2006. ISSN 0925-2312.

- YANG, X.; BATCHELOR, W. Modeling plant disease dynamics using neural networks. *AI Application*, v. 11, p. 47–55, 1997.
- YANG, X.; BATCHELOR, W.; TSCHANZ, A. A neural network model to predict soybean rust. *Phytopathology*, v. 75, p. 1172, 1995.
- YI, J.; PRYBUTOK, V. A neural network model forecasting for prediction of daily maximum ozone concentration in an industrialized urban area. *Environ. Pollut.*, v. 84, p. 349–357, 1996.
- YOSHITOMI, K.; ISHIMARU, A.; WANG, J. N.; CHEN, J. Surface roughness determination using spectral correlation of scattered intensities and an artificial neural network technique. *IEEE Transaction on Geoscience and Remote Sensing*, v. 41, p. 498–502, 1993.
- YUN, Z.; QUAN, Z.; CAIXIN, S.; SHAOLAN, L.; YUMING, L.; YANG, S. RBF Neural Network and ANFIS-Based Short-Term Load Forecasting Approach in Real-Time Price Environment. *IEEE TRANSACTIONS ON POWER SYSTEMS*, v. 23, n. 3, p. 853–858, ago. 2008.
- ZANCHETTIN, C.; LUDERMIR, T. B. Sistemas neurais híbridos para reconhecimento de padrões em narizes artificiais. *SBA Controle & Automação*, v. 16, n. 2, 2005.
- ZHANG, X.; LI, C.; YUAN, Y. Application of neural networks to identifying vegetation types from satellite images. *AI Application*, v. 11, p. 99–106, 1997.
- ZHOU, J.; CIVCO, D. Using genetic learning neural networks for spatial decision making in GIS. *Photogrammetric Engineering and Remote Sensing*, v. 11, p. 1287–1295, 1996.