

UNIVERSIDADE ESTADUAL DE CAMPINAS
FACULDADE DE ENGENHARIA AGRÍCOLA

**INTEGRAÇÃO DE DADOS ESPECTRAIS E INDICADORES
METEOROLÓGICOS POR MEIO DE REDES NEURAIS PARA
A ESTIMATIVA DE PRODUTIVIDADE DE CANA-DE-AÇÚCAR**

LIANE DE SOUZA WEBER

CAMPINAS
MARÇO DE 2005

UNIVERSIDADE ESTADUAL DE CAMPINAS
FACULDADE DE ENGENHARIA AGRÍCOLA

**INTEGRAÇÃO DE DADOS ESPECTRAIS E INDICADORES
METEOROLÓGICOS POR MEIO DE REDES NEURAIS PARA
A ESTIMATIVA DE PRODUTIVIDADE DE CANA-DE-AÇÚCAR**

Tese de Doutorado submetida à banca
examinadora para obtenção do título de
Doutor em Engenharia Agrícola, na
área de concentração em Planejamento
e Desenvolvimento Rural Sustentável.

LIANE DE SOUZA WEBER

Orientador: Prof. Dr. Jansle Vieira Rocha

CAMPINAS
MARÇO DE 2005

FICHA CATALOGRÁFICA ELABORADA PELA
BIBLIOTECA DA ÁREA DE ENGENHARIA E ARQUITETURA - BAE - UNICAMP

W388i Weber, Liane de Souza
Integração de dados espectrais e indicadores meteorológicos por meio de redes neurais para a estimativa de produtividade de cana-de-açúcar / Liane de Souza Weber.--Campinas, SP: [s.n.], 2005.

Orientador: Jansle Vieira Rocha
Tese (Doutorado) - Universidade Estadual de Campinas, Faculdade de Engenharia Agrícola.

1. Meteorologia agrícola. 2. Agricultura – Previsão. 3. Produtividade agrícola. I. Rocha, Jansle Vieira. II. Universidade Estadual de Campinas. Faculdade de Engenharia Agrícola. III. Título.

Título em Inglês: Integration of spectral and meteorological data through neural networks for sugarcane yield estimate

Palavras-chave em Inglês: Agrometeorological model, Vegetation index, Crop forecast, Ensemble

Área de concentração: Planejamento e Desenvolvimento Rural Sustentável

Titulação: Doutor em Engenharia Agrícola

Banca examinadora: Bernardo Friedrich Theodor Rudorff, Flavio André Cecchini Deppe, Fernando José Von Zuben, Rubens Augusto Camargo Lamparelli

Data da defesa: 22/03/2005

Programa de Pós-Graduação: Engenharia Agrícola

A *Claudio e Núbia*, meus pais
Pelo amor, confiança e eterno apoio em todas as horas.

A minha amada filha *Gabriela*,
Que soube enfrentar, com grandeza e vitória, a nossa distância
nestes longos quatro anos.

A minha querida sobrinha *Bárbara*,
A quem amo como filha.

Ao meu esposo *Paulo de Tarso*,
Pelo companheirismo, infinda paciência, amizade e amor.

Dedico.

AGRADECIMENTOS

Ao Departamento de Engenharia Rural do Centro de Ciências Rurais da Universidade Federal de Santa Maria-UFSM, pelo reconhecimento da importância do aperfeiçoamento.

A Faculdade de Engenharia Agrícola - FEAGRI da UNICAMP, pela oportunidade de realizar este curso - fundamental para meu amadurecimento pessoal e profissional.

A CAPES - pelo incentivo financeiro.

Ao Prof. Dr. *Jansle Vieira Rocha* – pela confiança e oportunidade de desenvolver a pesquisa nesta Instituição... sob a sua orientação tive a convicção de estar trilhando o caminho certo.

Ao Prof. Dr. *Fernando José Von Zuben*, pelo incentivo, amizade e total amparo ao trabalhar com redes neurais - presença imprescindível no desenvolvimento deste trabalho.

Aos Profs. Dr. *Rubens Augusto Camargo Lamparelli* e Dr. *Jurandir Zullo Jr.*, pelo incentivo e coleguismo.

Aos professores da FEAGRI e do Centro de Pesquisas Meteorológicas e Climáticas Aplicadas à Agricultura – CEPAGRI da UNICAMP, pelo enriquecimento de minhas experiências acadêmicas.

A *Clodoaldo A. de Moraes Lima* e *Wilfredo J. Puma Villanueva*, do Laboratório de Bioinformática e Computação Bio-Inspirada – LBiC, da Faculdade de Engenharia Elétrica e de Computação - FEEC da UNICAMP, pelo apoio imensurável na implementação dos algoritmos.

A *Ana M. Heuminski de Ávila* e *Márcia A. Procópio da Silva Scheer*, minhas colegas e amigas de toda a hora – sem vocês teria sido muito mais difícil amenizar a saudade.

A *Claudia Weber Corseuil*, minha amiga e irmã de coração – pelo eterno amparo na amizade, profissão e vida... a distância nunca te impediu de estar sempre presente.

Aos amigos, colegas, estagiários e funcionário do Laboratório de Geoprocessamento da FEAGRI - *Júlio César Dalla Mora Esquerdo*, *Pedro Piason Breglio Pontes*, *Hermógenes Moura Machado*, *Erivelto Mercante*, *João Francisco Gonçalves Antunes*, *Wander J. Pallone Filho*, *Luis Neri*, *Leonardo Sene de Lourenço*, *Luciene Marciano da Silva*, *Denise Fernandes*,

Enéias Camargo Tonhasca Junior, Agmon Moreira Rocha - pela ajuda e coleguismo. Sentirei muitas saudades!

A *Ana, Marta e Rosângela* da secretaria da Pós-graduação da FEAGRI, pela atenção, presteza e dedicação incansáveis.

Aos amigos *Darlila Gallina e Julio César Vergara Galeano; Claudete Lima, Carlos Luft e Jean Alexandre; Divair Christ; Fernanda e Daniel Weber* – pela solidariedade externada nos churrascos e nas saudosas rodas de chimarrão – quis o destino que nossos caminhos se cruzassem.

SUMÁRIO

LISTA DE FIGURAS	viii
LISTA DE QUADROS	x
RESUMO	xii
ABSTRACT	xiv
1. INTRODUÇÃO.....	1
1.1. Hipótese.....	3
1.2. Objetivos	3
1.3. Estrutura do trabalho	3
2. REVISÃO DE LITERATURA	5
2.1. Variáveis de produção da cana-de-açúcar	5
2.1.1. Histórico e caracterização	5
2.1.2. Fator de resposta espectral	7
2.1.3. Fator de produção.....	8
2.1.4. Banco de dados de produção	10
2.2. Introdução a Redes Neurais.....	14
2.2.1. Características Principais	16
2.2.2. Função de ativação	18
2.2.3. Algoritmos de treinamento.....	20
2.2.4. Redes do tipo Perceptron de Múltiplas Camadas.....	22
2.2.5. Representação do conhecimento	24
2.2.6. Preditores <i>ensemble</i>	25
2.2.7. Aplicações de redes neurais na área ambiental	26
3. PROCEDIMENTOS METODOLÓGICOS	30
3.1. Área de estudo.....	32
3.2. Obtenção das variáveis de entrada da rede neural.....	34
3.2.1. Variáveis de produção da cana-de-açúcar	35
3.2.2. Dados espectrais	35
3.2.3. Dados meteorológicos	36
3.2.4. Estruturação das variáveis no banco de dados	40

3.3. Rede Neural para integração de dados espectrais e meteorológicos	41
3.3.1. Etapas para o ajuste da RN: treinamento, validação e teste	42
3.3.2. Preditor <i>Ensemble/Bagging</i>	43
4. RESULTADOS E DISCUSSÕES.....	46
4.1. Variáveis de produção	46
4.1.1. Produtividade e dados espectrais.....	46
4.1.2. Indicador meteorológico - kp	46
4.1.3. Correlação entre as variáveis.....	48
4.1.4. Banco de dados de entrada/saída para a RN.....	51
4.2. Rede neural.....	53
4.2.1 Análise comparativa entre métodos de seleção de componentes de RNs ..	53
4.2.2. Comparação do desempenho entre as estimativas das RN e da usina.....	69
5. CONCLUSÕES E RECOMENDAÇÕES.....	73
REFERÊNCIAS BIBLIOGRÁFICAS	75
BIBLIOGRAFIA CONSULTADA.....	82
ANEXOS	84
APÊNDICES	86

LISTA DE FIGURAS

FIGURA 1 - Ciclo evolutivo da cana-de-açúcar de 12 e 18 meses para as regiões do Estado de São Paulo. (Adaptado de Alfonsi et al., 1987).....	6
FIGURA 2 – Curva de reflectância típica da vegetação verde. (Adaptado de Hoffer, 1978).....	7
FIGURA 3 – Alguns aspectos de um ambiente de Sistema de Gerenciamento de Banco de Dados (SGBD). (Fonte: MEDEIROS e PIRES, 1998)	12
FIGURA 4 - Célula neural biológica com a seqüência de propagação do sinal.(Fonte: CASTRO, 1998).....	15
FIGURA 5 - Modelo não-linear de um neurônio. (Fonte: HAYKIN, 1999, p. 36).....	17
FIGURA 6 - Tipos de funções de ativação: (a) sinal, (b) sigmóide e (c) gaussiana. (Adaptado de Gonçalves, 1997).....	18
FIGURA 7 - Estrutura topológica da rede neural MLP. (Fonte: CARVALHO, 2002)	23
FIGURA 8 – Fluxograma metodológico da pesquisa.	31
FIGURA 9 - Localização do município de Araras no Estado de São Paulo-Brasil.	32
FIGURA 10 – Distribuição espacial dos talhões (em amarelo) na imagem Landsat 7 ETM ⁺ , projeção UTM 23S, datum SAD69, composição RGB 453.....	34
FIGURA 11 – Distribuição espacial das estações meteorológicas e dos pontos amostrais nos talhões.	37
FIGURA 12 - Rede neural de arquitetura <i>Multilayer Perceptron</i> (MLP) com <i>bias</i> . (CASTRO et al., 1998).....	42
FIGURA 13 – Diagrama de dispersão da reflectância (%) da banda B4 com a produtividade colhida (ton/ha).	48
FIGURA 14 – Diagrama de dispersão da produtividade colhida (ton/ha) com o índice GVI expresso em % de reflectância.	49
FIGURA 15 – Diagrama de dispersão da produtividade colhida (ton/ha) com o coeficiente k_p	50
FIGURA 16 – Desempenho percentual do EQM dos métodos da Seleção pela Média, Construtivo e de Poda, comparados ao Método do Melhor Componente, na etapa de validação dos <i>ensembles</i> com 10 RNs.	56

FIGURA 17 – Desempenho percentual do EQM dos métodos da Seleção pela Média, Construtivo e de Poda, comparados ao Método do Melhor Componente, na etapa de teste dos <i>ensembles</i> com 10 RNs.	58
FIGURA 18 – Desempenho percentual do EQM dos métodos da Seleção pela Média, Construtivo e de Poda, comparados ao Método do Melhor Componente, na etapa de validação dos <i>ensembles</i> com 20 RNs.	60
FIGURA 19 – Desempenho percentual do EQM dos métodos da Seleção pela Média, Construtivo e de Poda, comparados ao Método do Melhor Componente, na etapa de teste dos <i>ensembles</i> com 20 RNs.	62
FIGURA 20 – Desempenho percentual do EQM dos métodos da Seleção pela Média, Construtivo e de Poda, comparados ao Método do Melhor Componente, na etapa de validação dos <i>ensembles</i> com 50 RNs.	64
FIGURA 21 – Desempenho percentual do EQM dos métodos da Seleção pela Média, Construtivo e de Poda, comparados ao Método do Melhor Componente, na etapa de teste dos <i>ensembles</i> com 50 RNs.	65
FIGURA 22 – Desempenho percentual do EQM dos métodos da Seleção pela Média, Construtivo e de Poda, comparados ao Método do Melhor Componente, na etapa de validação dos <i>ensembles</i> com 100 RNs.	67
FIGURA 23 – Desempenho percentual do EQM dos métodos da Seleção pela Média, Construtivo e de Poda, comparados ao Método do Melhor Componente, na etapa de teste dos <i>ensembles</i> com 100 RNs.	69
FIGURA 24 – EQM obtido na etapa de validação, para 4 métodos de seleção de RNs, considerando os 4 grupos de <i>ensembles</i> : 10, 20, 50 e 100 RNs.....	70
FIGURA 25 – EQM obtido na etapa de teste, para os 4 métodos de seleção de RNs, considerando os 4 grupos de <i>ensembles</i> : 10, 20, 50 e 100 RNs.....	70
FIGURA 26 – EQM em ton/ha, obtido pela estimativa da usina e pelos quatro métodos de seleção de RN, considerando os quatro grupos de <i>ensembles</i> : 10, 20, 50 e 100 RNs.....	72

LISTA DE QUADROS

QUADRO 1 – ETR, ETM e coeficiente de produtividade (kp) das amostras para três diferentes datas.....	47
QUADRO 2 – Variáveis de entrada e saída da RN, obtidas a partir de consulta ao banco de dados.	52
QUADRO 3 – Quantidade de padrões de entrada/saída de dados utilizados nas etapas de treinamento, validação e teste das RNs.....	54
QUADRO 4 – Erro Quadrático (EQ) e Erro Quadrático Médio (EQM) encontrado para 10 simulações de <i>ensembles</i> com 10 redes neurais, para os métodos do Melhor Componente, Seleção pela Média, Construtivo e de Poda, na etapa de validação.	55
QUADRO 5 – Erro Quadrático (EQ) e Erro Quadrático Médio (EQM) encontrado para 10 simulações de <i>ensembles</i> com 10 redes neurais, para os métodos do Melhor Componente, Seleção pela Média, Construtivo e de Poda, na etapa de teste.	57
QUADRO 6 – Erro Quadrático (EQ) e Erro Quadrático Médio (EQM) encontrado para 10 simulações de <i>ensembles</i> com 20 redes neurais, para os métodos do Melhor Componente, Seleção pela Média, Construtivo e de Poda, na etapa de validação.	59
QUADRO 7 – Erro Quadrático (EQ) e Erro Quadrático Médio (EQM) encontrado para 10 simulações de <i>ensembles</i> com 20 redes neurais, para os métodos do Melhor Componente, Seleção pela Média, Construtivo e de Poda, na etapa de teste.	61
QUADRO 8 – Erro Quadrático (EQ) e Erro Quadrático Médio (EQM) encontrado para 10 simulações de <i>ensembles</i> com 50 redes neurais, para os métodos do Melhor Componente, Seleção pela Média, Construtivo e de Poda, na etapa de validação.	63
QUADRO 9 – Erro Quadrático (EQ) e Erro Quadrático Médio (EQM) encontrado para 10 simulações de <i>ensembles</i> com 50 redes neurais, para os métodos do Melhor	

Componente, Seleção pela Média, Construtivo e de Poda, na etapa de teste.	64
QUADRO 10 – Erro Quadrático (EQ) e Erro Quadrático Médio (EQM) encontrado para 10 simulações de <i>ensembles</i> com 100 redes neurais, para os métodos do Melhor Componente, Seleção pela Média, Construtivo e de Poda, na etapa de validação.	66
QUADRO 11 – Erro Quadrático (EQ) e Erro Quadrático Médio (EQM) encontrado para 10 simulações de <i>ensembles</i> com 100 redes neurais, para os métodos do Melhor Componente, Seleção pela Média, Construtivo e de Poda, na etapa de teste.	68

RESUMO

O presente trabalho descreve um estudo sobre estimativa de safras cujo principal objetivo foi criar uma metodologia de integração de dados de produção, dados espectrais e indicadores meteorológicos por meio de redes neurais artificiais, estabelecendo correlações entre índices de vegetação e de produtividade, com o propósito de estimar a produtividade de cana-de-açúcar. O estudo foi dividido em duas etapas: a primeira correspondeu à obtenção e organização dos dados em um banco de dados com padrões de entrada/saída; a segunda, à implementação e ajuste das redes neurais, por meio de *ensembles*. O estudo foi realizado em unidades amostrais de produção de uma usina sucroalcooleira no município de Araras-SP. A primeira etapa consistiu na obtenção dos coeficientes de produtividade (kp), por meio da inversão do modelo agrometeorológico de Doorenbos e Kassam (1979), a partir da determinação do balanço hídrico. O resultado deste procedimento mostrou a sensibilidade do coeficiente à variabilidade da produtividade nos talhões. Os dados espectrais das imagens Landsat 7 – ETM⁺ foram obtidos de correlações descritas na literatura estabelecidas entre o Índice de Vegetação Greenness (GVI), a banda do infravermelho próximo (B4) e a produtividade da cana-de-açúcar. A estratégia para treinamento dos *ensembles* foi baseada no aprendizado supervisionado aplicado a uma arquitetura Multilayer Perceptron (MLP), com uma camada escondida, método de aprendizado de 2^a ordem e *feedforward*. Na etapa de treinamento e validação, as redes neurais tiveram como variáveis de entrada os valores de kp, GVI e B4, e como variável de saída a produtividade, que definiram os padrões de entrada/saída. A fase de teste consistiu em implementar a metodologia em um grupo de padrões de entrada não utilizados nos treinamentos. Os resultados mostraram valores de EQM entre 0,03 e 0,51 ton/ha, enquanto que a estimativa da usina errou em média 9,93 ton/ha, o que garantiu o correto ajuste da rede neural quanto à topologia, ao número de iterações e aos algoritmos de aprendizagem. Esta etapa mostrou a capacidade de generalização da rede neural, já que os treinamentos foram realizados a partir de unidades amostrais. O estudo ratificou a aplicação desta metodologia na determinação da estimativa de produtividade de cana-de-açúcar, empregando-a como técnica complementar aos atuais métodos de estimativa agrícola, sugerindo a ampliação da escala de aplicação para o ambiente de produção da usina.

PALAVRAS-CHAVE: Modelo agrometeorológico; índice de vegetação; estimativa de safra, *ensemble*.

ABSTRACT

The present thesis describes a study on crop forecast. Its main purpose was to create a methodology for integrating production, spectral and meteorological data indicators through artificial neural networks, establishing correlations between vegetation index and yield coefficients, aiming at the estimate of sugarcane yield. The study was divided in two parts: the first corresponded to obtaining and organizing data in a database with input/output default; the second corresponded to the implementation and adjustment of the neural network. The study was carried out in sample production units (fields) of a sugarmill agricultural area located in the municipality of Araras-SP, Brazil. The first part consisted in obtaining yield coefficients (kp) through the inversion of the Doorenbos-Kassam (1979) agrometeorological model, based on the determination of the water balance. The result of this procedure showed the coefficient's sensitivity to the variability of yield within the sample fields. The spectral data of the Landsat 7 – ETM⁺ images were obtained from correlations, available in scientific literature, between the Greenness Vegetation Index (GVI), near infrared band, and sugarcane yield. The strategy for training the neural network was based on supervised learning applied to a Multilayer Perceptron (MLP) architecture, with a hidden layer, second order learning method and feedforward. For the training and validation stage, the neural network had as input variables kp, GVI and B4 values, and as output variable the yield, both obtained in the input/output database. The test stage consisted of implementing the methodology in a set of input patterns not used for the trainings. The results showed Mean Square Error (MSE) values between 0,03 and 0,51 ton/ha, while the average error of the sugarmill estimates were 9,93 ton/ha, which showed the correct adjustment of the network concerning topology, number of iterations and learning algorithms. This showed the generalization capacity of the neural network once the trainings were carried out based on sample units. The study ratified the application of this methodology for determining sugarcane yield estimate, employing it as a complementary technique to the present methods of agricultural forecast, suggesting the increase of the application scale to a broader area of the sugarmill production environment.

Key-word: agrometeorological model; vegetation index; crop forecast, ensemble.

1. INTRODUÇÃO

Ano após ano o Brasil vem apresentando um crescente percentual em sua produção agrícola. Porém, este perfil não contabiliza os prejuízos no sistema de produção que vão desde perdas de produto na lavoura, no transporte e beneficiamento da matéria-prima até a especulação de preços no mercado financeiro.

O grande desafio das empresas agrícolas no país é produzir com qualidade e competitividade, empregando tecnologia de ponta e reduzindo custos, tendo em vista o mercado econômico que oscila de acordo com a política interna do país e as relações de comércio internacional. Considerando este perfil, a exportação de produtos é uma alternativa vista como positiva por economistas e um caminho viável para o momento de firmação econômica por que passa o país.

Um detalhe interessante é que essa alternativa exige que as empresas estejam estruturadas para que possam participar de maneira competitiva nesses mercados, pois quanto maior a capacidade de organização e integração dos dados de produção de uma empresa, maior será a expectativa de mitigação de custos na mesma. No setor sucroalcooleiro não é diferente. O mercado competitivo exige competência técnico-administrativa, que associada a inovações biotecnológicas (estudos de adaptação de variedades plantadas) pode reduzir custos de produção e aumentar a produtividade nos canaviais.

No caso das usinas de cana-de-açúcar a estimativa de produção é usualmente feita por técnicos de maneira tradicional, mas subjetiva. Eles percorrem os canaviais observando o desenvolvimento das culturas, associando-o ao conhecimento pessoal sobre a região cultivada e aos resultados registrados em safras anteriores. Essa maneira subjetiva de estimar a produção é tendenciosa e, muitas vezes, conduz a uma subestimação dos valores de produtividade.

São muitas as variáveis relacionadas ao plantio que afetam a produtividade da cana-de-açúcar. Para exemplificar esta afirmação, citam-se as diferenças na fisiologia das variedades, o estágio de desenvolvimento da planta, o tipo de colheita e o manejo do solo e do cultivo.

Ainda em relação à produtividade, existem fatores que não são intrínsecos à planta, mas que desenvolvem uma importância significativa em sua produtividade, pois refletem a

condição climática na qual a cultura irá se desenvolver, como exemplo tem-se a temperatura e a precipitação.

Portanto, é imprescindível que se tenha um conhecimento do comportamento da cultura, durante o período de produção, e dos fatores ambientais que interferem na produtividade da mesma, para que se possa fazer uma análise temporal, considerando o seu desenvolvimento no ciclo e entre safras.

Em geral, as usinas de cana-de-açúcar não possuem seus dados de produção estruturados em banco de dados, sendo que o procedimento usual é o armazenamento das informações em planilhas, cujo uso é restrito às aplicações em sistemas de geoprocessamento. Com isso, surge a necessidade de utilizar a estrutura de dados existente integrada a novas tecnologias, como sensoriamento remoto e inteligência computacional.

O uso destas tecnologias empregando dados espectrais e agrometeorológicos, durante o processo de produção da cultura da cana-de-açúcar, oferece resultados que venham auxiliar os modelos de estimativa a resolverem a complexa tarefa de estimar a produtividade agrícola. Assim, a associação de geotecnologias às técnicas de suporte à decisão pode proporcionar o uso mais racional e intensivo das informações para se estimar a produtividade e com isso, obter resultados mais confiáveis e próximos à realidade.

O desafio é aliar as informações agrometeorológicas, a partir de dados de temperatura do ar e precipitação, na forma de indicadores que correlacionem a resposta do suprimento de água com a produtividade da cultura (denominados, neste estudo, de indicadores meteorológicos) e os dados de sensoriamento remoto, como comportamento espectral e índices de vegetação, relacionados à produção da cultura.

Neste contexto, a perspectiva de integração de dados espectrais e meteorológicos proposta a partir de estimadores de alto desempenho, como os *ensembles* de componentes de redes neurais, demonstra a vantagem da agregação de mais de um preditor na produção de uma única solução computacional para um determinado problema de aprendizado (LIMA, 2004). Esta metodologia permite a redução de custos de implementação e fornece uma projeção mais realista da estimativa de produtividade para a usina, possibilitando que se torne economicamente mais competitiva.

1.1. Hipótese

As técnicas de processamento de informação vinculadas a modelos conexionistas na forma de redes neurais artificiais podem ser utilizadas na integração de dados espectrais e indicadores meteorológicos, de forma a estimar a produtividade de cana-de-açúcar e melhorar a estimativa subjetiva das usinas sucroalcooleiras.

1.2. Objetivos

Esta pesquisa teve como objetivo geral criar uma metodologia que integre dados de produção de cultura, dados espectrais e indicadores meteorológicos, por meio de redes neurais artificiais (RNA). Agregando, para isto, dados de produtividade, índices de vegetação - obtidos a partir de dados de reflectância - e coeficientes de produtividade - obtidos a partir de um modelo agrometeorológico - com o propósito de estimar a produtividade da cana-de-açúcar.

Os objetivos específicos foram:

1 – Determinar o coeficiente de produtividade (kp) dos talhões amostrais por meio do modelo agrometeorológico de Doorenbos e Kassam (1979);

2 – Estruturar os dados de produção da cultura, índices de vegetação e coeficiente de produtividade em um banco de dados, formando padrões de entrada/saída para o treinamento da rede neural, e determinando a correlação amostral entre as variáveis;

3 – Implementar e testar uma arquitetura de rede neural, que permita a integração das variáveis, visando a estimativa de produtividade da cultura de cana-de-açúcar.

1.3. Estrutura do trabalho

O presente estudo teve o propósito de ajustar técnicas de inteligência computacional, por meio de topologia de redes neurais, empregando processamento paralelo de dados e reconhecimento de padrões, que permitiram a agregação de informações originárias das

planilhas de produção da usina e de dados espectrais e meteorológicos. O desenvolvimento desta metodologia resultou na obtenção de redes neurais treinadas para reconhecimento de padrões como indicadores de estimativa de produtividade da cana-de-açúcar, em talhões amostrais.

A situação apresentada nesse trabalho necessitou que os dados estivessem organizados de maneira lógica, pois existem informações oriundas de diferentes fontes, com diferentes características de dados e obtidos em diferentes épocas. Para isto, esses dados foram organizados em um banco de dados, cujas características de organização e funcionalidade facilitaram a consulta às informações.

Na parte do estudo sobre redes neurais foram abordados os fundamentos básicos e as principais arquiteturas empregadas em pesquisas com estimadores de safras agrícolas. Esta fase englobou a etapa de treinamento e validação da rede neural. Neste procedimento, a rede foi implementada por meio de um processo iterativo até alcançar a convergência em relação ao erro de treinamento, o que garantiu à RN um desempenho positivo na representatividade das amostras de treinamento. As amostras que não foram usadas no treinamento foram empregadas na etapa de teste, resultando num procedimento de validação do modelo.

2. REVISÃO DE LITERATURA

2.1. Variáveis de produção da cana-de-açúcar

2.1.1. Histórico e caracterização

Originária da Ásia, a cana-de-açúcar é uma poácea semi-perene, pertencente ao gênero *Saccharum*, que foi introduzida no Brasil, aproximadamente, em 1530 por Martim Afonso de Souza. A cana, como usualmente é denominada, é cultivada nas regiões tropicais e subtropicais compreendidas entre as latitudes 35° Norte e Sul, tendo o Brasil como seu maior produtor mundial (RUDORFF e BATISTA, 1988; JOAQUIM, 1998).

O cultivo desenvolveu-se em todos os estados brasileiros. Contudo, as regiões de grande produção estão concentradas no norte do Paraná e em alguns estados do nordeste e do sudeste do país, sendo o Estado de São Paulo o principal produtor nacional (COPERSUCAR, 1997b).

A cana-de-açúcar tem um determinado período de crescimento até que atinge a maturidade para o primeiro corte, sendo que nessa fase é denominada cana-planta. Dependendo da época do plantio, alguns autores denominam cana-de-ano aquela cujo primeiro corte acontece aos 12 meses e cana de ano-e-meio aquela com primeiro corte entre 14 e 18 meses (JOAQUIM, 1998). A Figura 1 mostra o ciclo evolutivo da cana-de-açúcar de 12 e 18 meses para as regiões do Estado de São Paulo.

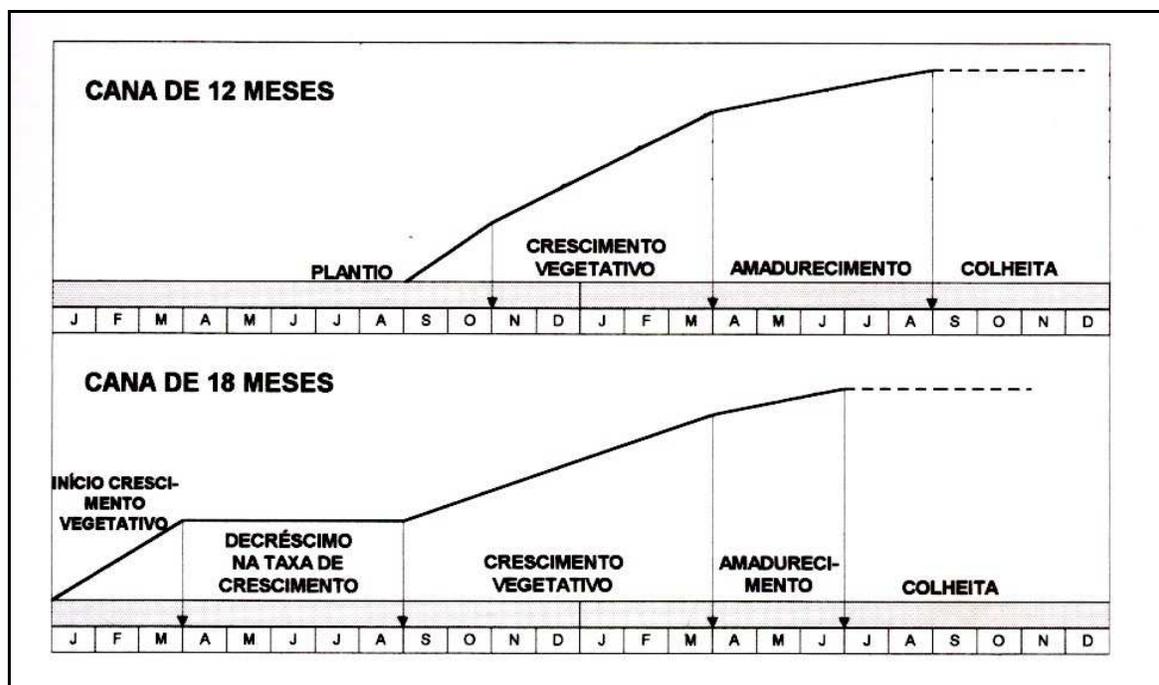


FIGURA 1 - Ciclo evolutivo da cana-de-açúcar de 12 e 18 meses para as regiões do Estado de São Paulo. (Adaptado de Alfonsi et al., 1987)

Após a primeira colheita, a cana-de-açúcar passa a ser denominada cana-soca e o ciclo de crescimento passa a ser de 12 meses para todas as variedades (RUDORFF e BATISTA, 1988).

Os autores citados acima, comentam que a produtividade agrícola é quantificada pelo peso dos colmos, levando-se em conta o teor de sacarose por peso fresco, já que esta percentagem determinará a produção de açúcar ou de álcool por tonelada colhida.

A matéria-prima da cana-de-açúcar é utilizada para produção de açúcar e álcool sendo que a safra 2003/2004 do Estado de São Paulo foi responsável por cerca de 60% da produção de açúcar e por 60% da produção de álcool total do País. O agronegócio da cana-de-açúcar reúne 6% dos empregos agroindustriais brasileiros e é responsável por 35% do emprego rural no Estado (UNICA, 2004).

2.1.2. Fator de resposta espectral

Para melhor prever as mudanças nas características espectrais dos alvos é fundamental o conhecimento sobre as relações entre as características da reflectância do dossel, a temperatura do ar e a disponibilidade hídrica no processo de produção da cana-de-açúcar, o que pode alterar a interação da radiação solar com a vegetação, a fim de esclarecer as variações quantitativas gravadas por um sensor remoto (HOFFER e JOHANSEN, 1969).

Ratificando essa afirmação, KNIPLING et al. (1970) e HOFFER (1978) descreveram em seus estudos que a reflectância de uma vegetação verde é distinta e completamente variável com os comprimentos de onda do espectro eletromagnético (FIGURA 2).

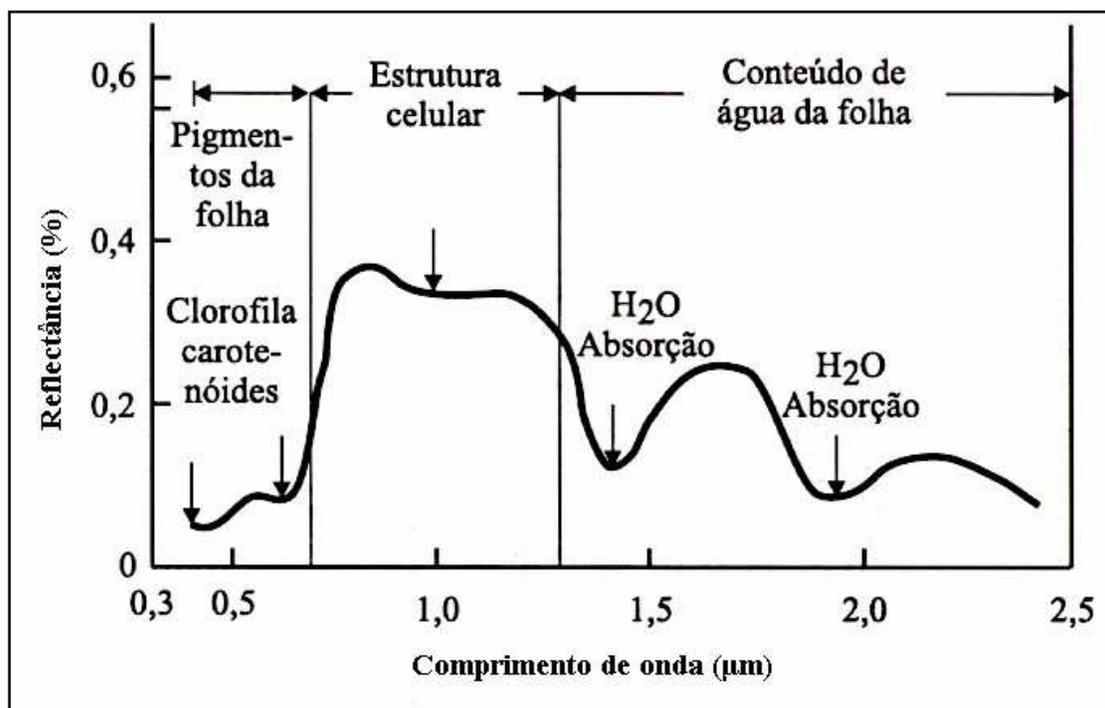


FIGURA 2 – Curva de reflectância típica da vegetação verde. (Adaptado de Hoffer, 1978)

Analisando a Figura 2, KNIPLING et al. (1970) comenta que, na região do visível (0,4 μm a 0,7 μm) ocorre uma baixa reflectância na faixa do azul e do vermelho, devido à alta absorvância da energia incidente por pigmentos da folha, como é o caso da clorofila.

HOFFER (1978) e De CAROLIS e AMOEDO (1980) relatam que na região do infravermelho próximo (0,7 μm a 1,4 μm) a vegetação verde e sadia se caracteriza pela alta reflectância (45% a 50%), alta transmitância (45% a 50%) e baixa absorvância (menos do que

5%), influenciadas pela estrutura interna das folhas de uma planta. Além desta, deve-se levar em conta também outros fatores importantes que influenciam a resposta espectral da folha como pigmentos, conteúdo de água, estado nutricional, maturidade e condições fitossanitárias.

Ainda sobre a reflectância das plantas, em casos de deficiência nutricional, ocorre aumento da reflectância das folhas, na região do comprimento de onda do visível, devido à menor concentração de pigmentos que são responsáveis pela absorção da energia incidente (AL ABBAS et al., 1974)

Outros autores como KNIPLING et al. (1970) afirmam, também, que ocorrem variações na quantidade de energia refletida pela planta (se referindo à região do infravermelho próximo) quando esta se encontra suscetível ao ataque de pragas e doenças, ao estresse por falta de água ou a senescência. Essas alterações são ocasionadas pela diminuição do índice de área foliar e alteração da estrutura interna e morfologia das folhas.

Alguns estudos afirmam ser possível a incorporação de variáveis como índices de vegetação e indicadores meteorológicos como estimadores de produtividade, por meio de técnica de regressão, requerendo que elas sejam independentes ou que pelo menos tenham um certo grau de independência (RUDORFF e BATISTA, 1988; PELLEGRINO, 2000).

MACHADO (2003) explica que existem fatores de produção que são comuns tanto aos indicadores meteorológicos, como aos índices de vegetação e podem refletir certa dependência entre eles. Como exemplos, têm-se: água no solo, temperatura, radiação, variedade e estágio de corte. Com isto os resultados de correlações entre índices de vegetação e a produtividade da cultura, por meio de análise exploratória, pode evidenciar o índice de vegetação que melhor responde à variabilidade da produtividade da biomassa.

2.1.3. Fator de produção

Sendo de clima tropical, a cana-de-açúcar se desenvolve entre temperaturas de 22°C a 30°C, quando apresenta máximo potencial de produção em sua fase vegetativa. Em temperaturas inferiores a 20°C o crescimento é muito reduzido e é paralisado aos 10°C. A quantidade de água exigida pela cultura varia entre 1500 a 2500 mm durante o período de crescimento, porém para completar o ciclo vegetativo, a cana requer um déficit hídrico ou

térmico a fim de acumular sacarose em seus colmos (RUDORFF e BATISTA, 1988; JOAQUIM, 1998).

A cultura não é muito exigente em solos, contudo apresenta melhor desenvolvimento em áreas que tenham boa aeração e boa drenagem. Quanto ao pH, a cana cresce bem no intervalo de 5,0 a 8,5, sendo que o pH ótimo recomendado encontra-se próximo a 6,5. A recomendação de adubação e calagem para cana-planta e soca é baseada nos resultados de análises químicas de solos (COPERSUCAR, 1988; RUDORFF e BATISTA, 1988).

Um detalhe a ser considerado no desenvolvimento vegetativo da cultura é que, muitas vezes, ele está associado à quantidade de nutrientes que é distribuído na adubação, fazendo com que haja diferença de crescimento dentro de uma mesma variedade, e interferindo na resposta espectral registrada pelo sensor (UNIVERSIDADE ESTADUAL DE CAMPINAS, 1983).

Os autores comentam que, a influência da disponibilidade da água para a cultura da cana, depende essencialmente da água pelo menos num período de 8 a 9 meses no ano, que corresponde a fase de desenvolvimento vegetativo, onde a carência desse elemento, nesta condição, pode determinar quebras de produção que tornariam impossível a condução da cultura sem irrigação. Na prática, devido a diferentes tipos de solos, a produção pode reagir de maneira bastante diferenciada nos períodos de carência hídrica, principalmente na rebrota das socas. Como exemplo, temos que “em solos mais argilosos de boa capacidade de retenção hídrica, e de porosidade adequada para uma boa movimentação de água no perfil (drenagem e ascensão capilar) observa-se um dano menor, em condição de estiagem pronunciada”.

Neste mesmo trabalho sobre simulação de crescimento da cana-de-açúcar, descreve-se que para analisar a movimentação da água no perfil do solo, explorado pelas raízes da planta, é necessário realizar um balanço hídrico completo ao longo do ciclo de produção da cultura.

Na realidade, o teor de sacarose nos colmos depende também de características intrínsecas à variedade da cultura. As variedades de cana são consideradas precoces, médias ou tardias, de acordo com a época em que elas apresentam maior teor de sacarose nos colmos, tendo como referência o período da colheita. Ou seja, a variedade é considerada precoce, quando o maior acúmulo de sacarose se dá nos primeiros meses do período da colheita e

média ou tardia, quando o teor de sacarose se concentra do meio para o final do período de colheita (RUDORFF e BATISTA, 1988).

As variedades atualmente cultivadas são híbridas de duas ou mais espécies, criadas estrategicamente com o intuito de alcançar três objetivos comuns: maior produtividade de colmos em diversos cortes, maior resistência às doenças e pragas, e colmos mais ricos em sacarose (COPERSUCAR, 1997a).

Estes autores relatam também que a variedade SP80-1816 destaca-se pela sua produtividade agrícola, brotação de soqueira, rápido desenvolvimento vegetativo e porte ereto, sendo uma excelente alternativa ao corte mecanizado. Suas principais características são: excelente perfilhamento (assim como fechamento de entrelinhas), não floresce, não isoporiza, possui alto teor de fibra, não apresenta tombamento, possui sensibilidade média a herbicidas e a exigência em fertilidade do solo é de média a baixa.

O autor registra ainda que a variedade possui maturação um pouco mais precoce na cana soca atingindo altos teores de sacarose. Em relação aos padrões varietais dos ensaios de competição, aos quais a variedade foi comparada, seu retorno econômico foi mais favorável até o meio de safra, sendo 11% superior às variedades padrão na estimativa para cinco cortes.

Outra variedade bem adaptada é a SP80-1842 que possui hábito decumbente e acamamento regular. Suas principais características são: perfilhamento médio (com colmos de crescimento vigoroso), folhas de largura média (com comprimento longo e pontas dobradas) e alto teor de açúcar. Segundo ensaios realizados pela Copersucar (Cooperativa dos Produtores de Cana, Açúcar e Álcool do Estado de São Paulo Ltda.), essa variedade possui baixa exigência em fertilidade de solo e apresenta produtividade superior nas soqueiras, quando comparada à cana-planta (COPERSUCAR, 1993).

2.1.4. Banco de dados de produção

“Um banco de dados, muitas vezes também chamado de base de dados, é um conjunto de arquivos estruturados de forma a facilitar o acesso a conjuntos de informações que descrevem determinadas entidades do mundo” (MEDEIROS e PIRES, 1998, p. 31).

JOAQUIM (1998) comenta que os avanços da microeletrônica e da indústria de softwares impulsionaram uma verdadeira revolução na área da tecnologia da informação, o

que requereu a criação de grandes bancos de dados eletrônicos com a peculiaridade de acesso rápido e interface amigável com o usuário.

O autor salienta que os bancos de dados agrícolas são compostos por dados da produção, que vão desde o plantio até a colheita, organizados de forma lógica, de maneira que permitam um acesso rápido e direcionado às informações cadastradas.

À medida que avançam os estudos experimentais sobre um determinado cultivo, cresce também o volume de informações a serem gerenciadas, tornando cada vez mais complexo o processo de consulta, integração e análise conjunta dos dados adquiridos. Isso evidencia a necessidade de que estas informações estejam organizadas e sistematizadas para facilitar o acesso e, principalmente, a tomada de decisão (SANO et al., 1998).

No caso específico do setor sucroalcooleiro, um imenso volume de informações tem sido gerado ao longo dos anos, evidenciando a necessidade de um banco de dados que reúna informações das diversas áreas integrantes da usina. Esse conjunto de dados é uma ferramenta poderosa para a análise das relações solo-clima-planta e fornece padrões de comportamento a serem aplicados por sistemas de planejamento e na análise dos diferentes manejos adotados na usina. No caso da cana-de-açúcar, o banco de dados armazena informações de diversas safras. Estas informações são separadas por talhão, que é a menor unidade de área de manejo da lavoura (JOAQUIM, 1998).

a) Modelagem de banco de dados

Como já mencionado anteriormente, a maneira como os dados são armazenados em um banco de dados facilita a organização, a consulta e a atualização das informações. Porém, para alcançar esta estruturação, é preciso que se realize a chamada modelagem de dados, que consiste na atividade de especificar as necessidades de um conjunto de aplicações de forma a estruturar corretamente o armazenamento de dados. Assim, os mesmos dados podem ser utilizados para diferentes aplicações, reduzindo espaço e esforço de programação (MEDEIROS e PIRES, 1998).

As autoras comentam ainda que, à medida que o volume e os tipos de dados armazenados aumentam, é preciso fazer uso de um sistema para administrá-los, conhecido como Sistema de Gerenciamento de Bancos de Dados (SGBD). “Um SGBD é um software de

caráter geral para manipulação eficiente de grandes coleções de informações estruturadas e armazenadas de uma forma consistente e integrada”. Ou seja, estes sistemas são utilizados para consulta e atualização dos dados, incluindo as interfaces entre sistema e usuário (Figura 3), tendo como principais objetivos:

- Tornar disponíveis dados integrados para uma grande variedade de usuários através de interfaces amigáveis;
- Garantir a privacidade dos dados através de medidas de segurança dentro do sistema;
- Permitir o compartilhamento de dados de forma organizada, atuando como mediador entre as aplicações e o banco de dados, garantindo assim o controle e a redução do nível de redundância e administrando acessos concorrentes;
- Controlar a administração dos dados com garantia de manutenção de padrões de qualidade e integridade, e;
- Possibilitar a independência dos dados no sentido de poupar o usuário de detalhes físicos da organização e do armazenamento.

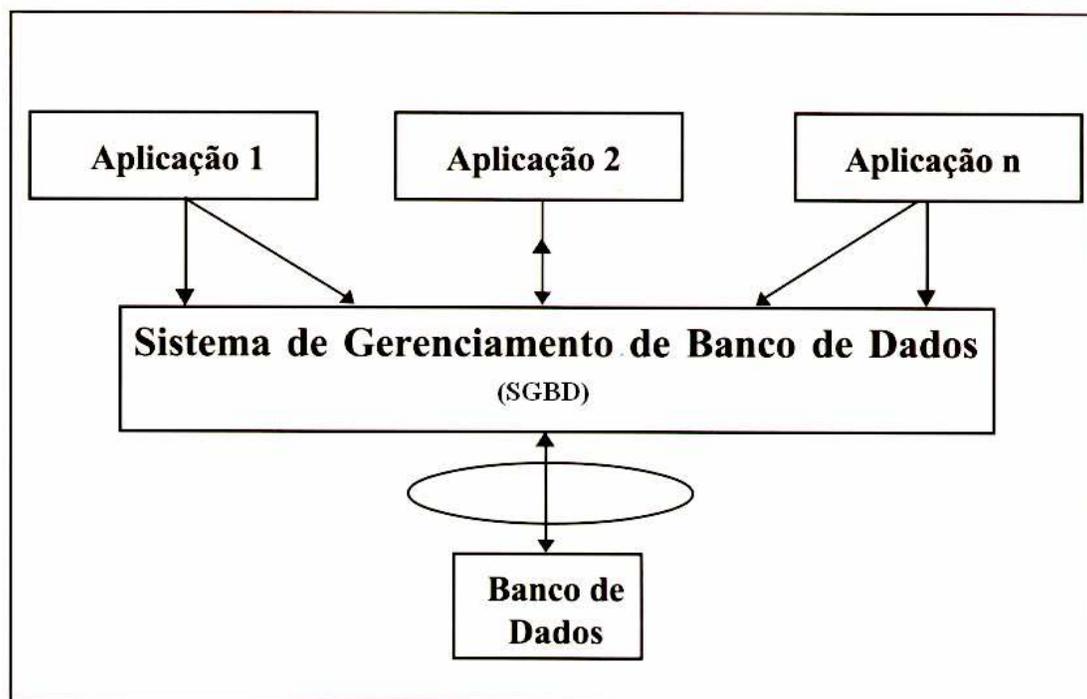


FIGURA 3 – Alguns aspectos de um ambiente de Sistema de Gerenciamento de Banco de Dados (SGBD). (Fonte: MEDEIROS e PIRES, 1998)

b) SGBD: Modelo Entidade – Relacionamento

“O modelo de dados entidade-relacionamento (E-R) baseia-se na percepção de um universo constituído por um grupo básico de objetos chamados entidades e por relacionamentos entre estes objetos” (KORTH e SILBERSCHATZ, 1989, p. 23).

Uma entidade é um objeto que tem existência própria e é distinguível de outros através de um conjunto de atributos que descrevem o objeto. Já o relacionamento é uma associação entre entidades (KORTH e SILBERSCHATZ, 1989; FURTADO e SANTOS, 1989; AGUIAR, 1995).

No modelo E-R existem algumas restrições de mapeamento as quais o banco de dados deve obedecer. Como exemplo, tem-se o **mapeamento de cardinalidades**, que expressa o número de entidades ao qual outra entidade pode estar associada, via um conjunto de relacionamentos, e a **dependência existencial**, que especifica a dependência entre duas entidades diferentes. Conceitualmente, entidades individuais e relacionamentos são distintos, porém considerando a perspectiva de banco de dados, esta diferença precisa ser determinada em relação a seus atributos. Para que isso ocorra, uma chave primária é associada a cada conjunto de entidades (KORTH e SILBERSCHATZ, 1989).

Segundo os mesmos autores, a estrutura lógica global de um banco de dados pode ser determinada graficamente por um diagrama E-R. Se um banco de dados apresentar essa condição, então ele pode ser representado por uma coleção de tabelas, considerando que para cada conjunto de entidades ou de relacionamentos há uma tabela única constituída de diversas colunas com nomes distintos.

c) Algumas aplicações na área da agricultura

Pesquisas realizadas em fazendas experimentais descritas nos estudos de Sano et al. (1998) mostraram a necessidade da criação de um banco de dados tendo em sua estrutura as informações referentes ao histórico de uso de cada campo experimental envolvendo algumas variáveis como: identificação do campo experimental; ano de plantio; tipos de cultivo; preparo

do solo; calagem; adubação (quantidade de N, P, K e micronutrientes) e semeadura (data, espaçamento, profundidade, equipamento utilizado e data da colheita).

JOAQUIM (1998) cita que a Copersucar, para atender à demanda de informações de suas unidades cooperadas, desenvolveu um programa chamado Gerenciamento Agrícola (GA) que é uma ferramenta de apoio na coleta, organização e processamento das diversas informações geradas pela área agrícola das usinas. A implantação desse sistema possibilitou uma padronização na forma com que os dados são armazenados, facilitando a utilização dos mesmos. Além disso, a análise dos relatórios oriundos desse sistema permite melhorar o planejamento e o controle técnico da área agrícola e avaliar a necessidade de introdução de novas tecnologias de produção. Enfim, o sistema de Gerenciamento Agrícola (GA) ocupa-se do planejamento, da otimização e do controle da safra da cana-de-açúcar.

2.2. Introdução a Redes Neurais

Redes neurais artificiais (RNAs) ou, simplesmente, redes neurais (RNs) são sistemas computacionais que apresentam características de desempenho semelhantes às redes neurais biológicas. As RNs são sistemas de processamento de informação que se baseiam na evidência biológica de uma grande multiplicidade de elementos de processamento muito simples chamados neurônios, que apresentam alto grau de interconexão e paralelismo (GONÇALVES, 1997; CASTRO, 1998).

GONÇALVES (1997) comenta que entre as várias características das redes neurais destacam-se:

- flexibilidade e fácil ajuste de seu comportamento a novos ambientes, devido à sua capacidade de aprendizagem a partir de exemplos;
- capacidade de generalização;
- controle altamente paralelo e distribuído, explorando muitas hipóteses simultaneamente, ao invés de um processamento seqüencial de instruções.

RAMOS (2001) cita que a célula nervosa biológica chamada neurônio é delimitada por uma fina membrana celular que possui propriedades que permitem a transmissão de sinais elétricos. O neurônio biológico é dividido em três partes principais:

- os dendritos, cuja função é receber os estímulos transmitidos por outros neurônios;

- o corpo do neurônio, também chamado de soma, que é responsável por coletar e combinar as informações vindas de outros neurônios. É o centro dos processos metabólicos da célula nervosa;

- o axônio, que é o responsável pela condução do impulso nervoso na saída do neurônio.

A Figura 4 apresenta um modelo de um neurônio biológico com a seqüência de propagação dos sinais pela célula.

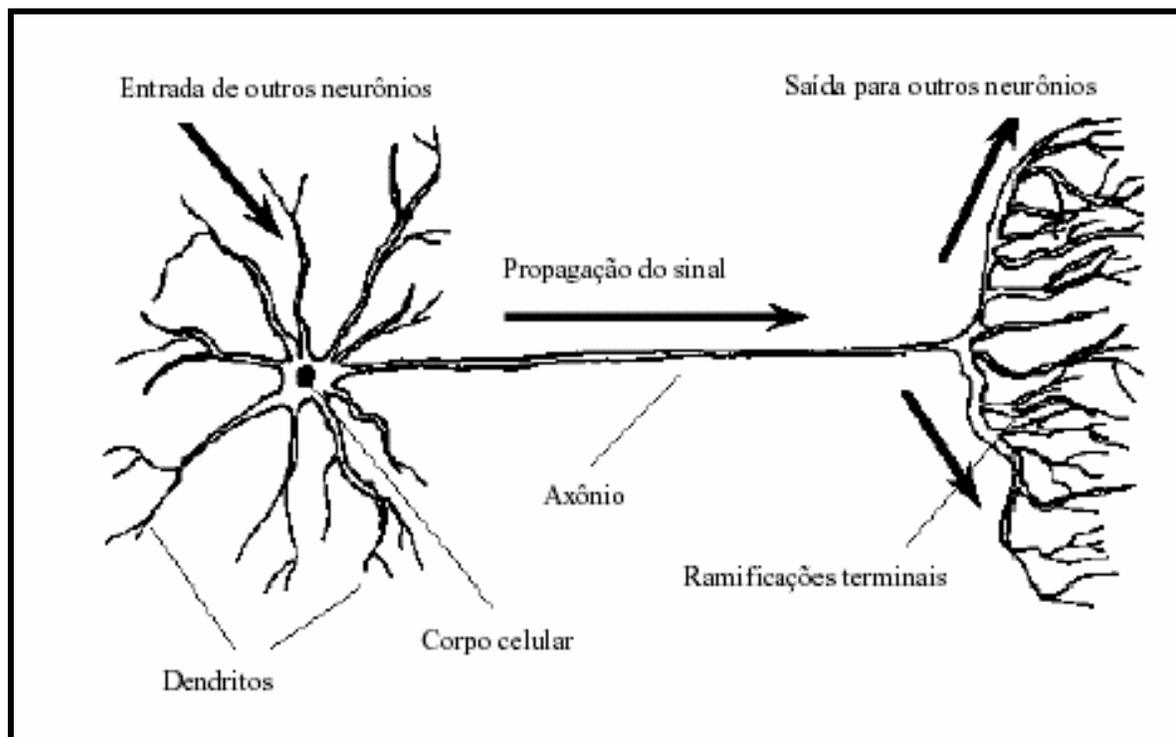


FIGURA 4 - Célula neural biológica com a seqüência de propagação do sinal.(Fonte: CASTRO, 1998)

As redes neurais têm sido aplicadas para resolver problemas reais de considerável complexidade. Sua grande vantagem é poder resolver problemas muito complexos, que não encontram uma solução algorítmica nas tecnologias convencionais ou que a solução seja muito difícil de ser encontrada (GONÇALVES, 1997; GALO, 2000).

Os autores dizem ainda que, em função de sua complexidade, ainda se está muito longe das redes neurais produzirem resultados tão completos e perfeitos quanto aqueles

relativos ao cérebro humano. Entretanto, os problemas de classificação de padrões estão entre os melhores resolvidos por estas redes.

“A natureza das RNAs faz com que seu estudo seja multidisciplinar, envolvendo pesquisadores de diversas áreas, como neurofisiologia, psicologia, física, computação e engenharia” (CASTRO, 1998).

2.2.1. Características Principais

O modelo genérico de um neurônio artificial recebe sinais provenientes de sensores ou de outros neurônios através de conexões de entrada, semelhantes aos dendritos do neurônio biológico. Os sinais gerados pelo neurônio artificial são transmitidos através das conexões de saída, análogo ao axônio biológico (GONÇALVES, 1997).

As RNs têm sido desenvolvidas como generalizações de modelos matemáticos da cognição humana ou biologia neural, considerando que (CASTRO, 1998):

- o processamento da informação ocorre em vários elementos chamados neurônios;
- os sinais são propagados de um elemento a outro através de conexões ou sinapses;
- cada conexão possui um peso sináptico associado, que, em uma rede neural típica, pondera o sinal transmitido; e
- para cada neurônio (ou unidade) é aplicada uma função de ativação (geralmente não-linear) sobre o somatório ponderado dos sinais de entrada, para determinar a saída.

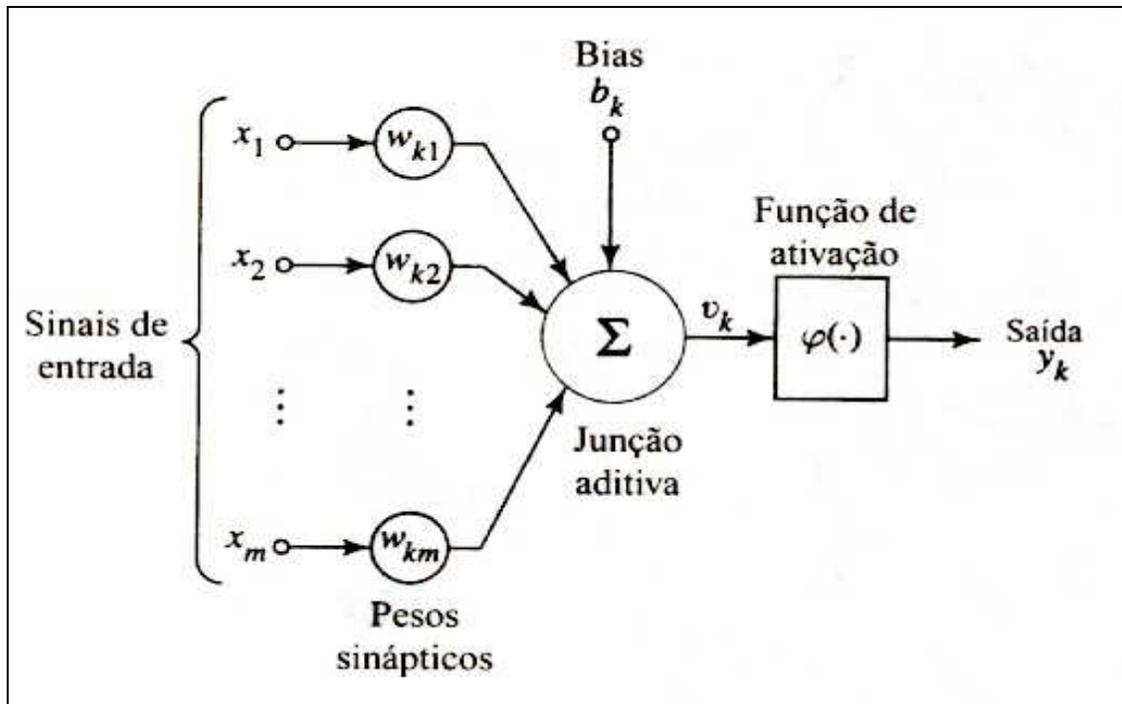


FIGURA 5 - Modelo não-linear de um neurônio. (Fonte: HAYKIN, 1999, p. 36)

A Figura 5 mostra um modelo não-linear de neurônio artificial. Analisando os elementos constituintes deste neurônio, GONÇALVES (1997) e HAYKIN (1999) analisam suas correlações e analogias, como segue abaixo:

- as conexões ou sinais de entrada x_m são dotados de sinapses, que modulam o sinal recebido. Essa modulação é representada por um operador sináptico v_k e por um peso sináptico w_{km} (k indica o neurônio que está recebendo o sinal e m indica a origem do sinal), sendo que o operador mais utilizado é o produto algébrico;

- as sinapses do neurônio artificial se assemelham às sinapses biológicas, que são os pontos de ligação entre os neurônios, funcionando como válvulas capazes de controlar a transmissão de impulsos e regular as suas intensidades;

- o processamento neural dos sinais recebidos é modelado por duas funções: a de agregação de entradas Σ e a função de ativação $\varphi(\cdot)$;

- quanto à função de agregação Σ , ela é responsável por fundir os sinais de entrada, fornecendo um valor que representa o conjunto de sinais. Em geral, utiliza-se o somatório dos sinais de entrada;

- a função de ativação $\varphi(\cdot)$ produz um sinal de saída y_k a partir do sinal agregado de entradas. Considerando a analogia com o neurônio biológico, pode-se associar o somatório de sinais de entrada ao processo de integração dos pulsos elétricos recebidos, efetuado pela capacitância da membrana do neurônio, e o valor de saída à representação da frequência dos pulsos gerados pelo neurônio.

Em síntese, CASTRO (1998) comenta que uma rede neural pode ser caracterizada por três aspectos principais: a função de ativação de seus neurônios, o método de determinação dos pesos das conexões (algoritmo de treinamento ou aprendizado) e o padrão de conexões entre as unidades (arquitetura).

2.2.2. Função de ativação

As funções de ativação mais comuns são função sinal, função sigmóide e função gaussiana. Sua forma é geralmente não-linear (Figura 6), contendo um ponto de corte ou limiar (u_l). Esta forma visa reproduzir o comportamento do neurônio biológico, que se torna ativo apenas quando for estimulado para além de um determinado limiar (GONÇALVES, 1997; CASTRO, 1998; HAYKIN, 1999).

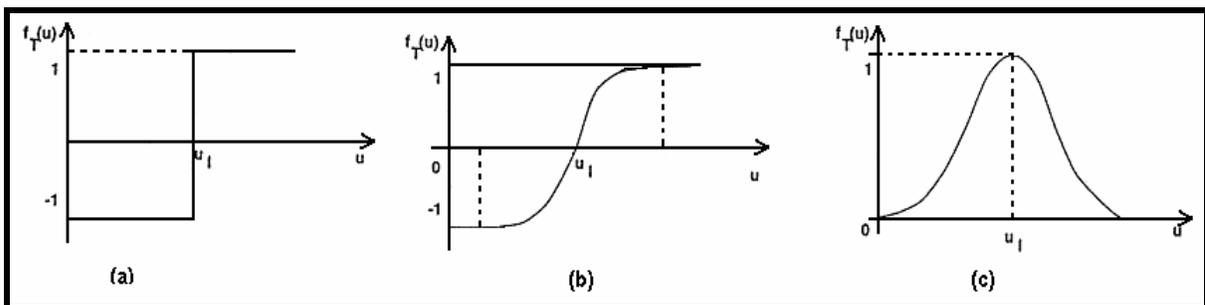


FIGURA 6 - Tipos de funções de ativação: (a) sinal, (b) sigmóide e (c) gaussiana. (Adaptado de Gonçalves, 1997)

A função de ativação representa o efeito que a entrada interna e o estado atual de ativação exercem na definição do próximo estado de ativação da unidade. Tendo em vista a simplicidade desejada para as unidades processadoras, geralmente define-se seu estado de ativação como uma função algébrica da entrada interna atual. Geralmente, esta função é não-

decrecente e apresenta um tipo de não-linearidade associada ao efeito da saturação. Na seqüência, são descritos alguns tipos de função de ativação empregados na literatura (KOSKO, 1992; HAYKIN, 1999):

Função Logística

A origem dessa função sigmóide está vinculada à preocupação em limitar o intervalo de variação da função entre 0 e 1, pela inclusão de um efeito de saturação. Sua derivada (Equação 1) também é uma função contínua.

$$f(x) = \frac{e^{px}}{1 + e^{px}} = \frac{1}{1 + e^{-px}}, \quad f'(x) = p f(x) \cdot (1 - f(x)) \quad (01)$$

Onde:

$f(x)$ = função logística

p = parâmetro de inclinação da função

x = campo local induzido do neurônio

Função Tangente Hiperbólica

A função logística apresenta valores de ativação apenas no intervalo entre 0 e 1, por esse motivo, em muitos casos ela é substituída pela função tangente hiperbólica, que preserva a forma sigmoidal da função logística, mas assume valores positivos e negativos definidos pelo intervalo ($f(x) \in (-1,1)$). A função tangente hiperbólica e sua derivada (Equação 2) são dadas pelas expressões:

$$f(x) = \frac{e^{px} - e^{-px}}{e^{px} + e^{-px}} = \tanh(x), \quad f'(x) = p(1 - f(x)^2) \quad (2)$$

Onde:

$f(x)$ = função tangente hiperbólica

x = campo local induzido do neurônio

A função tangente hiperbólica geralmente é escolhida para as unidades intermediárias das redes do tipo MultiLayer Perceptron. Uma consideração a ser feita é que a função tangente hiperbólica pode ser transladada para o intervalo (0,1), assim como a função logística pode ser transladada para o intervalo (-1,1).

Função Arco-Tangente

Pode ser apresentada como uma alternativa à função tangente hiperbólica na implementação computacional, pois requer menos cálculos para sua elaboração. Comparações de tempo de processamento mostram que a função arco-tangente possui o menor tempo de processamento, seguida da função logística e por último a função tangente hiperbólica. A função arco-tangente e sua derivada (Equação 3) possuem valores de ativação no intervalo $(-\pi/2, \pi/2)$ e é dada pela seguinte expressão:

$$f(x) = a \tan(px) \qquad f'(x) = p \cdot \frac{1}{1+x^2} \qquad (3)$$

Onde:

$f(x)$ = função arco-tangente

p = parâmetro de inclinação da função

x = campo local induzido do neurônio

Como no exemplo das funções anteriores, os limites dos intervalos da função arco-tangente podem ser transladados para o intervalo (-1,1) comumente utilizado.

2.2.3. Algoritmos de treinamento

Uma das características mais interessantes de uma rede neural é a habilidade que ela possui em aprender a resolver problemas por meio de exemplos, ou seja, por condicionamento (GONÇALVES, 1997; CASTRO, 1998; RAMOS, 2001).

Esse aprendizado é um processo pelo qual os parâmetros da rede são adaptados por meio de um processo contínuo de estimulação pelo ambiente onde a rede está inserida. Este processo está condicionado à seguinte seqüência de fatos (HAYKIN, 1999):

- a rede neural é estimulada por um ambiente;
- a rede neural sofre mudanças em consequência dessa estimulação;
- a rede neural responde de uma maneira nova ao ambiente, devido às mudanças que ocorreram em sua estrutura interna.

GONÇALVES (1997) e RAMOS (2001) comentam ainda que uma rede pode ser capaz de alterar a sua própria topologia, de modificar as funções de seus elementos processadores ou apenas alterar os valores dos pesos w_{ij} de suas conexões, como ocorre na maioria dos casos.

O tipo de aprendizagem em uma rede neural é definido pela maneira com que os seus parâmetros são ajustados. Existem dois grandes paradigmas de aprendizado segundo (HAYKIN, 1999):

- supervisionado ou associativo: necessita de um **professor** durante a fase de aprendizagem, que antecede a execução da rede, isso significa dizer que o conhecimento sobre o ambiente é representado por um conjunto de exemplos de entrada-saída, e
- não-supervisionado ou auto-organizado: direcionado por correlações existentes nos dados de entrada, ou seja, não há exemplos rotulados da função a ser aprendida pela rede.

A maioria dos algoritmos de aprendizagem procura fazer a rede se adaptar aos estímulos de treinamento através de um ajuste de pesos das conexões entre os neurônios, de acordo com alguma regra de modificação. Na prática, as regras de aprendizagem de modelos como os descritos anteriormente são variantes da regra de aprendizagem proposta por Hebb em 1949. O princípio básico dessa regra é reforçar as conexões entre neurônios que se ativam simultaneamente quando a rede é estimulada. Na seqüência, são citados alguns algoritmos de otimização para treinamento supervisionado e não-supervisionado (GONÇALVES, 1997).

Algoritmos de Otimização para Treinamento Supervisionado

- Algoritmo padrão (BP)
- Método do gradiente (GRAD)
- Gradiente conjugado (GC)
- Algoritmo de 2ª ordem de Polak-Ribière (PR)
- Gradiente conjugado escalonado de MOLLER (1993) (SCG)
- Newton (MN)
- Levenberg-Marquardt (LM)
- Davidon-Fletcher-Powell (DFP)
- Broyden-Fletcher-Goldfarb-Shanno (BFGS)
- Battiti - One-step Secant (OSS)
- Quickprop de FAHLMAN (QUICK)
- Máquina de Boltzmann (BM)
- Mean Field Annealing (MFA)
- Filtro de Kalman Recorrente (EKF)

Algoritmos de Otimização para Treinamento Não-Supervisionado

- Grossberg Aditivo (AG)
- Adaptive Resonance Theory (ART1)
- Hopfield Simétrico e Assimétrico (DH/CH)
- Memória Associativa Bidirecional (BAM)
- Memória Associativa Temporal (TAM)
- Mapa Auto-organizável de Kohonen (SOM)
- Aprendizado Competitivo
- $\vec{w}_{k+1} = \vec{w}_k + \alpha_k \cdot \vec{d}_k$ (onde: α_k = passo; \vec{d}_k = direção de ajuste)

2.2.4. Redes do tipo Perceptron de Múltiplas Camadas

As arquiteturas do tipo Perceptron de Múltiplas Camadas ou Multi Layer Perceptron (MLP) são os modelos neurais artificiais mais utilizados e conhecidos. Esta arquitetura consiste de um conjunto de unidades sensoriais que formam uma camada de entrada, uma ou

mais camadas intermediárias (chamadas escondidas ou ocultas) e uma camada de saída (Figura 7). Os sinais de entrada são propagados camada a camada pela rede em uma direção positiva, ou seja, da entrada para a saída. Esta arquitetura representa uma topologia de rede do tipo *feedforward* (GONÇALVES, 1997; CASTRO, 1998; HAYKIN, 1999; GALO, 2000).

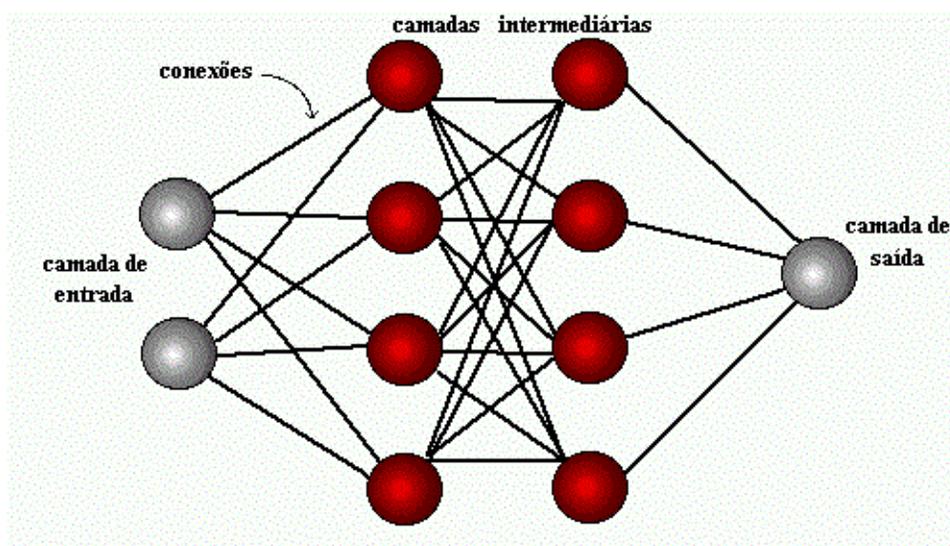


FIGURA 7 - Estrutura topológica da rede neural MLP. (Fonte: CARVALHO, 2002)

Os autores comentam ainda que, as redes *feedforward* são aquelas cujos sinais se propagam sempre da camada de entrada para a camada de saída da rede, passando por eventuais camadas intermediárias. Não existem conexões de realimentação, ou seja, conexões entre saídas de uma camada de neurônios e as entradas de neurônios da mesma camada ou de camadas anteriores.

As redes do tipo MLP são muito utilizadas para a solução de problemas envolvendo alto grau de não-linearidade. Seu treinamento é do tipo supervisionado e, usualmente, utiliza um algoritmo chamado retro-propagação do erro (*error backpropagation*). Este algoritmo é baseado numa regra de aprendizagem que corrige o erro durante o treinamento (HAYKIN, 1999).

O processo de treinamento por retro-propagação do erro é constituído de duas fases: uma fase positiva de propagação do sinal funcional (*feedforward*) e uma de retro-propagação do erro (*backpropagation*). Na fase positiva, os vetores de dados são aplicados às unidades de entrada, e seu efeito se propaga pela rede, camada a camada, até chegar a um conjunto de saídas correspondente à resposta da rede. Durante essa fase, os pesos das conexões são mantidos fixos. Na retro-propagação do erro, por outro lado, os pesos são ajustados de acordo com uma regra de correção do erro. Assim, a resposta da rede em um determinado instante de tempo é subtraída da saída desejada (*target*) para produzir um sinal de erro. Este sinal de erro é propagado da saída para a entrada, camada a camada, originando o nome **retro-propagação do erro**. Os pesos são ajustados de forma que o vetor de distância entre a resposta da rede e aquela desejada seja o mais reduzido possível, o que equivale ao menor erro encontrado entre o valor esperado e o calculado (VON ZUBEN, 1996; CASTRO, 1998).

2.2.5. Representação do conhecimento

As redes neurais artificiais utilizam a estrutura de interconexões para representar o conhecimento. Isso significa dizer que, com base na configuração resultante da rede, a intensidade das conexões é ajustada com o objetivo de armazenar informação. Pela complexidade de suas interconexões, o tipo de representação de conhecimento empregado no caso das redes neurais fornece potencialidades de representação ausentes em outros sistemas tradicionais de representação do conhecimento (CASTRO, 1998).

Considerando que todo conhecimento pode ser representado como parâmetros de um problema, o autor comenta ainda que a capacidade de representação das redes neurais geralmente excede a dimensão paramétrica do problema, pois o conhecimento é distribuído pelas conexões da rede, sendo que cada conexão pode participar na representação de mais de uma unidade de informação.

Na tentativa de representação do conhecimento, LIMA (2004) descreve que muitas técnicas e conceitos de aprendizado de máquina são apresentados, porém os “*ensembles* representam uma das principais direções atuais em pesquisa na área, e têm sido aplicados a uma grande extensão de problemas práticos”. O autor comenta que um *ensemble* consiste de um conjunto de componentes, cada um representando uma proposta de solução, cujas

classificações, no caso de problemas de reconhecimento de padrões, são combinadas de formas diversas visando um ganho de desempenho, demonstrando a tendência de ser mais preciso que qualquer um dos classificadores individuais que o compõem.

2.2.6. Preditores *ensemble*

LIMA (2004) em seu estudo sobre *ensemble* (combinação ou agrupamento) comenta que a metodologia “trata da obtenção de uma saída, para um problema de classificação ou regressão, a partir das saídas individuais propostas por múltiplas soluções alternativas para o mesmo problema, denominadas componentes do *ensemble*”, considerando ainda que *bagging* (**Bootstrap aggregating**) e *boosting* são dois métodos populares para a produção de *ensembles*.

O autor argumenta que um *ensemble* é construído em dois passos: primeiramente, a geração dos vários componentes e então, a combinação da saída proposta por estes. E que, “para garantir um melhor desempenho, deve-se adotar um metodologia baseada em três passos: treinamento (geração de componentes), seleção e combinação”.

Segundo BREIMAN (1996) “os preditores *bagging* são um método para generalização de versões múltiplas de um preditor e são usados para criar um preditor agregado. A agregação é obtida pelo cálculo da média das versões quando a predição é um resultado numérico e executa uma decisão pluralista quando a predição é de uma classe. As versões múltiplas são reamostradas de um conjunto de aprendizagem e usadas como um novo conjunto de dados para obter um consenso nas divergências. Testes sobre conjunto de dados reais e simulados usando árvores de classificação e regressão, com subconjuntos selecionados em uma regressão linear, mostram que o método do *bagging* pode proporcionar ganhos substanciais em acurácia”. O elemento vital é a estabilidade do método de predição, pois o objetivo do *ensemble* é reamostrar o conjunto de dados para obter um consenso nas divergências. “Se perturbações no conjunto de aprendizado podem causar trocas significativas na construção do preditor, então o *bagging* pode melhorar a acurácia”.

LEISCH e HORNIK (1997) complementam que “o *bagging* introduzido por BREIMAN (1996) para árvores de classificação também pode ser usado para redes neurais artificiais. O algoritmo *bagging* inicia com um conjunto de treinamento X_N . Várias réplicas de autocarregadores X_{N1}, \dots, X_{Nk} são construídos e uma rede neural é treinada para cada um deles.

Estas redes são finalmente combinadas por escolha majoritária. Os conjuntos de autocarregadores (*bootstrap*) X_{Ni} consistem de N padrões retirados com reposição oriundos do conjunto original de dados de treinamento.”

O treinamento da RN é usualmente um processo estocástico e variável. Como os pesos da rede são inicializados por randomização e os padrões de treinamento são apresentados também em ordenação randômica, as RNs treinadas a partir dos mesmos dados serão, tipicamente, diferentes em valores e performance. Além do mais, pequenas alterações na ordenação do conjunto de treinamento podem conduzir a duas redes treinadas completamente diferentes com diferentes performances, mesmo se as redes tiverem os mesmos pesos iniciais. Generalizando, as RNs têm uma baixa tendência (*bias*) por causa de sua capacidade de aproximação, mas uma variância um tanto alta, por causa de suas divergências. Conseqüentemente, para conjuntos de treinamento reamostrados do conjunto de treinamento original e combinando o resultado dos classificadores em um classificador de escolha, deve ser possível reduzir a alta variância dos algoritmos de classificação divergentes (LEISCH e HORNIK, 1997).

2.2.7. Aplicações de redes neurais na área ambiental

RIBEIRO e CENTENO (2001) aplicaram redes neurais com o objetivo de delimitar e caracterizar unidades de paisagem utilizando dados de imagens de sensoriamento remoto associados a dados topográficos e geológicos. As redes foram utilizadas como ferramentas para integração de dados de fontes diferentes e resultaram em uma alternativa à classificação tradicional, pois possibilitaram minimizar a subjetividade que cada analista utiliza na sua interpretação sobre as características únicas da paisagem. Os autores alegaram ainda que tal complementação de informações seria inviável se no processo de classificação fossem utilizados os métodos estatísticos convencionais.

As características espaciais, espectrais, radiométricas e temporais das imagens de sensoriamento remoto permitem sua utilização em uma ampla variedade de estudos ambientais. Já a aplicação de estruturas de redes neurais a essas imagens, muitas vezes integradas a dados temáticos, permitiu estabelecer relações de síntese entre as variáveis que representam o meio físico e os fenômenos ambientais. Nesse contexto, GALO (2000) buscou

adequar essas estruturas computacionais a diferentes situações de classificação e aplicou à caracterização ambiental do Parque Estadual Morro do Diabo (PEMD). Os resultados apontaram a viabilidade de se aplicar redes neurais no estudo da ecologia da paisagem.

BACA (2001) desenvolveu um aplicativo com técnicas de redes neurais para a Modelagem Numérica do Terreno (MNT), afirmando que em muitas situações é preciso ter valores pontuais interpolados para abranger amplas superfícies. Este tipo de levantamento pode ser utilizado para diversos fins, como por exemplo, o cálculo do desvio geoidal na determinação da altitude e o estudo da determinação de superfícies de temperatura.

O autor alega que em todos estes casos a metodologia tradicional de formação da grade de valores numéricos, empregando métodos geoestatísticos ou tradicionais, exige o armazenamento de grande volume de dados e o emprego de um aplicativo para a interpolação. A aplicação da ferramenta de redes neurais pode economizar espaço de armazenamento e facilitar a interpolação.

BRAGA (1995) propôs, em seu trabalho de tese, avançar os estudos no entendimento de modelos de previsão das principais fases fenológicas da cultura da maçã, considerando sua produtividade nas safras. Para tanto, foram desenvolvidos, testados e comparados modelos de previsão polinomiais contra redes neurais artificiais. A combinação destes modelos também foi testada, buscando minimizar desvios ou erros relativos das previsões.

O autor argumenta que os modelos têm fundamentação agrometeorológica com combinação de dados do potencial produtivo da espécie e seus cultivares, sendo que as variáveis ou estimadores agrometeorológicos considerados levam em conta o conceito de graus-dia, horas de frio e balanço hídrico. Os modelos desenvolvidos são polinomiais de diversas ordens, ajustados por regressão múltipla e a rede neural empregada foi a Back-Propagation.

MEDEIROS (1999) cita que as redes neurais podem ser utilizadas nas mais diversas áreas, principalmente em aplicações que envolvam a resolução de problemas de aproximação, mapeamento de funções e reconhecimento de padrões. No entanto, para que as soluções obtidas da implementação da rede tenham desempenho satisfatório, deve-se dispor de uma grande quantidade de dados de treinamento e não necessitar de regras de decisão discretas (por exemplo, sim ou não).

DRUMMOND et al. (2000) registraram em seus estudos de predição agrícola que os métodos tradicionais de compilação de dados são extremamente demorados e trabalhosos, o que não condiz com as exigências da realidade. Já considerando as técnicas de redes neurais, os autores consideraram-nas interessantes para essas situações, sendo que os resultados do estudo mostraram que a variação no tempo de treinamento entre os métodos neurais poderia certamente ser atribuído às especificidades do algoritmo de treinamento ou aos parâmetros de treinamento usados (ou a ambos), e por isso, foram considerados irrelevantes no estudo.

Ainda sobre o estudo de predição, uma situação interessante foi considerada: quando uma simples observação climatológica foi removida dos dados de treinamento, a habilidade de predição do método foi reduzida dramaticamente, embora uma das fases do experimento tenha indicado que o método não-linear teve a capacidade de sucesso usando variáveis climatológicas adicionais. Os autores sugeriram estudos mais aprofundados sobre essa situação.

CASTRO et al. (1998) enfatizam que o primeiro aspecto associado com os maiores desafios nos problemas de predição é o grande número de variáveis de entrada a serem consideradas e as interações não-lineares significativas entre elas, impedindo a adoção de estratégias de predição convencionais.

Segundo os autores as redes neurais artificiais são um dispositivo computacional muito poderoso para efetuar extração e representação de informações, podendo ser usadas para produzir um modelo de predição. Quando um problema de predição envolve um grande número de variáveis de entrada e existe uma interação não-linear entre elas, há a necessidade de introduzir vários métodos de redução de dimensão. As aplicações que usam arquiteturas de redes neurais podem ser encontradas em muitas áreas de pesquisa, sendo que as ferramentas de predição apresentadas nesse estudo podem ser diretamente aplicadas para todos os problemas de predição em outras áreas de pesquisa de similar complexidade.

SIMPSON (1998) publicou um estudo sobre uma estrutura de RN para predição de produtividade em safras agrícolas. Primeiramente, foi elaborado um estudo comparativo sobre desempenho de classificação de safras utilizando dois tipos de dados: dados agrometeorológicos (umidade do solo, temperatura, radiação solar) e dados de sensoriamento remoto, a partir de imagens Landsat 5 TM, encontrando resultados de 5% de erro padrão para os dados estudados. Após, foi implementado, com sucesso, o treinamento de uma RN CMAC

(Cerebellar Model Articulation Controller) empregando dados de classificação de nuvens por imagens Meteosat e identificação de minerais pelo o sensor AVIRIS, visando a predição da produtividade agrícola.

3. PROCEDIMENTOS METODOLÓGICOS

O presente estudo está estruturado em duas partes seqüenciais. Esta separação foi proposta com o objetivo de favorecer o entendimento da estrutura metodológica desenvolvida.

Na primeira etapa são demonstrados os procedimentos de obtenção e organização das variáveis de produção utilizadas como padrões de reconhecimento no treinamento da RN, tais como: dados de produção da usina, índices de vegetação e coeficiente de produtividade. Na segunda etapa, descreve-se a arquitetura e topologia da rede neural utilizada como ferramenta integradora das variáveis de produção, e também os procedimentos de implementação desta ferramenta.

A seguir, destaca-se a divisão do presente trabalho em duas etapas de estudo:

1ª Etapa – Obtenção e organização das variáveis de produção

2ª Etapa – Treinamento, validação e teste da Rede Neural - Integração dos Dados

A Figura 8, apresenta-se o fluxograma metodológico das etapas da pesquisa.

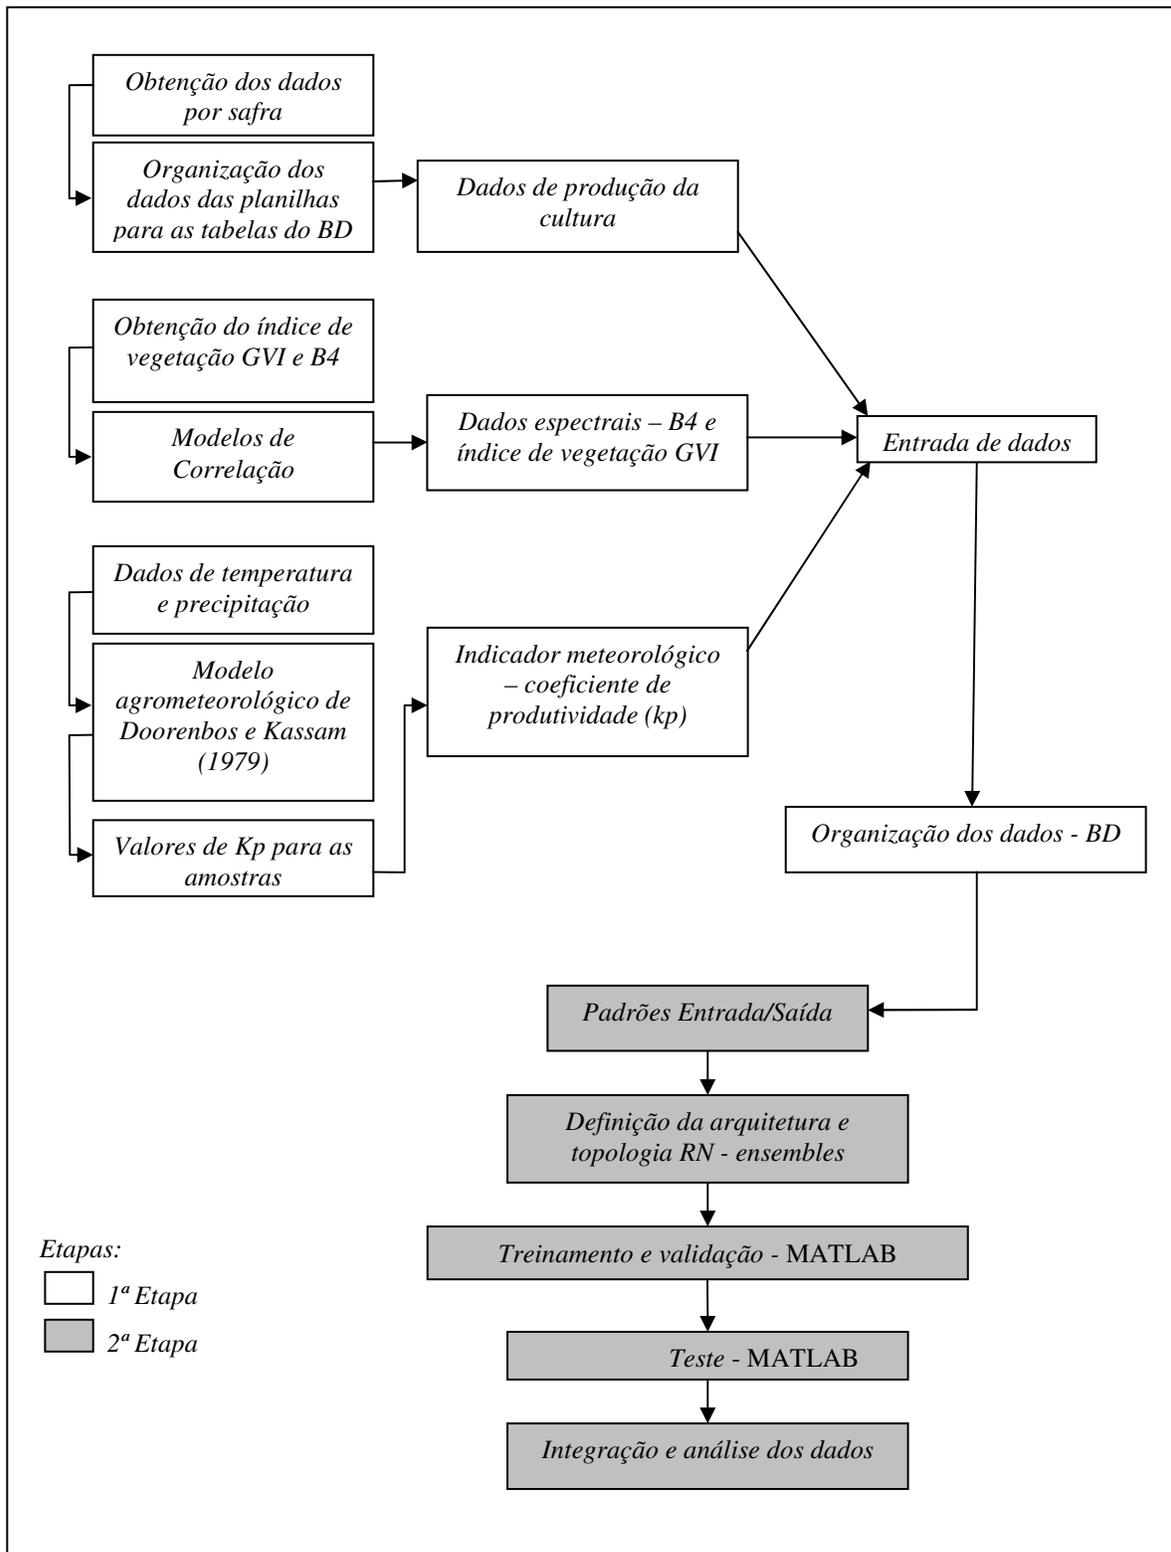


FIGURA 8 – Fluxograma metodológico da pesquisa.

3.1. Área de estudo

Este estudo foi implantado em áreas de produção de cana-de-açúcar na Usina São João Açúcar e Álcool S/A, localizada no município de Araras, no Estado de São Paulo (Figura 9), por meio de um convênio com o Grupo de Estudos em Geoprocessamento, da Faculdade de Engenharia Agrícola, desta Universidade.

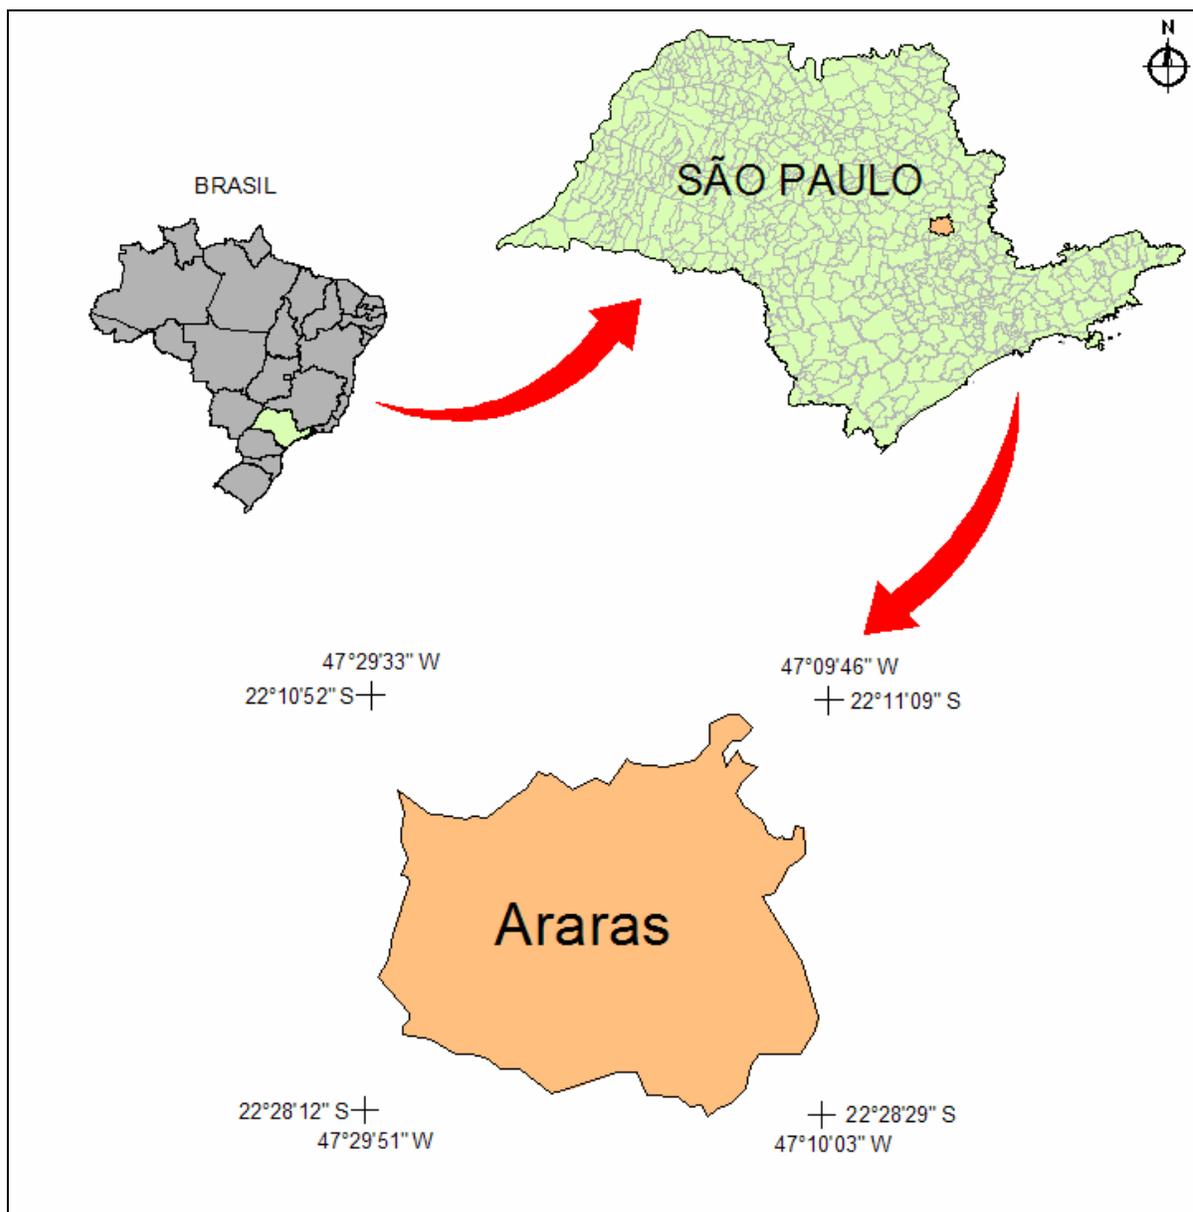


FIGURA 9 - Localização do município de Araras no Estado de São Paulo-Brasil.

A usina foi escolhida por sua tradição e importância junto ao setor sucroalcooleiro nacional. Ocupando uma área superior a 40 mil hectares cultivados com cana-de-açúcar, encontra-se entre as principais usinas produtoras do estado de São Paulo e é considerada uma das principais fornecedoras de açúcar para os segmentos industriais. Esta posição deve-se ao fato de produzir álcool e açúcar cristal de várias especificações e com eficaz controle de qualidade de matérias-primas, processos e produtos acabados, além de ser dotada de uma matriz energética muito bem equilibrada, possuindo auto-suficiência na geração elétrica, o que permite maior flexibilidade e incremento de sua produção.

Nesta pesquisa, as áreas amostrais delineadas para a condução do experimento foram escolhidas em talhões de cana-de-açúcar previamente determinados, considerando como quesitos técnicos de escolha: a disponibilidade de informações sobre a produção e os tratamentos culturais; a acessibilidade à área e também o planejamento da usina para a colheita da safra, pois a qualidade dos dados de produção obtida no campo depende da capacidade de controle, pela usina, das informações de produtividade da safra no talhão, considerando também, a disponibilidade técnica para aplicação de práticas de coleta de dados.

No processo de seleção das áreas, foram consideradas as seguintes características de plantio: tipo de variedade, ambiente de produção, estágio de corte e tipo de colheita. Essas características permitiram a análise e a correlação da produtividade com os fatores que influenciaram a mesma.

Na área da usina foram escolhidas 91 unidades amostrais com dimensões de 30 metros de largura por 50 metros de comprimento, compreendendo uma área aproximada de 1500 m² cada. Essas áreas estão distribuídas espacialmente dentro da usina segundo a Figura 10.

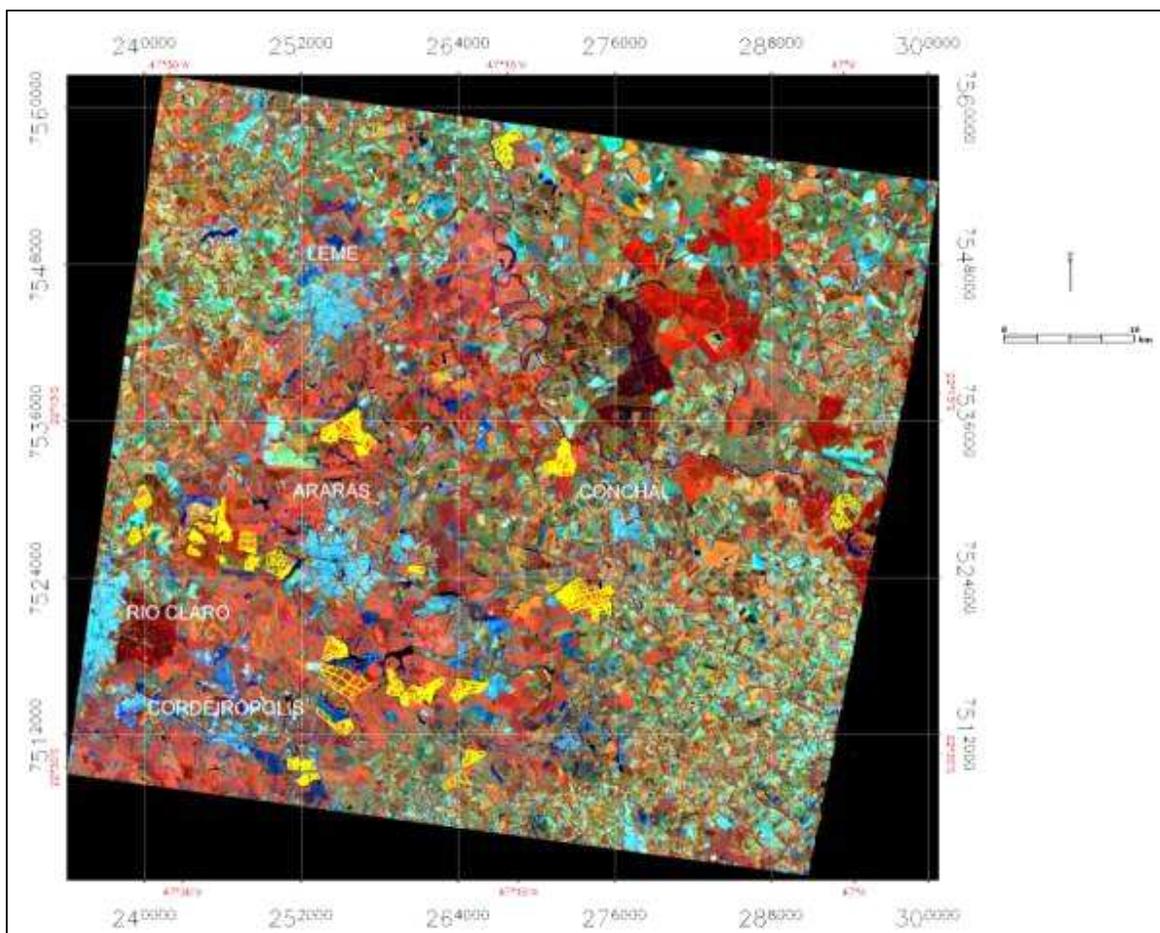


FIGURA 10 – Distribuição espacial dos talhões (em amarelo) na imagem Landsat 7 ETM⁺, projeção UTM 23S, datum SAD69, composição RGB 453.

3.2. Obtenção das variáveis de entrada da rede neural

Neste estudo, foram pesquisados três grupos de variáveis diferenciados pelo tipo de dados: dados de produção da cana-de-açúcar, dados espectrais de imagens Landsat 7 ETM⁺ e dados meteorológicos de estações terrestres.

3.2.1. Variáveis de produção da cana-de-açúcar

Os dados de produção foram fornecidos pela usina e estão estruturados na forma de planilhas armazenadas em arquivos digitais de formato xls, padrão do programa Microsoft Excel. Nestes arquivos encontram-se os seguintes dados de produção distribuídos por talhão: ano agrícola, fazenda, zona, talhão, variedade, estágio de corte, área do talhão, ambiente de solo, data do plantio, data do último corte, produção real e estimada, e produtividade real e estimada. Estes dados foram obtidos para dois anos de colheita: 2001 e 2002 (ANEXO 1).

As variedades estudadas foram SP80-1816 e SP80-1842, ambas desenvolvidas pela Copersucar (COPERSUCAR, 1993; COPERSUCAR, 1997a) e de grande ocorrência na usina durante o período em que se desenvolveu esta pesquisa, o que facilitou a obtenção de um grande conjunto de dados de produção. Apesar dessa facilidade, ao analisar as planilhas de dados e consultando as rotinas operacionais de colheitas efetuadas pela usina, observou-se que, apesar dos dados de produção estarem discriminados por talhão, na prática os valores não correspondiam ao talhão especificado, ou seja, no momento do carregamento a produção era misturada no caminhão que transportava a cana-de-açúcar até a usina. Isto acontecia devido à logística de colher a produção mecanicamente, talhão por talhão. Assim, optou-se por utilizar as informações de produtividade por zona, que representa conjuntos de talhões com ambiente de produção semelhante, seguindo os estudos experimentais de BENVENUTI (2002).

3.2.2. Dados espectrais

Esta etapa de aquisição de dados está diretamente relacionada aos resultados do trabalho de dissertação desenvolvido por MACHADO (2003), que fundamentou seu estudo na variabilidade espacial da biomassa de cana-de-açúcar utilizando índices de vegetação a partir de dados de reflectância. Este trabalho inferiu sobre a correlação entre a quantidade de biomassa da cultura de cana-de-açúcar e sua resposta espectral.

Assim, para melhor entendimento da origem dos dados espectrais que foram utilizados no presente estudo, mostra-se a seqüência em que os dados foram trabalhados no estudo de MACHADO (2003):

1 - Correção atmosférica das imagens Landsat 7-ETM⁺, órbita/ponto 220/75, pelo Sistema de Correção Radiométrica de Imagens de Satélite – SCORADIS, desenvolvido por ZULLO Jr. (1994);

2 - Correção geométrica das imagens Landsat 7-ETM⁺, por compilação de pontos de controle nas imagens e em cartas topográficas do IBGE, na escala 1:50.000;

3 - Obtenção dos valores de produtividade da biomassa nas áreas de amostragem através da pesagem de colmos. Esse processo é semelhante aos procedimentos efetuados pela usina no período da safra. Os pontos de coleta foram demarcados por áreas de amostragem;

4 - Correlação entre a resposta espectral da biomassa e sua produtividade através da análise da banda B4 e do índice de vegetação GVI. A melhor correlação entre os índices de vegetação e a produtividade foi determinada através da análise de regressão entre os dados de produtividade de cada parcela amostral e seus valores espectrais.

3.2.3. Dados meteorológicos

Foram utilizados dados de precipitação pluviométrica e temperatura do ar, correspondentes ao período de janeiro de 2000 a julho de 2002. Estes dados foram provenientes de 5 estações meteorológicas localizadas no entorno da área de estudo: Campinas, Cordeirópolis, Espírito Santo do Pinhal e Piracicaba (Instituto Agrônomo de Campinas-IAC) e UFSCar (Centro de Ciências Agrárias da UFSCar - Campus Araras) (FIGURA 11).

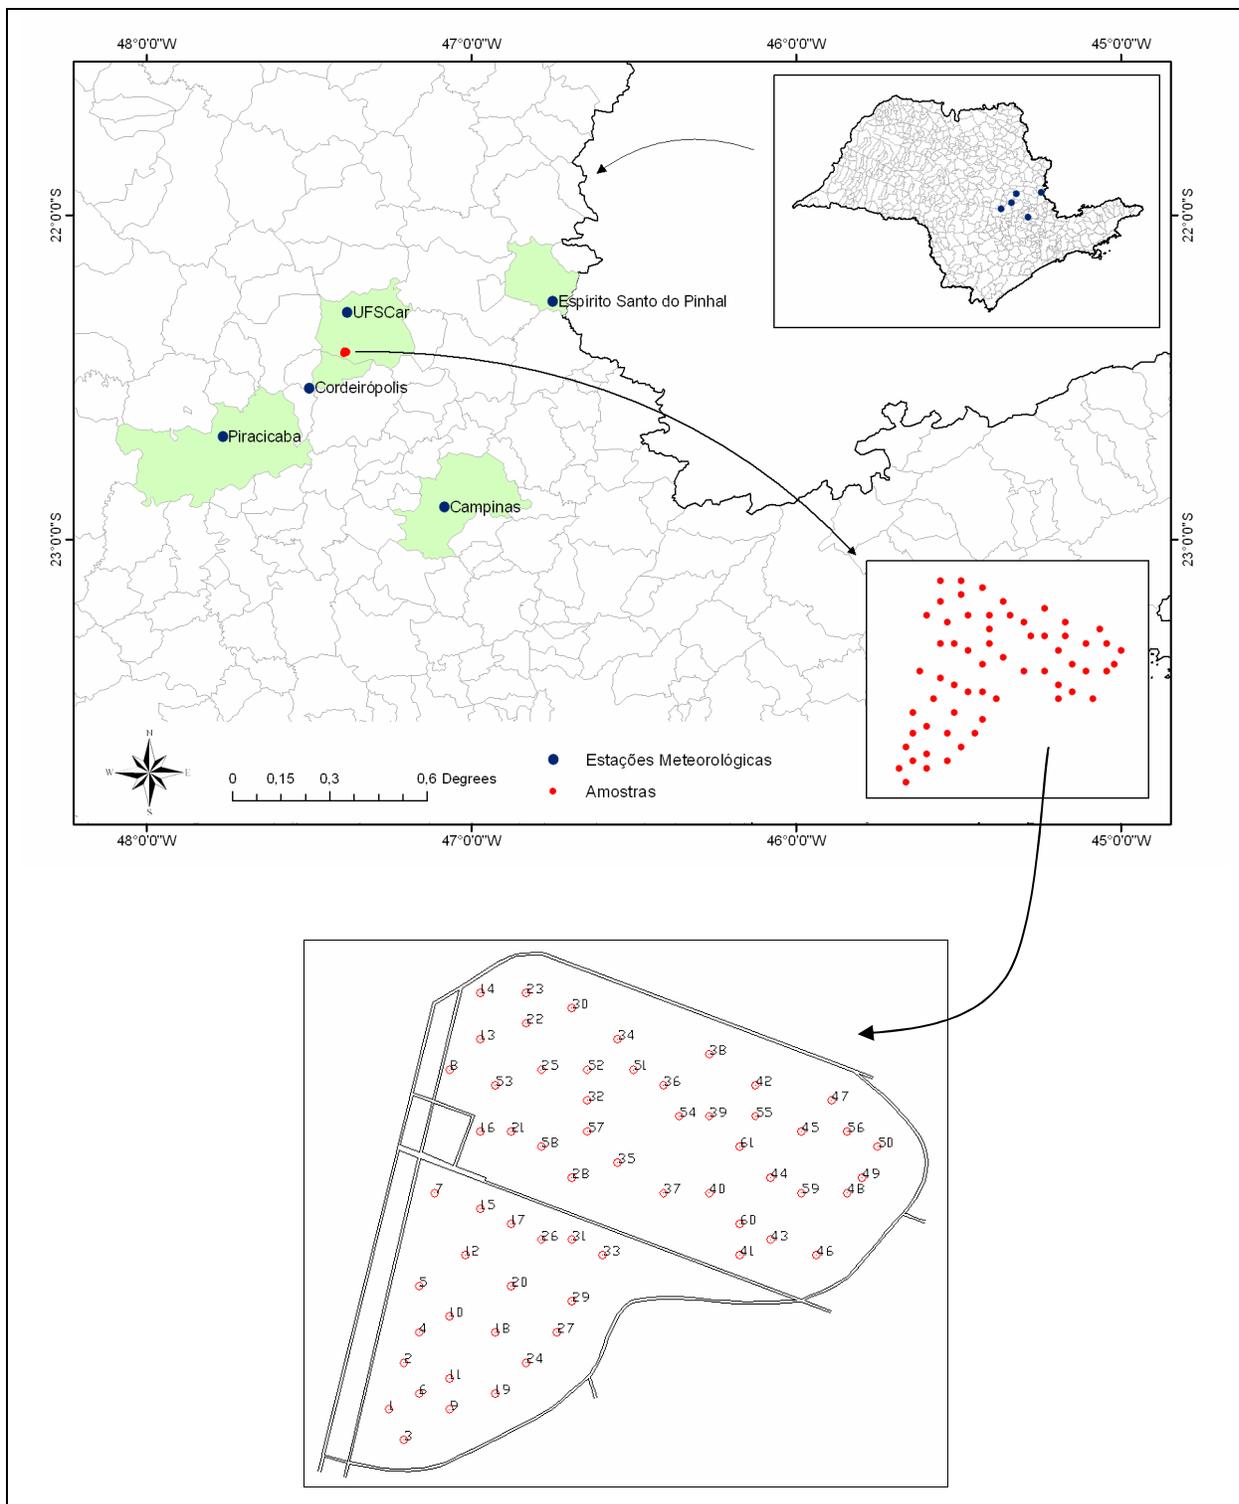


FIGURA 11 – Distribuição espacial das estações meteorológicas e dos pontos amostrais nos talhões.

O modelo agrometeorológico que foi utilizado nesse trabalho baseou-se no modelo proposto por DOORENBOS e KASSAM (1979) que quantifica o efeito da falta de água disponível no solo sobre a produtividade da cultura, ou seja, estima a produtividade de uma cultura em função da disponibilidade hídrica do solo (RUDORFF e BATISTA, 1988; MORAES, 1998).

Segundo os autores, o modelo se baseia na penalização da produtividade relativa ($1 - PE/PM$) em relação ao déficit da evapotranspiração relativa ($1 - ETR/ETM$), por meio do fator de penalização da produtividade (kp). Esta relação é demonstrada na Equação 4:

$$\boxed{\left(1 - \frac{PE}{PM}\right) = kp \left(1 - \frac{ETR}{ETM}\right)} \quad [4]$$

onde:

PE = Produtividade estimada, em kg/ha.

PM = Produtividade máxima, em kg/ha.

ETR = Evapotranspiração real, em mm.

ETM = Evapotranspiração máxima, em mm.

kp = fator de penalização da produtividade por déficit hídrico.

A metodologia proposta para obter os valores dos indicadores meteorológicos baseia-se na inversão do modelo agrometeorológico descrito acima. Assim, conhecendo-se a relação entre a produtividade (PE/PM) e a influência da disponibilidade hídrica na cultura (ETR/ETM), obtém-se o kp para determinada variedade em determinado estágio de corte. Esta condição foi estabelecida pelas características das amostras de cana-de-açúcar estudadas nessa pesquisa.

Essa situação permite expressar a Equação 4 da seguinte forma:

$$\boxed{kp = \frac{\left(1 - \frac{PE}{PM}\right)}{\left(1 - \frac{ETR}{ETM}\right)}} \quad [5]$$

A produtividade estimada (**PE**) foi obtida por meio da pesagem das parcelas amostrais dos talhões em estudo, na época da colheita da safra da cana-de-açúcar na usina, segundo metodologia desenvolvida por MACHADO (2003).

No que se refere à produtividade máxima (**PM**), esta foi obtida dos resultados dos ensaios estaduais da variedade realizados por COPERSUCAR (1993, 1997b), onde foram pesquisados os valores máximos de produtividade para a região, de acordo com suas características genéticas e sua adaptação ao meio (COPERSUCAR, 1997a).

Para o cálculo da Evapotranspiração Real (**ETR**), foi aplicado o balanço hídrico decenal segundo o método de THORNTHWAITE e MATHER (1955), obtendo-se também a deficiência e o excedente hídrico do solo para a cultura. Já a Evapotranspiração Máxima (**ETM**) foi determinada pelo método simplificado por Camargo em 1971, através da utilização do índice “T”, adaptando-o às condições climáticas do Estado de São Paulo (CAMARGO, 1984; CAMARGO e CAMARGO, 2000), expresso na Equação 6:

$$EP = Q_0 \cdot T \cdot K \cdot D \quad [6]$$

onde:

EP = evapotranspiração potencial, em mm/dia.

Q₀ = radiação solar extraterrestre incidente acima da atmosfera.

T = temperatura média diária do período, em °C.

K = fator de ajuste.

D = número de dias do período.

Os valores de evapotranspiração foram calculados pelo programa BHSEQ - Balanço Hídrico Seqüencial, implementado por ZULLO Jr. (2002) do Centro de Pesquisas Meteorológicas e Climáticas Aplicadas à Agricultura (CEPAGRI) da UNICAMP. Estes valores foram obtidos para cada uma das 5 estações meteorológicas. Na seqüência, foram geradas superfícies de interpolação de ETR e ETM, obtendo-se os valores para cada unidade amostral.

O **kp** foi calculado segundo a expressão determinada na Equação 5.

Os valores de **kp** disponíveis na literatura são resultados experimentais de variedades altamente produtivas, bem adaptadas ao ambiente e desenvolvidas sob alto nível de manejo de culturas. A aplicação deste fator de resposta da cultura permitiu a quantificação do suprimento de água e sua utilização em termos de produtividade da mesma (DOORENBOS e KASSAM, 1979). O modelo agrometeorológico utilizado serviu para obter este coeficiente que foi um indicador da relação da disponibilidade hídrica, como variável meteorológica, na produtividade da cultura.

Partindo do modelo de DOORENBOS e KASSAM (1979) foram calculados os diferentes **kp** para os valores de produtividade registrados nas unidades amostrais. Assim, identificaram-se os limites mínimos e máximos de variabilidade, indicando a variação segundo os dados meteorológicos. O resultado dessa metodologia foi uma escala de valores de **kp** para a área de estudo.

Considerando que existe correlação entre a produtividade e a resposta espectral da imagem, através do índice de vegetação, então o passo seguinte foi inverter o modelo de produtividade, considerando o **kp** que melhor se adapta à média da resposta espectral do talhão. Tendo o resultado da produtividade conhecido, então, pôde-se avaliar qual **kp** melhor respondeu à correlação.

3.2.4. Estruturação das variáveis no banco de dados

Tendo obtido os dados de produção da usina e os valores dos índices de vegetação e dos coeficientes de produtividade, o passo seguinte foi organizar esses dados num banco ou base de dados relacional.

Para a implementação do banco de dados, foi utilizado o programa Access da Microsoft, por oferecer as ferramentas básicas para a criação e o desenvolvimento da base de dados. Sua característica de fácil manejo favorece o armazenamento, a organização e o compartilhamento dos dados, ajudando o usuário na tomada de decisão.

No caso dos dados de produção da usina, estes se encontram armazenados em planilhas do programa Excel (ANEXO 1). Então, o primeiro passo foi importar essas planilhas para o banco de dados, respeitando a estrutura original definida pela usina. Esses dados foram

organizados em tabelas considerando o agrupamento temporal, ou seja, ter-se-á tabelas com informações de produção por ano-safra.

Em cada um dos registros foram agrupadas as informações de produção por talhão. Assim, foram estabelecidos indexadores para esses registros tendo o talhão como unidade de produção. Esse procedimento ajudou na fase de consulta, quando foi necessário agrupar as informações por zona de produção. Os campos da tabela que compõe o indexador foram constituídos pelas numerações da zona e do talhão.

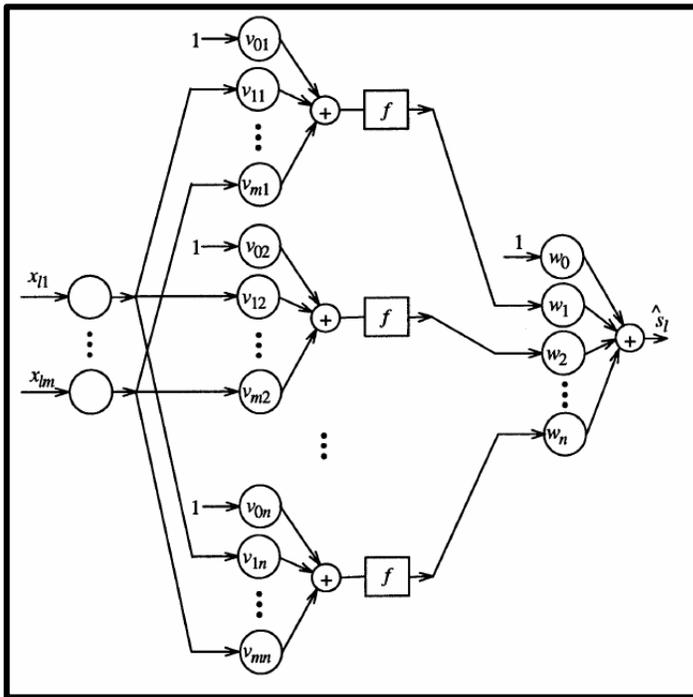
Quanto aos valores dos índices de vegetação, estes também foram organizados por talhão, sendo que cada tabela teve como estrutura básica os seguintes campos: zona, talhão e valores dos índices de vegetação.

No que se refere aos valores de kp, estes também foram organizados por talhões. Porém, nos casos em que se teve mais de uma unidade amostral por talhão, foi preciso criar uma subdivisão na identificação do talhão para que fosse possível a indexação dos registros.

3.3. Rede Neural para integração de dados espectrais e meteorológicos

Neste trabalho empregou-se uma arquitetura de RN com características de *feedforward*. Esta determinação baseou-se em trabalhos científicos publicados na área de predição agrícola que obtiveram resultados satisfatórios em suas implementações (CASTRO et al., 1998; DRUMMOND et al., 2000). Especificamente, foram seguidas as etapas metodológicas determinadas por CASTRO et al. (1998) que adaptou uma arquitetura neural para a predição de culturas agrícolas.

A estratégia inicial para predição foi baseada no aprendizado supervisionado aplicado para uma arquitetura de rede neural baseada na composição de uma rede *Multilayer Perceptron* (MLP), com uma camada escondida (FIGURA 12).



Onde:

- n = número de neurônios escondidos;
- m = dimensão do vetor de entrada;
- l = índice de ligação com o padrão de entrada-saída usado durante o processo de treinamento;
- v_{ij} ($i=0, \dots, m$; $j=1, \dots, n$) = pesos da camada escondida;
- w_j ($j=0, \dots, n$) = pesos da camada de saída;
- f = função de ativação sigmoideal (tangente hiperbólica);
- x_{li} = i -ésimo neurônio de entrada para o l -ésimo padrão;
- \hat{s}_l = predição de saída para a rede neural com o l -ésimo padrão.

FIGURA 12 - Rede neural de arquitetura *Multilayer Perceptron* (MLP) com *bias*. (CASTRO et al., 1998)

3.3.1. Etapas para o ajuste da RN: treinamento, validação e teste

O treinamento da rede MLP foi baseado no Método do Gradiente Conjugado de Pollak-Ribière (CASTRO et al., 1998 e HAYKIN, 1999). O tempo de treinamento dependeu do número de iterações necessárias para se alcançar o mínimo global representativo considerando os padrões de entrada/saída, sendo que o critério de parada foi determinado pela etapa de validação.

Para implementação da rede neural e das funções de aprendizagem/treinamento foi utilizado o programa Matlab 6.0 - MathWorks. Este programa ofereceu a possibilidade de efetuar a simulação do desempenho da rede a partir de arquiteturas neurais especializadas e adaptadas à situação de predição de culturas agrícolas. O código fonte foi implementado a partir da bibliografia publicada por CASTRO (1998) e CASTRO et al. (1998), e foi adaptado para este estudo por VON ZUBEN, LIMA e VILLANUEVA (2004) (APÊNDICES 1 a 15).

A etapa de teste consistiu em apresentar à rede neural treinada e validada, dados de entrada selecionados do banco de dados, cujas características são semelhantes às das variáveis de entrada, consideradas na fase de treinamento da rede e que não foram usados no treinamento.

Para ajustar as funções da RN foram adotados os seguintes procedimentos:

- Efetuou-se o ajuste da função para gerar as matrizes de padrões de entrada (X) e de saída (S). Esta função gerou aleatoriamente a ordem das matrizes para a etapa de treinamento, validação e teste da RN (Apêndice 01);

- Submeteu-se a topologia da RN a diferentes números de neurônios na camada escondida e a várias iterações. A topologia que apresentou melhor desempenho foi a RN de dimensão 3 (1 camada de entrada, 1 camada escondida e 1 camada de saída), composta por 3 neurônios na camada de entrada, 15 neurônios na camada escondida e 1 neurônio na camada de saída. Os neurônios da camada de entrada correspondem aos padrões das variáveis obtidas da banda B4, do índice de vegetação GVI e do coeficiente k_p ; e os neurônios da camada de saída são representados pelos padrões de produtividade. A RN foi treinada com critério de parada de 10000 iterações e limiar de 10^{-5} .

- O Erro Quadrático Médio (EQM) do conjunto de validação foi considerado como critério de parada e o de teste foi utilizado para avaliar o resultado do treinamento.

- Os dados utilizados na implementação da RN foram 91 padrões de entrada/saída subdivididos em frações de 60% para treinamento, 20% para validação e 20% para teste. Eles foram normalizados com Variância igual a 0 (zero) e Desvio Padrão igual a 1.

3.3.2. Preditor *Ensemble/Bagging*

No presente estudo, o processo de treinamento/validação/teste da RN consistiu no agrupamento de 10, 20, 50 e 100 componentes de RNs, que foram colocadas para processar paralelamente, compondo 4 grupos de preditores *ensembles*. Estes conjuntos de RNs apresentaram melhores resultados em relação aos estimadores associados a qualquer uma das redes individualmente. Num primeiro momento, a metodologia do *bagging* foi empregada como método de seleção de componentes de melhor desempenho. Porém, as médias dos componentes não apresentaram resultados superiores às médias das RN tomadas isoladamente,

então se aplicou a técnica de PERRONE e COOPER (1993), que sugerem um método de seleção pelo qual os componentes treinados são ordenados segundo o erro quadrático médio (EQM) crescente.

LIMA (2004) sugere que o *ensemble* seja formado pela lista ordenada dos candidatos de melhor desempenho ou pela adoção de uma técnica construtiva, com a inclusão de componentes (RNs) que conduzam a um incremento na capacidade de generalização junto a um conjunto de dados de teste. Então, de uma maneira generalista, seguiu-se os passos:

1 - Ordenação dos candidatos a compor o *ensemble* segundo o desempenho junto aos dados de teste;

2 - Inclusão do candidato de melhor desempenho, significando dizer que o componente de melhor desempenho participa sempre;

3 - Inclusão do próximo componente de melhor desempenho no *ensemble*. Se não houver um próximo candidato, então o procedimento termina neste passo;

4 - Se esta inclusão melhorar o desempenho do *ensemble*, manter a inclusão e voltar ao passo 3. Caso piore o desempenho, retirar este componente do *ensemble* e voltar ao passo 3 novamente.

A metodologia de seleção de componentes de *ensembles* seguiu à descrita por LIMA (2004), em que o desempenho dos componentes é avaliado pelos Métodos de Seleção pela Média, Método Construtivo e Método de Poda.

O processo de avaliação e teste de desempenho dos *ensembles* constituiu-se do treinamento de quatro grupos com 10, 20, 50 e 100 redes neurais cada um, sendo implementadas 10 simulações de desempenho para cada grupo.

O 1º grupo de *ensemble* foi composto por 10 redes neurais. Para cada RN realizou-se o seguinte procedimento:

- Efetuou-se o reordenamento do conjunto de treinamento, tomando o cuidado para que a semente de geração aleatória não produzisse a mesma ordem dos padrões de entrada/saída;

- Após, foi feito o treinamento das redes neurais com critério de parada guiado pelo conjunto de validação. Para isto, foram rodadas várias iterações até encontrar o erro mínimo

global do conjunto de validação. Em seguida, executou-se novamente o treinamento até o ponto onde foi encontrado o valor mínimo.

A saída do *ensemble* de 10 componentes, treinados até maximizar o desempenho junto ao conjunto de validação, foi determinada pelas médias aritméticas dos EQMs, considerando o método de seleção de componentes pela Média, Construtivo e de Poda. Este procedimento foi implementado com 10 simulações, sendo os resultados finais determinados pela média aritmética para cada método de seleção.

Este procedimento foi implementado para os outros três grupos de *ensembles* com 20, 50 e 100 componentes de RNs.

A partir da integração dos dados espectrais e agrometeorológicos realizada por meio das RNs foi possível determinar o erro quadrático médio (EQM) entre a produtividade encontrada pela RN e a produtividade real coletada no campo. O erro determinado pelas RNs foi então comparado com o erro obtido pelo método de estimativa da usina, indicando desta forma a capacidade de competitividade e a possibilidade de utilização das redes neurais como método de estimativa de produção.

4. RESULTADOS E DISCUSSÕES

4.1. Variáveis de produção

4.1.1. Produtividade e dados espectrais

A produtividade e os dados espectrais de reflectância das amostras foram obtidos do trabalho de Machado (2003), que colheu informações de 91 unidades, em três épocas diferentes: 02/11/2001, 27/04/2002 e 16/07/2002. Estas datas correspondem a época de máximo desenvolvimento vegetativo da cana-de-açúcar e próxima à colheita. No presente trabalho, foi utilizada a reflectância obtida pela Banda 4 e pelo índice GVI determinado a partir das imagens do sensor ETM⁺ do Landsat 7, como dados a compor o padrão de entrada para treinamento das RNs e a produtividade como padrão de saída (ANEXO 2).

4.1.2. Indicador meteorológico - kp

O indicador meteorológico foi determinado a partir do balanço hídrico decendial sequencial, implementado por meio do programa BHSEQ (ZULLO Jr., 2002). Este programa forneceu os valores de evapotranspiração real (ETR) e evapotranspiração máxima (ETM) para cada estação meteorológica. A partir destes valores, criaram-se superfícies de interpolação para ETR e ETM, correspondentes aos períodos de coleta de dados, obtendo-se os valores de evapotranspiração para cada amostra. Estes dados, juntamente com a produtividade colhida, foram inseridos no modelo agrometeorológico de DOORENBOS e KASSAM (1979), cuja inversão possibilitou a obtenção dos coeficientes de produtividade (kp) (QUADRO 1).

O Quadro 1 mostra os valores de kp obtidos para as amostras e permite a comparação da variação do mesmo, com o intervalo recomendado por DOORENBOS e KASSAM (1979).

QUADRO 1 – ETR, ETM e coeficiente de produtividade (kp) das amostras para três diferentes datas.

Coleta	ETR (mm)	ETM (mm)	Amostra	Produtividade colhida (kg/ha)	Produtividade máxima (kg/ha)	kp	Coleta	ETR (mm)	ETM (mm)	Amostra	Produtividade colhida (kg/ha)	Produtividade máxima (kg/ha)	kp
2/11/2001	34,02	52,19	1	82350	118500	1,07	27/4/2002	13,96	41,05	1	69120	118500	0,63
	34,00	52,18	2	64470		0,84		13,71	41,33	2	55660		0,79
	34,06	52,20	3	73140		0,95		13,67	41,15	3	91170		0,35
	34,07	52,20	4	55790		0,72		13,67	41,10	4	62570		0,71
	34,10	52,21	5	60640		0,78		13,65	41,15	5	63590		0,69
	34,20	52,23	6	67560		0,87		13,64	41,27	6	64970		0,67
	34,06	52,19	7	67500		0,87		13,67	41,26	7	88360		0,38
	34,13	52,21	8	75180		0,97		13,68	41,27	8	92390		0,33
	34,20	52,23	9	82720		1,07		13,70	41,26	9	71290		0,60
	34,14	52,21	10	74810		0,97		13,60	41,19	10	84240		0,43
	33,67	53,00	11	69330		0,93		13,58	41,16	11	65840		0,66
	34,13	52,20	12	63460		0,82		13,59	41,25	12	62720		0,70
	34,87	52,01	13	67360		0,84		13,62	41,17	13	55610		0,79
	34,15	52,20	14	68730		0,89		13,62	41,25	14	83680		0,44
	34,21	52,22	15	70780		0,91		13,21	41,30	15	94590		0,30
	34,24	52,23	16	66670		0,86		13,19	41,31	16	82540		0,45
	34,26	52,24	17	78670		1,01		13,27	41,28	17	77890		0,51
	34,14	52,20	18	83560		1,08		13,23	41,32	18	40130		0,97
	34,21	52,21	19	73780		0,95		13,30	41,31	19	72490		0,57
	34,18	52,20	20	72860		0,94		13,94	41,04	20	75550		0,55
35,00	51,02	21	78670	0,93	6,03	29,30	21	71810	0,50				
34,23	52,21	22	81330	1,05	6,07	29,71	22	61170	0,61				
34,25	52,21	23	69350	0,89	5,97	30,11	23	79610	0,41				
34,30	52,22	24	80000	1,03	6,07	30,56	24	79990	0,41				
34,37	52,23	25	78670	1,01	6,02	30,35	25	59330	0,62				
34,34	52,22	26	72440	0,93	5,96	30,78	26	61540	0,60				
34,43	52,24	27	81780	1,05	5,91	30,80	27	55620	0,66				
34,41	52,23	28	82380	1,06	5,95	29,77	28	78070	0,43				
34,39	52,22	29	77330	0,99	5,73	30,38	29	109700	0,09				
34,39	52,21	30	83560	1,07	5,90	30,41	30	118480	0,00				
33,89	52,98	31	75110	1,01	5,95	30,17	31	67120	0,54				
34,42	52,22	32	77330	0,99	6,00	30,45	32	64060	0,57				
34,82	52,01	33	80950	1,02	5,89	30,72	33	57860	0,63				
34,48	52,23	34	80890	1,03	5,96	30,36	34	100200	0,19				
34,46	52,22	35	80440	1,03	5,90	30,78	35	82030	0,38				
34,53	52,23	36	74850	0,96	5,96	30,50	36	80590	0,40				
34,51	52,22	37	94220	1,20	5,90	30,91	37	72320	0,48				
34,54	52,23	38	78570	1,00	5,95	30,97	38	39360	0,83				
34,54	52,23	39	78670	1,00	5,86	30,76	39	81110	0,39				
34,33	52,23	40	74670	0,96	5,58	30,99	40	70670	0,49				
34,30	52,23	41	88130	1,13									
34,20	52,23	42	85900	1,11									
33,60	52,97	43	71920	0,97									
34,46	52,23	44	71730	0,92									
34,53	52,23	45	90720	1,16									
34,28	52,22	46	81350	1,05									
34,23	52,22	47	72630	0,94									
34,46	52,22	48	79140	1,01									
34,40	52,22	49	74010	0,95									
34,42	52,23	50	76170	0,98									
34,16	52,21	51	76050	0,98									

Os valores de kp para a cana-de-açúcar, encontrados em DOORENBOS e KASSAM (1979), variam de acordo com os períodos específicos de crescimento da cultura, sendo 0,75 no período vegetativo, 0,5 na formação da colheita e 0,1 na maturação. Neste estudo (QUADRO 1), o intervalo variou entre 0 (zero) e 1,2. Estes resultados mostraram que o kp, usualmente recomendado para estimar a produtividade, não é sensível às diversidades da cultura, tais como: diferenças entre variedades plantadas, estágio fisiológico e sistema de manejo. Os valores tabelados são resultados de análises de dados experimentais de campo de alta produtividade, bem adaptadas ao ambiente de crescimento e desenvolvidas sob alto nível de manejo de culturas. Esta discussão tem a pretensão de enaltecer a importância de se rever

os critérios utilizados para obter estes coeficientes, pois eles são comumente usados no modelo de estimativa de produtividade dos referidos autores, como fator de penalização por déficit hídrico.

4.1.3. Correlação entre as variáveis

BARROS NETO et al. (2002) comentam que a demonstração da correlação em diagramas de dispersão é importante para o gerenciamento da qualidade dos dados, pela eficiência em revelar padrões de associação entre variáveis. Assim, nas Figuras 13 a 15 são apresentados os coeficientes de correlação amostral entre as variáveis da banda B4, do índice GVI e do coeficiente k_p , com a produtividade colhida.

a) Correlação entre a reflectância da banda B4 e a produtividade colhida

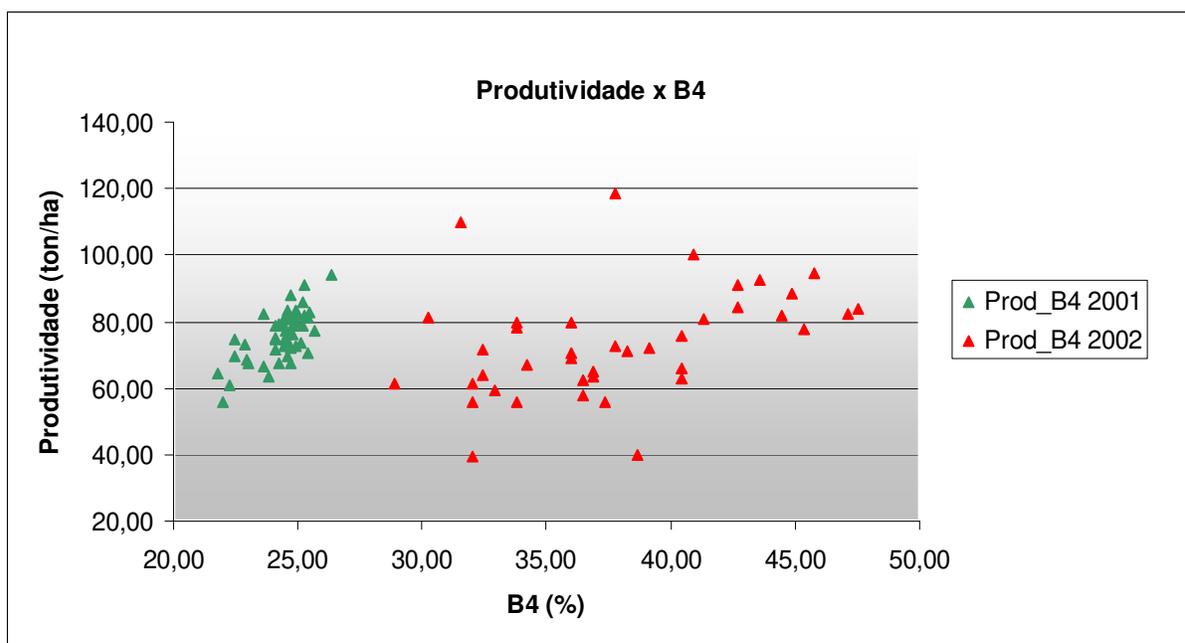


FIGURA 13 – Diagrama de dispersão da reflectância (%) da banda B4 com a produtividade colhida (ton/ha).

O coeficiente de correlação determinado entre a banda B4 e a produtividade foi de 0,66, indicando que há uma tendência parcial de relação linear entre as variáveis. Contudo, na

Figura 13 observa-se que a dispersão ocorreu em 2 padrões de agrupamento, que representam os ciclos de crescimento da cana-de-açúcar na época de aquisição dos dados: amostras obtidas em 2001, próximas à colheita (em verde) e amostras obtidas em 2002, no período de maturação e de colheita (em vermelho). A análise da dispersão pode indicar a existência de outro tipo de dependência, não explicada pela medida de associação linear entre as duas variáveis, como argumentam BARROS NETO et al. (2002).

b) Correlação entre a reflectância do índice GVI e a produtividade colhida

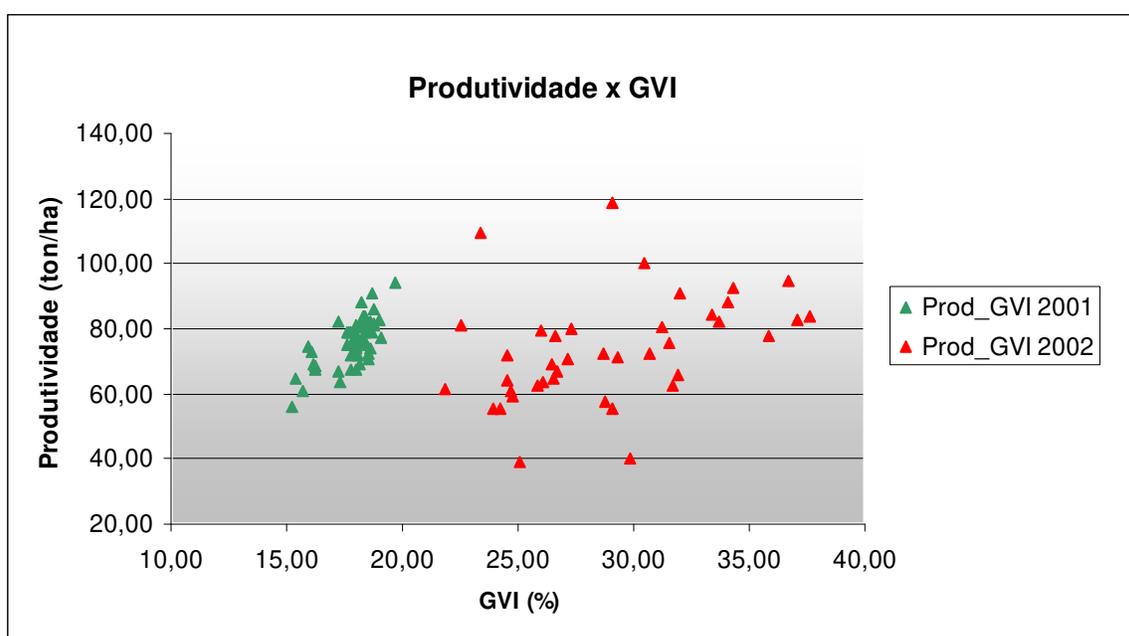


FIGURA 14 – Diagrama de dispersão da produtividade colhida (ton/ha) com o índice GVI expresso em % de reflectância.

O coeficiente de correlação amostral obtido entre o índice GVI e a produtividade foi de 0,65, indicando que ocorreu uma relação parcialmente linear entre as variáveis. Esta análise permite identificar um comportamento semelhante ao encontrado nas dispersões da banda B4 (Figura 13), isto é, a existência de 2 padrões de agrupamentos. Provavelmente, a semelhança na dispersão dos dados ocorreu pelo fato de ambas as variáveis representarem a reflectância da vegetação verde da cana-de-açúcar.

As Figuras 13 e 14 mostram a correlação positiva entre os índices de reflectância da banda B4 e do GVI com a produtividade, corroborando os resultados de diversos autores que afirmam que, quanto maior estes índices, maior os valores de produtividade de cana-de-açúcar. As duas variáveis correlacionadas foram consideradas no mapeamento de entrada da RN. Apesar de expressarem resultados semelhantes foram obtidas por diferentes procedimentos: uma pelo valor absoluto e a outra, pela razão entre bandas.

c) Correlação entre o coeficiente k_p e a produtividade colhida

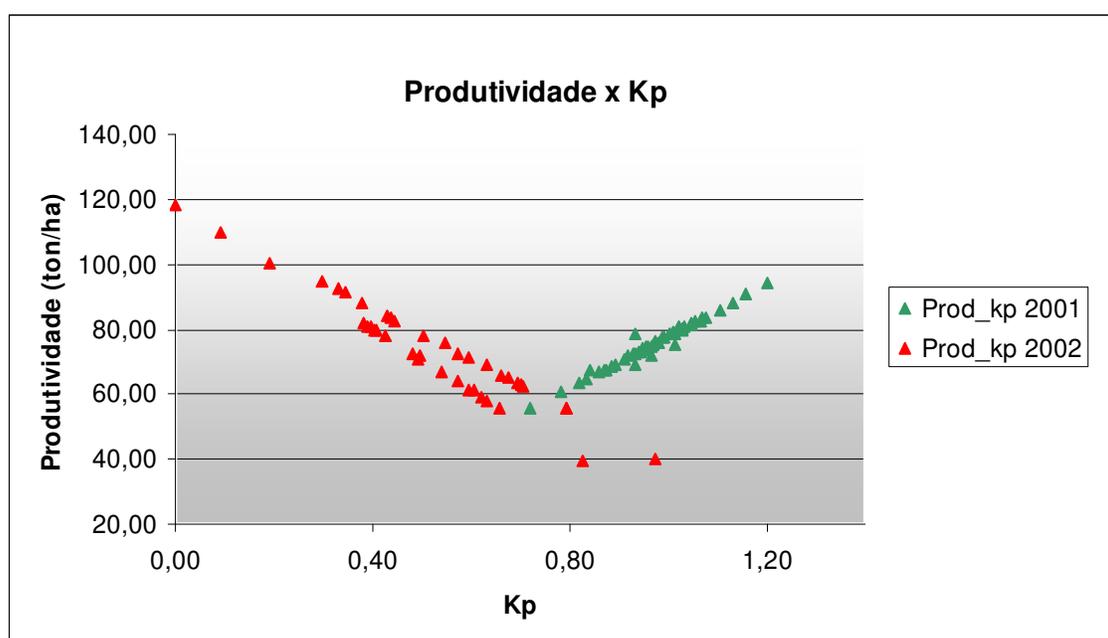


FIGURA 15 – Diagrama de dispersão da produtividade colhida (ton/ha) com o coeficiente k_p .

O coeficiente de correlação amostral determinado entre a produtividade colhida e o k_p foi de 0,74, indicando uma correlação maior que as encontradas para a B4 e o GVI. Analisando a Figura 15, pode-se perceber também a existência de 2 padrões de agrupamentos demarcados em verde (dados 2001) e em vermelho (dados de 2002), correspondentes aos ciclos de crescimento da cana-de-açúcar. Porém, se analisados separadamente, os coeficientes de correlação chegam próximos a relação linear perfeita, isto é, 1 (um). Isto se deve ao fato de que os valores de k_p apresentaram pouca variação entre si, considerando as superfícies de

interpolação de ETR e ETM utilizadas neste trabalho. O gráfico de dispersão mostra ainda que o k_p apresenta uma relação inversa com a produtividade, isto é, quanto maior o valor de k_p , menor será a produtividade, pois maior será a sua penalização por déficit hídrico.

4.1.4. Banco de dados de entrada/saída para a RN

A partir da obtenção dos valores de produtividade colhidos em ton/ha, dos valores de B4 e GVI e dos valores do k_p , organizou-se um banco de dados no aplicativo MS Access, de maneira a auxiliar a disponibilidade dos mesmos como variáveis de entrada/saída para treinamento da rede neural. O Quadro 2 mostra a estrutura das variáveis de entrada/saída da RN para as 91 amostras.

QUADRO 2 – Variáveis de entrada e saída da RN, obtidas a partir de consulta ao banco de dados.

Amostra	Entrada RN			Saída RN	Amostra	Entrada RN			Saída RN
	B4	GVI	kp	Produtividade (ton/ha)		B4	GVI	kp	Produtividade (ton/ha)
1	23,63	17,27	1,07	82,35	52	36,00	26,42	0,63	69,12
2	21,76	15,35	0,84	64,47	53	33,78	24,20	0,79	55,66
3	22,84	16,11	0,95	73,14	54	42,67	32,02	0,35	91,17
4	21,96	15,26	0,72	55,79	55	36,44	25,86	0,71	62,57
5	22,25	15,67	0,78	60,64	56	36,89	26,10	0,69	63,59
6	24,22	17,75	0,87	67,56	57	36,89	26,54	0,67	64,97
7	23,04	16,26	0,87	67,50	58	44,89	34,09	0,38	88,36
8	24,12	17,60	0,97	75,18	59	43,56	34,28	0,33	92,39
9	25,49	18,99	1,07	82,72	60	38,22	29,30	0,60	71,29
10	22,45	15,94	0,97	74,81	61	42,67	33,41	0,43	84,24
11	22,45	16,12	0,93	69,33	62	40,44	31,96	0,66	65,84
12	23,82	17,33	0,82	63,46	63	40,44	31,69	0,70	62,72
13	24,71	18,03	0,84	67,36	64	37,33	29,08	0,79	55,61
14	22,94	16,20	0,89	68,73	65	47,56	37,59	0,44	83,68
15	25,39	18,55	0,91	70,78	66	45,78	36,70	0,30	94,59
16	23,63	17,23	0,86	66,67	67	47,11	37,11	0,45	82,54
17	24,12	17,70	1,01	78,67	68	45,33	35,87	0,51	77,89
18	24,90	18,37	1,08	83,56	69	38,67	29,85	0,97	40,13
19	25,10	18,61	0,95	73,78	70	37,78	28,67	0,57	72,49
20	24,51	17,93	0,94	72,86	71	40,44	31,56	0,55	75,55
21	25,20	18,67	0,93	78,67	72	32,44	24,53	0,50	71,81
22	24,80	18,33	1,05	81,33	73	32,00	24,72	0,61	61,17
23	24,61	18,18	0,89	69,35	74	33,78	26,00	0,41	79,61
24	24,90	18,50	1,03	80,00	75	36,00	27,31	0,41	79,99
25	24,80	18,38	1,01	78,67	76	32,89	24,74	0,62	59,33
26	24,90	18,54	0,93	72,44	77	28,89	21,85	0,60	61,54
27	25,29	18,73	1,05	81,78	78	32,00	23,90	0,66	55,62
28	25,00	18,60	1,06	82,38	79	33,78	26,62	0,43	78,07
29	24,51	17,99	0,99	77,33	80	31,56	23,39	0,09	109,7
30	24,61	18,28	1,07	83,56	81	37,78	29,10	0,00	118,48
31	24,51	18,32	1,01	75,11	82	34,22	26,66	0,54	67,12
32	25,69	19,06	0,99	77,33	83	32,44	24,51	0,57	64,06
33	24,41	18,01	1,02	80,95	84	36,44	28,78	0,63	57,86
34	24,61	18,13	1,03	80,89	85	40,89	30,44	0,19	100,2
35	24,90	18,34	1,03	80,44	86	44,44	33,70	0,38	82,03
36	24,12	17,78	0,96	74,85	87	41,33	31,22	0,40	80,59
37	26,37	19,66	1,20	94,22	88	39,11	30,70	0,48	72,32
38	24,41	18,03	1,00	78,57	89	32,00	25,08	0,83	39,36
39	24,22	17,81	1,00	78,67	90	30,22	22,55	0,39	81,11
40	24,51	18,00	0,96	74,67	91	36,00	27,18	0,49	70,67
41	24,71	18,22	1,13	88,13					
42	25,20	18,77	1,11	85,90					
43	24,71	18,07	0,97	71,92					
44	24,12	17,73	0,92	71,73					
45	25,29	18,72	1,16	90,72					
46	25,39	18,78	1,05	81,35					
47	24,41	17,88	0,94	72,63					
48	24,22	17,59	1,01	79,14					
49	24,61	18,03	0,95	74,01					
50	24,61	18,28	0,98	76,17					
51	24,80	18,37	0,98	76,05					

Os dados do Quadro 2 foram normalizados à variância 0 (zero) e desvio padrão 1 (um). Este procedimento foi necessário devido às variáveis possuírem valores absolutos em diferentes escala de valores.

A utilização do aplicativo permitiu organizar os dados de maneira lógica e simples, e alcançou o objetivo de facilitar a consulta por meio dos procedimentos de seleção, edição e filtragem dos dados, atendendo, desta forma, às necessidades para as análises requeridas nas redes neurais.

4.2. Rede neural

4.2.1 Análise comparativa entre métodos de seleção de componentes de RNs

A partir da definição da arquitetura da rede neural, os elementos constituintes de sua topologia descreveram o relacionamento entre o conjunto de dados de entrada e o de saída.

O processo de ajuste da rede neural constituiu-se do treinamento de quatro grupos de *ensembles* de 10, 20, 50 e 100 conjuntos de redes neurais, respectivamente. Cada grupo foi submetido a um processo de 10 simulações. Os dados utilizados na implementação da RN de dimensão 3 (1 camada de entrada, 1 camada escondida e 1 camada de saída) foram 91 padrões de entrada/saída subdivididos em frações de 60% para treinamento, 20% para validação e 20% para teste.

O Quadro 3 mostra as proporções de padrões de entrada/saída utilizados em cada etapa. Dos 91 padrões de entrada/saída disponíveis para a implementação dos *ensembles*, 55 padrões foram utilizados na etapa de treinamento, 18 padrões na etapa de validação e outros 18 padrões na etapa de teste, não utilizados no treinamento. Estes padrões foram escolhidos aleatoriamente, sendo que para cada *ensemble* foi determinado um conjunto diferente de dados de treinamento para cada RNs, mas o mesmo conjunto de validação e de teste para todas. Estes resultados foram analisados considerando o EQM obtido para 4 métodos distintos de seleção de componentes: Melhor Componente, Seleção pela Média, Método Construtivo e Método de Poda.

QUADRO 3 – Quantidade de padrões de entrada/saída de dados utilizados nas etapas de treinamento, validação e teste das RNs.

Etapa	Padrões Entrada/Saída	
	Quantidade	Valores percentuais aproximados
Treinamento	55	60%
Validação	18	20%
Teste	18	20%
Total	91	100%

Os resultados foram analisados por grupos como mostra a seqüência a seguir:

a) 1º Grupo: *ensembles* com 10 redes neurais

O Quadro 4 apresenta os resultados de 10 simulações do treinamento e da validação de um *ensemble* composto por 10 redes neurais. Os valores apresentados no quadro são o Erro Quadrático (EQ) e o Erro Quadrático Médio (EQM) de cada simulação considerando 4 métodos distintos de seleção de componentes: Melhor Componente, Seleção pela Média, Método Construtivo e Método de Poda. O resultado analisado é a média aritmética dos EQM para cada método, de um *ensemble* de dados de 10 RNs.

O método do Melhor Componente permite selecionar a RN de melhor desempenho, dentro de um grupo, baseado no EQM. No presente estudo, partiu-se dos resultados obtidos por este método e comparou-se os resultados aos outros 3 métodos de seleção de desempenho.

QUADRO 4 – Erro Quadrático (EQ) e Erro Quadrático Médio (EQM) encontrado para 10 simulações de *ensembles* com 10 redes neurais, para os métodos do Melhor Componente, Seleção pela Média, Construtivo e de Poda, na etapa de validação.

VALIDAÇÃO								
Simulação	Melhor Componente		Seleção pela Média		Método Construtivo		Método Poda	
	EQ	EQM	EQ	EQM	EQ	EQM	EQ	EQM
1	0,0145	0,0401	0,0392	0,0660	0,0149	0,0407	0,0145	0,0401
2	0,0088	0,0313	0,0308	0,0585	0,0104	0,0341	0,0088	0,0313
3	0,0359	0,0631	0,1093	0,1102	0,0389	0,0657	0,0359	0,0631
4	0,0073	0,0285	0,0125	0,0373	0,0063	0,0264	0,0081	0,0300
5	0,0393	0,0661	0,0706	0,0886	0,0274	0,0551	0,0274	0,0551
6	0,0477	0,0728	0,0221	0,0496	0,0179	0,0446	0,0150	0,0409
7	0,0390	0,0658	0,0403	0,0669	0,0278	0,0556	0,0278	0,0556
8	0,0159	0,0421	0,0431	0,0692	0,0175	0,0441	0,0193	0,0463
9	0,0260	0,0538	0,0657	0,0854	0,0166	0,0430	0,0166	0,0430
10	0,0082	0,0302	0,0148	0,0405	0,0071	0,0282	0,0085	0,0307
Média	0,0243	0,0494	0,0448	0,0672	0,0185	0,0437	0,0182	0,0436

Analisando o Quadro 4, observa-se que, para o conjunto de dados de validação, o EQM apresenta valores médios de 0,0494 para o Método do Melhor Componente; 0,0672 para o Método da Seleção pela Média; 0,0437 para o Método Construtivo e 0,0436 para o Método de Poda. Observando-se a média dos EQMs, verifica-se que o melhor resultado foi obtido pelo Método da Poda, uma vez que houve uma redução dos valores do erro em relação aos outros métodos.

A Figura 16 permite analisar os resultados de acordo com os percentuais de redução do EQM de cada método em relação ao Método do Melhor Componente (referência para o cálculo dos valores percentuais). Os percentuais dos métodos Construtivo, de Seleção pela Média e de Poda são obtidos dividindo-se a média de EQM, encontrada em cada um, pela média de EQM do Melhor Componente e subtraindo-se de 1, obtendo-se deste modo a proporção de desempenho em relação ao método de referência.

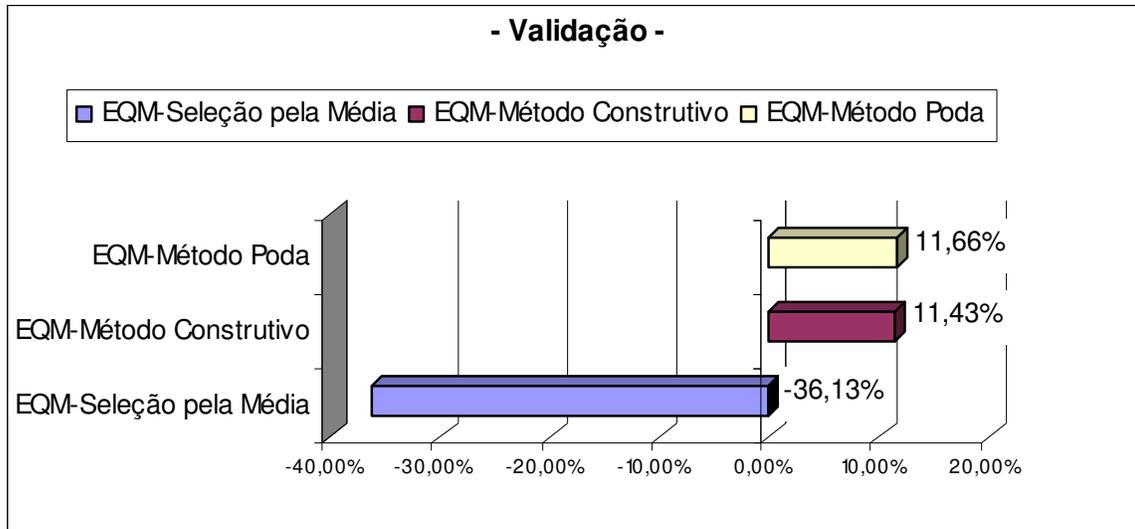


FIGURA 16 – Desempenho percentual do EQM dos métodos da Seleção pela Média, Construtivo e de Poda, comparados ao Método do Melhor Componente, na etapa de validação dos *ensembles* com 10 RNs.

Embora não tenha sido utilizado um parâmetro estatístico para comparar os valores percentuais apresentados, pode-se observar na Figura 16 que os métodos Construtivos e de Poda reduziram o erro em 11,43% e 11,66% respectivamente, resultando numa melhora de desempenho em relação ao Método do Melhor Componente. Já o Método da Média apresentou um desempenho negativo de 36,13% em relação ao Melhor Componente, indicando que o erro foi superior aos resultados do método de referência, demonstrando um desempenho inferior.

QUADRO 5 – Erro Quadrático (EQ) e Erro Quadrático Médio (EQM) encontrado para 10 simulações de *ensembles* com 10 redes neurais, para os métodos do Melhor Componente, Seleção pela Média, Construtivo e de Poda, na etapa de teste.

TESTE								
Simulação	Melhor Componente		Seleção pela Média		Método Construtivo		Método Poda	
	EQ	EQM	EQ	EQM	EQ	EQM	EQ	EQM
1	0,0466957	0,07203062	0,139385	0,1244477	0,036666	0,0638279	0,046696	0,072031
2	0,1053851	0,10821026	0,030474	0,0581889	0,055285	0,078376	0,105385	0,10821
3	0,0250587	0,05276645	0,027799	0,0555772	0,023279	0,0508577	0,025059	0,052766
4	0,0514171	0,07558446	0,100871	0,1058672	0,06253	0,0833533	0,100161	0,105494
5	0,1597366	0,13322353	0,110983	0,111047	0,207953	0,1520064	0,207953	0,152006
6	0,023693	0,05130845	0,022323	0,0498033	0,01534	0,0412855	0,018174	0,044936
7	0,0611702	0,08244203	0,073243	0,0902117	0,081296	0,0950415	0,081296	0,095041
8	0,0362211	0,06343951	0,022212	0,0496793	0,040376	0,0669795	0,022223	0,049691
9	0,061383	0,08258528	0,120426	0,1156747	0,094799	0,1026315	0,094799	0,102631
10	0,0332737	0,06080363	0,034349	0,061778	0,039032	0,0658547	0,034499	0,061913
Média	0,0604	0,0782	0,0682	0,0822	0,0657	0,0800	0,0736	0,0845

Analisando o Quadro 5, observa-se que, para o conjunto de dados de teste, o EQM apresenta valores médios de 0,0782 para o Método do Melhor Componente; 0,0822 para o Método da Seleção pela Média; 0,08 para o Método Construtivo e 0,0845 para o Método de Poda. Observando-se a média dos EQMs, verifica-se que o melhor resultado foi obtido pelo Método da Melhor Componente, uma vez que houve uma redução dos valores do erro em relação aos outros métodos.

A Figura 17 permite analisar os resultados de acordo com os percentuais de redução do EQM de cada método em relação ao Método do Melhor Componente (referência para o cálculo dos valores percentuais). Os percentuais dos métodos Construtivo, de Seleção pela Média e de Poda são obtidos conforme já descrito anteriormente na etapa de validação.

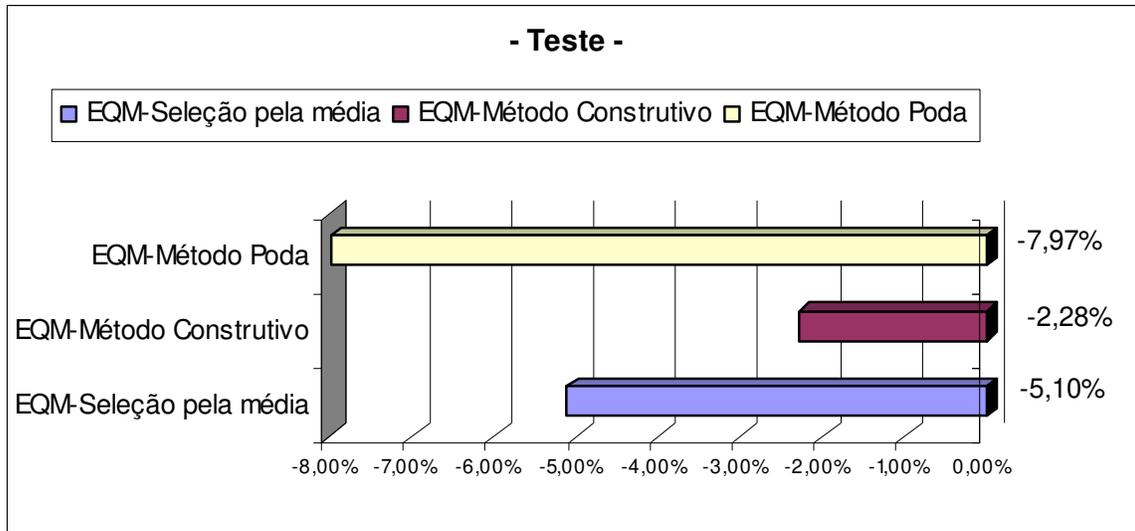


FIGURA 17 – Desempenho percentual do EQM dos métodos da Seleção pela Média, Construtivo e de Poda, comparados ao Método do Melhor Componente, na etapa de teste dos *ensembles* com 10 RNs.

Analisando os percentuais na Figura 17, os Métodos da Seleção pela Média, Construtivo e da Poda aumentaram o erro em 5,10%, 2,28% e 7,97% respectivamente, demonstrando um desempenho negativo em relação ao Método do Melhor Componente. Na etapa de teste da RN, os três métodos comparativos resultaram em um aumento do erro o que indica um desempenho negativo quanto à representatividade das amostras de teste para os métodos utilizados.

b) 2º Grupo: *ensembles* com 20 redes neurais

O Quadro 6 apresenta os resultados da validação para 10 simulações de *ensembles* compostos por 20 redes neurais. Os valores apresentados no quadro são o Erro Quadrático (EQ) e o Erro Quadrático Médio (EQM) de 4 métodos distintos de seleção de componentes: Melhor Componente, Seleção pela Média, Método Construtivo e Método de Poda. O resultado analisado é a média aritmética dos EQM de *ensembles* com 20 RNs, para cada método.

QUADRO 6 – Erro Quadrático (EQ) e Erro Quadrático Médio (EQM) encontrado para 10 simulações de *ensembles* com 20 redes neurais, para os métodos do Melhor Componente, Seleção pela Média, Construtivo e de Poda, na etapa de validação.

VALIDAÇÃO								
Simulação	Melhor Componente		Seleção pela Média		Método Construtivo		Método Poda	
	EQ	EQM	EQ	EQM	EQ	EQM	EQ	EQM
1	0,0145	0,0401	0,0269	0,0547	0,0135	0,0388	0,0121	0,0367
2	0,0050	0,0237	0,0035	0,0197	0,0016	0,0134	0,0015	0,0131
3	0,0209	0,0482	0,1360	0,1229	0,0264	0,0541	0,0251	0,0528
4	0,0306	0,0583	0,0838	0,0965	0,0267	0,0545	0,0268	0,0546
5	0,0233	0,0508	0,0299	0,0577	0,0205	0,0477	0,0211	0,0484
6	0,0578	0,0801	0,2212	0,1568	0,0718	0,0893	0,1040	0,1075
7	0,0378	0,0648	0,0459	0,0714	0,0349	0,0623	0,0367	0,0638
8	0,0321	0,0597	0,0526	0,0764	0,0242	0,0518	0,0232	0,0508
9	0,0433	0,0694	0,0488	0,0736	0,0251	0,0528	0,0297	0,0574
10	0,0170	0,0434	0,0292	0,0570	0,0103	0,0339	0,0089	0,0315
Média	0,0282	0,0539	0,0678	0,0787	0,0255	0,0499	0,0289	0,0517

Analisando o Quadro 6, observa-se que, para o conjunto de dados de validação, o EQM apresenta valores médios de 0,0539 para o Método do Melhor Componente; 0,0787 para o Método da Seleção pela Média; 0,0499 para o Método Construtivo e 0,0517 para o Método de Poda. Observando-se a média dos EQMs, verifica-se que o melhor resultado foi obtido pelo Método Construtivo, uma vez que houve uma redução dos valores do erro em relação aos outros métodos.

A Figura 18 permite analisar os resultados de acordo com os percentuais de redução do EQM de cada método em relação ao Método do Melhor Componente (referência para o cálculo dos valores percentuais). Os percentuais dos métodos Construtivo, de Seleção pela Média e de Poda são obtidos da mesma forma descrita na Figura 16.

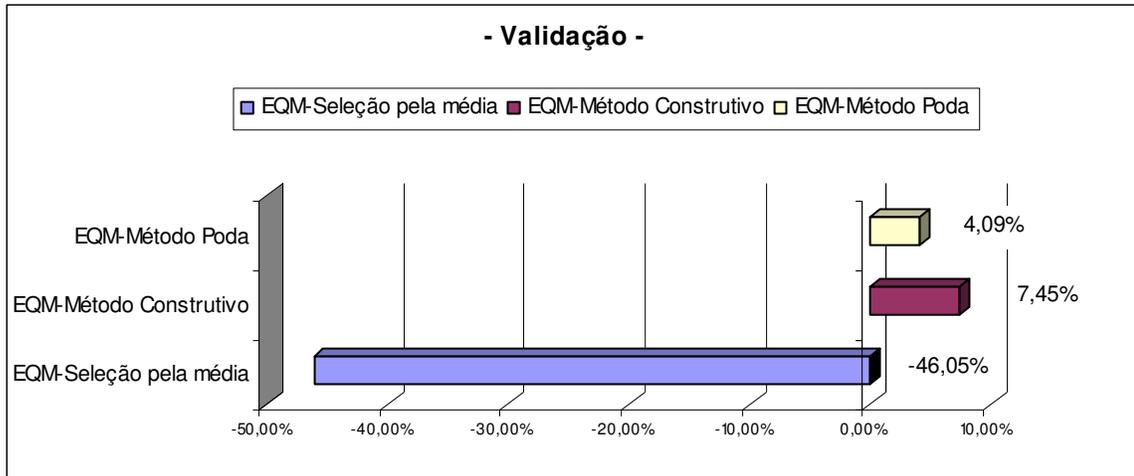


FIGURA 18 – Desempenho percentual do EQM dos métodos da Seleção pela Média, Construtivo e de Poda, comparados ao Método do Melhor Componente, na etapa de validação dos *ensembles* com 20 RNs.

Analisando os percentuais na Figura 18, o Método Construtivo e da Poda reduziram o erro em 7,45% e 4,09% respectivamente, demonstrando uma melhora de desempenho em relação ao Método do Melhor Componente. Já o Método da Média apresenta um desempenho negativo de 46,05% em relação ao Melhor Componente, indicando que o erro foi superior aos resultados do método de referência.

QUADRO 7 – Erro Quadrático (EQ) e Erro Quadrático Médio (EQM) encontrado para 10 simulações de *ensembles* com 20 redes neurais, para os métodos do Melhor Componente, Seleção pela Média, Construtivo e de Poda, na etapa de teste.

TESTE								
Simulação	Melhor Componente		Seleção pela Média		Método Construtivo		Método Poda	
	EQ	EQM	EQ	EQM	EQ	EQM	EQ	EQM
1	0,0467	0,0720	0,1069	0,1090	0,0434	0,0694	0,0513	0,0755
2	0,0480	0,0730	0,0882	0,0990	0,0915	0,1008	0,0953	0,1029
3	0,9085	0,3177	0,0860	0,0977	0,4282	0,2181	0,9731	0,3288
4	0,1657	0,1357	0,0522	0,0762	0,0562	0,0790	0,0997	0,1052
5	0,2212	0,1568	0,0360	0,0633	0,0384	0,0653	0,0383	0,0653
6	0,2102	0,1528	0,1175	0,1143	0,1320	0,1211	0,1126	0,1118
7	0,1005	0,1057	0,0934	0,1019	0,1070	0,1090	0,0942	0,1023
8	0,0645	0,0847	0,0486	0,0734	0,1195	0,1152	0,0474	0,0726
9	0,1246	0,1177	0,0205	0,0477	0,0413	0,0677	0,0288	0,0566
10	0,0994	0,1051	0,0355	0,0628	0,0783	0,0933	0,0381	0,0651
Média	0,1989	0,1321	0,0685	0,0845	0,1136	0,1039	0,1579	0,1086

Analisando o Quadro 7, observa-se que, para o conjunto de dados de teste, o EQM apresenta valores médios de 0,1321 para o Método do Melhor Componente; 0,0845 para o Método da Seleção pela Média; 0,1039 para o Método Construtivo e 0,1086 para o Método de Poda. Observando-se a média dos EQMs, verifica-se que o melhor resultado foi obtido pelo Método da Seleção pela Média, uma vez que houve uma redução dos valores do erro em relação aos outros métodos.

A Figura 19 permite analisar os resultados de acordo com os percentuais de redução do EQM de cada método em relação ao Método do Melhor Componente (referência para o cálculo dos valores percentuais). Estes percentuais dos métodos Construtivo, de Seleção pela Média e de Poda são obtidos como descrito na etapa de validação.

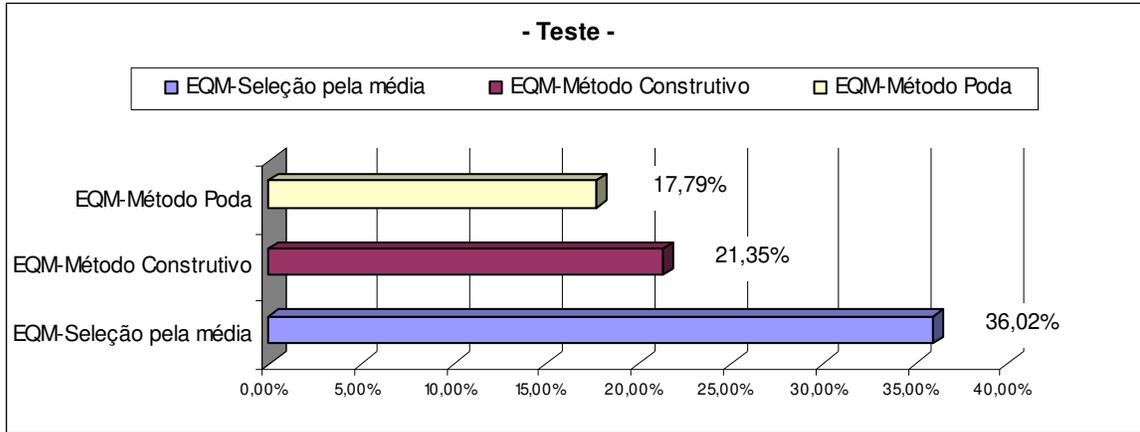


FIGURA 19 – Desempenho percentual do EQM dos métodos da Seleção pela Média, Construtivo e de Poda, comparados ao Método do Melhor Componente, na etapa de teste dos *ensembles* com 20 RNs.

Analisando os percentuais da Figura 19, o Método da Seleção pela Média, Construtivo e da Poda reduziram o erro em 36,02%, 21,35% e 17,79%, respectivamente, demonstrando uma melhora de desempenho em relação ao Método do Melhor Componente. Na etapa de teste dos *ensembles*, os três métodos comparativos resultaram em uma diminuição do erro, o que indica um desempenho positivo quanto à representatividade das amostras de teste para os métodos utilizados.

c) 3º Grupo: *ensembles* com 50 redes neurais

O Quadro 8 apresenta os resultados da validação de *ensembles* compostos por 50 redes neurais. Os valores apresentados no quadro são o Erro Quadrático (EQ) e o Erro Quadrático Médio (EQM) de cada uma das 10 simulações, considerando 4 métodos distintos de seleção de componentes: Melhor Componente, Seleção pela Média, Método Construtivo e Método de Poda. O resultado analisado é a média aritmética dos EQMs de *ensembles* com 50 RNs, para cada método.

QUADRO 8 – Erro Quadrático (EQ) e Erro Quadrático Médio (EQM) encontrado para 10 simulações de *ensembles* com 50 redes neurais, para os métodos do Melhor Componente, Seleção pela Média, Construtivo e de Poda, na etapa de validação.

VALIDAÇÃO								
Simulação	Melhor Componente		Seleção pela Média		Método Construtivo		Método Poda	
	EQ	EQM	EQ	EQM	EQ	EQM	EQ	EQM
1	0,0428	0,0690	0,1158	0,1134	0,0398	0,0665	0,0604	0,0820
2	0,0172	0,0438	0,0303	0,0580	0,0104	0,0341	0,0145	0,0402
3	0,0066	0,0270	0,0077	0,0293	0,0030	0,0184	0,0030	0,0183
4	0,0323	0,0599	0,0758	0,0918	0,0238	0,0514	0,0254	0,0531
5	0,0224	0,0499	0,0597	0,0814	0,0145	0,0401	0,0236	0,0512
6	0,0116	0,0360	0,0169	0,0433	0,0119	0,0363	0,0134	0,0386
7	0,0508	0,0752	0,0654	0,0852	0,0264	0,0542	0,0264	0,0542
8	0,0178	0,0445	0,0234	0,0510	0,0143	0,0399	0,0155	0,0415
9	0,0069	0,0278	0,0118	0,0362	0,0028	0,0176	0,0027	0,0174
10	0,0139	0,0393	0,0177	0,0443	0,0110	0,0350	0,0123	0,0370
Média	0,0223	0,0472	0,0424	0,0634	0,0158	0,0393	0,0197	0,0433

Analisando o Quadro 8, observa-se que, para o conjunto de dados de validação, o EQM apresenta valores médios de 0,0472 para o Método do Melhor Componente; 0,0634 para o Método da Seleção pela Média; 0,0393 para o Método Construtivo e 0,0433 para o Método de Poda. Observando-se a média dos EQMs, verifica-se que o melhor resultado foi obtido pelo Método Construtivo, uma vez que houve uma redução dos valores do erro em relação aos outros métodos.

A Figura 20 permite analisar os resultados de acordo com os percentuais de redução do EQM de cada método em relação ao Método do Melhor Componente (referência para o cálculo dos valores percentuais). Os percentuais dos métodos Construtivo, de Seleção pela Média e de Poda são obtidos da mesma forma como foi descrito na análise da Figura 16.

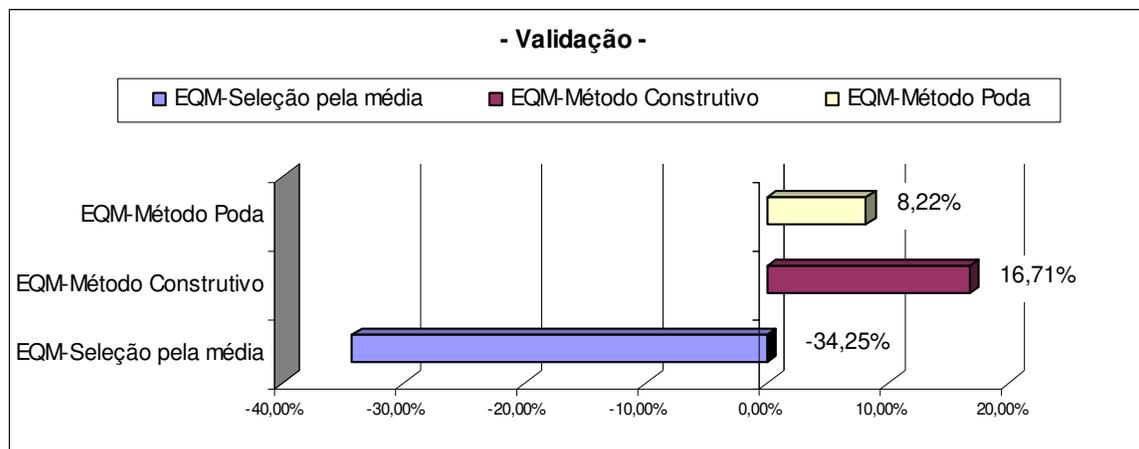


FIGURA 20 – Desempenho percentual do EQM dos métodos da Seleção pela Média, Construtivo e de Poda, comparados ao Método do Melhor Componente, na etapa de validação dos *ensembles* com 50 RNs.

Analisando os percentuais na Figura 20, o Método Construtivo e de Poda reduziram o erro em 16,71% e 8,22%, respectivamente, demonstrando uma melhora de desempenho em relação ao Método do Melhor Componente. Já o Método da Média apresentou um desempenho negativo de 34,25% em relação ao Melhor Componente, indicando que o erro foi superior aos resultados encontrados no método de referência.

QUADRO 9 – Erro Quadrático (EQ) e Erro Quadrático Médio (EQM) encontrado para 10 simulações de *ensembles* com 50 redes neurais, para os métodos do Melhor Componente, Seleção pela Média, Construtivo e de Poda, na etapa de teste.

TESTE								
Simulação	Melhor Componente		Seleção pela Média		Método Construtivo		Método Poda	
	EQ	EQM	EQ	EQM	EQ	EQM	EQ	EQM
1	0,0926	0,1014	0,0557	0,0787	0,0573	0,0798	0,1096	0,1104
2	0,0449	0,0706	0,0577	0,0801	0,0386	0,0655	0,0612	0,0824
3	0,0312	0,0589	0,0305	0,0582	0,0471	0,0724	0,0613	0,0825
4	0,4284	0,2182	0,0718	0,0893	0,1802	0,1415	0,1442	0,1266
5	0,0588	0,0809	0,0797	0,0941	0,0349	0,0623	0,0826	0,0958
6	0,1649	0,1354	0,1291	0,1198	0,0994	0,1051	0,1463	0,1275
7	0,0860	0,0978	0,0621	0,0831	0,0465	0,0719	0,0324	0,0600
8	0,0861	0,0978	0,0452	0,0708	0,0641	0,0844	0,0668	0,0862
9	0,0736	0,0904	0,0542	0,0776	0,0472	0,0725	0,0365	0,0636
10	0,2231	0,1574	0,0689	0,0875	0,1080	0,1095	0,0880	0,0989
Média	0,1290	0,1109	0,0655	0,0839	0,0723	0,0865	0,0829	0,0934

Analisando o Quadro 9, observa-se que, para o conjunto de dados de teste, o EQM apresenta valores médios de 0,1109 para o Método do Melhor Componente; 0,0839 para o Método da Seleção pela Média; 0,0865 para o Método Construtivo e 0,0934 para o Método de Poda. Observando-se a média dos EQMs, verifica-se que os melhores resultados foram obtidos para o Método da Seleção pela Média, uma vez que este apresentou uma redução dos valores do erro em relação aos outros métodos.

A Figura 21 permite analisar os resultados de acordo com os percentuais de redução do EQM de cada método em relação ao Método do Melhor Componente, referência para o cálculo percentual. A obtenção dos percentuais dos métodos Construtivo, de Seleção pela Média e de Poda segue o descrito na validação.

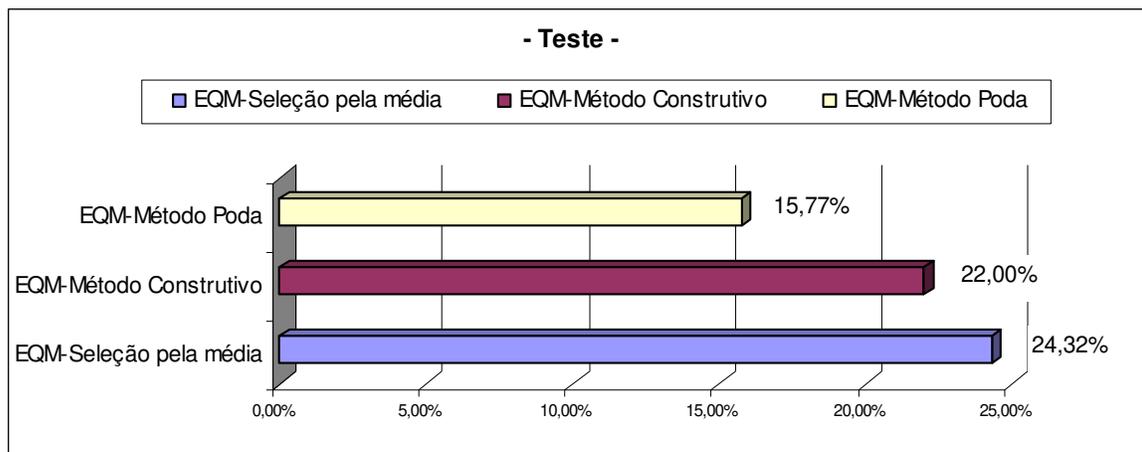


FIGURA 21 – Desempenho percentual do EQM dos métodos da Seleção pela Média, Construtivo e de Poda, comparados ao Método do Melhor Componente, na etapa de teste dos *ensembles* com 50 RNs.

Analisando os percentuais na Figura 21, o Método da Seleção pela Média, Construtivo e de Poda reduziram o erro em 24,32%, 22% e 15,77%, respectivamente, demonstrando uma melhora de desempenho em relação ao Método do Melhor Componente. Na etapa de teste dos *ensembles*, os três métodos comparativos resultaram em uma diminuição do erro o que indica um desempenho positivo quanto à representatividade das amostras de teste para os métodos utilizados.

d) 4º Grupo: *ensembles* com 100 redes neurais

O Quadro 10 apresenta os resultados da validação de *ensembles* compostos por 100 redes neurais. Os valores apresentados no quadro são o Erro Quadrático (EQ) e o Erro Quadrático Médio (EQM) de cada simulação, considerando 4 métodos distintos de seleção de componentes: Melhor Componente, Seleção pela Média, Método Construtivo e Método de Poda. O resultado analisado é a média aritmética dos EQMs de 10 simulações de *ensembles* com 100 RNs, para cada método.

QUADRO 10 – Erro Quadrático (EQ) e Erro Quadrático Médio (EQM) encontrado para 10 simulações de *ensembles* com 100 redes neurais, para os métodos do Melhor Componente, Seleção pela Média, Construtivo e de Poda, na etapa de validação.

VALIDAÇÃO								
Simulação	Melhor Componente		Seleção pela Média		Método Construtivo		Método Poda	
	EQ	EQM	EQ	EQM	EQ	EQM	EQ	EQM
1	0,0347	0,0621	0,0697	0,0880	0,0213	0,0487	0,0240	0,0516
2	0,0066	0,0272	0,0092	0,0320	0,0043	0,0217	0,0044	0,0221
3	0,0222	0,0496	0,0339	0,0614	0,0169	0,0434	0,0182	0,0450
4	0,0157	0,0418	0,0378	0,0648	0,0145	0,0402	0,0194	0,0464
5	0,0139	0,0392	0,0329	0,0605	0,0084	0,0305	0,0126	0,0375
6	0,0360	0,0633	0,0531	0,0768	0,0218	0,0492	0,0295	0,0572
7	0,0213	0,0487	0,0413	0,0678	0,0178	0,0445	0,0199	0,0470
8	0,0364	0,0636	0,0795	0,0940	0,0320	0,0596	0,0436	0,0696
9	0,0058	0,0254	0,0299	0,0577	0,0028	0,0177	0,0052	0,0240
10	0,0212	0,0486	0,0270	0,0547	0,0123	0,0370	0,0142	0,0397
Média	0,0214	0,0469	0,0414	0,0658	0,0152	0,0392	0,0191	0,0440

Analisando o Quadro 10, observa-se que, para o conjunto de dados de validação, o EQM apresenta valores médios de 0,0469 para o Método do Melhor Componente; 0,0658 para o Método da Seleção pela Média; 0,0392 para o Método Construtivo e 0,044 para o Método de Poda. Observando-se a média dos EQMs, verifica-se que o melhor resultado foi obtido pelo Método Construtivo, uma vez que houve uma redução dos valores do erro em relação aos outros métodos.

A Figura 22 permite analisar os resultados de acordo com os percentuais de redução do EQM de cada método em relação ao Método do Melhor Componente (referência para o

cálculo dos valores percentuais). Tal qual nos 3 grupos anteriores, no caso do Método Construtivo divide-se a sua média de EQM pela média do EQM do Melhor Componente e subtrai-se de 1, obtendo-se a proporção de desempenho em relação ao método de referência. Este procedimento também foi utilizado para o Método da Seleção pela Média e de Poda.

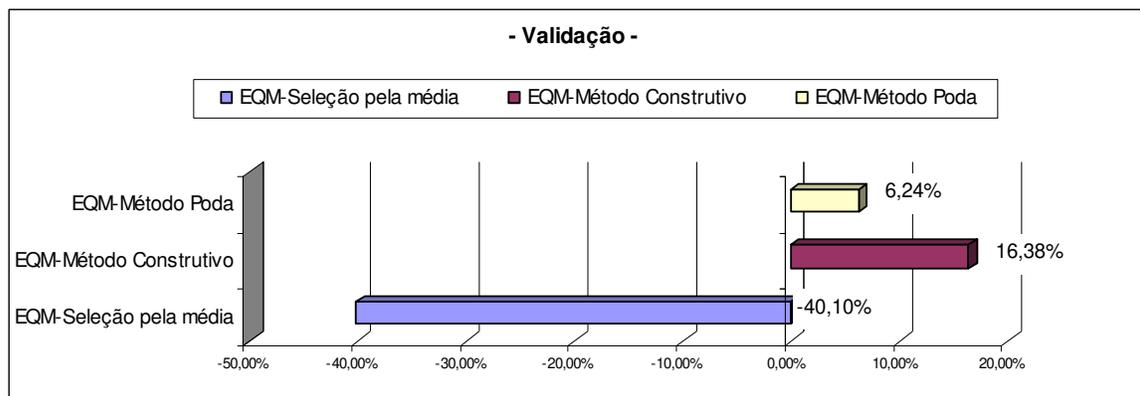


FIGURA 22 – Desempenho percentual do EQM dos métodos da Seleção pela Média, Construtivo e de Poda, comparados ao Método do Melhor Componente, na etapa de validação dos *ensembles* com 100 RNs.

Analisando os percentuais na Figura 22, o Método Construtivo e de Poda reduziram o erro em 16,38% e 6,24% respectivamente, demonstrando uma melhora de desempenho em relação ao Método do Melhor Componente. Já o Método da Média apresentou um desempenho negativo de 40,1% em relação ao Melhor Componente, indicando que o erro foi superior aos resultados obtidos pelo método de referência.

QUADRO 11 – Erro Quadrático (EQ) e Erro Quadrático Médio (EQM) encontrado para 10 simulações de *ensembles* com 100 redes neurais, para os métodos do Melhor Componente, Seleção pela Média, Construtivo e de Poda, na etapa de teste.

TESTE								
Simulação	Melhor Componente		Seleção pela Média		Método Construtivo		Método Poda	
	EQ	EQM	EQ	EQM	EQ	EQM	EQ	EQM
1	0,0303	0,0581	0,0376	0,0646	0,0160	0,0422	0,0191	0,0461
2	0,1393	0,1244	0,1513	0,1297	0,1801	0,1415	0,1176	0,1143
3	0,0380	0,0650	0,0375	0,0645	0,0325	0,0601	0,0315	0,0592
4	0,0284	0,0562	0,0322	0,0598	0,0237	0,0513	0,0264	0,0542
5	0,1165	0,1138	0,0468	0,0721	0,0569	0,0795	0,0459	0,0714
6	0,0214	0,0488	0,0429	0,0691	0,0777	0,0929	0,0560	0,0789
7	0,2055	0,1511	0,0265	0,0543	0,0403	0,0669	0,0540	0,0774
8	0,0607	0,0821	0,0348	0,0622	0,0455	0,0711	0,0329	0,0605
9	0,2918	0,1801	0,0493	0,0740	0,0421	0,0684	0,0614	0,0826
10	0,2064	0,1514	0,0591	0,0810	0,0724	0,0897	0,0411	0,0676
Média	0,1138	0,1031	0,0518	0,0731	0,0587	0,0764	0,0486	0,0712

Analisando o Quadro 11, observa-se que, para o conjunto de dados, o EQM apresenta valores médios de 0,1031 para o Método do Melhor Componente; 0,0731 para o Método da Seleção pela Média; 0,0764 para o Método Construtivo e 0,0712 para o Método de Poda. Observando-se a média dos EQM, verifica-se que o melhor resultado foi obtido pelo Método de Poda, uma vez que houve uma redução dos valores do erro em relação aos outros métodos.

A Figura 23 permite analisar os resultados de acordo com os percentuais de redução do EQM de cada método em relação ao Método do Melhor Componente (referência para o cálculo dos valores percentuais). Os percentuais dos métodos Construtivos, de Seleção pela Média e de Poda são obtidos conforme já descrito anteriormente na validação.

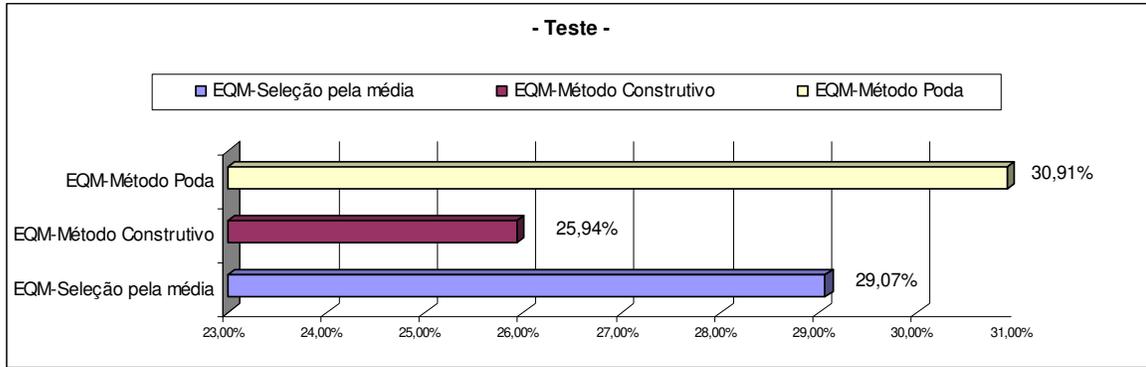


FIGURA 23 – Desempenho percentual do EQM dos métodos da Seleção pela Média, Construtivo e de Poda, comparados ao Método do Melhor Componente, na etapa de teste dos *ensembles* com 100 RNs.

Analisando os percentuais na Figura 23, os Métodos da Seleção pela Média, Construtivo e de Poda reduziram o erro em 29,07%, 25,94% e 30,91%, respectivamente, demonstrando uma melhora de desempenho em relação ao Método do Melhor Componente. Na etapa de teste dos *ensembles*, os três métodos comparativos resultaram em uma diminuição do erro, o que indica um desempenho positivo quanto à representatividade das amostras de teste para os métodos utilizados.

Como modo de calibração, a metodologia de *ensembles* proposta no presente estudo foi aplicada a outros dois conjuntos de dados de natureza, número de padrões e dimensão distintos. Estes conjuntos, conhecidos como Body Fat e Função de Friedman-1, são comumente utilizados como referência em aplicações de desempenho de RN. Este procedimento teve por intenção comparar o ajuste da RN considerando, principalmente, o número de padrões de treinamento (APÊNDICES 16 e 17). Os métodos de seleção de componentes implementados nestes dois conjuntos de dados reportaram resultados de comportamento semelhante aos apresentados neste estudo.

4.2.2. Comparação do desempenho entre as estimativas das RN e da usina

As Figuras 24 e 25 apresentam a comparação entre os valores de EQMs, em ton/ha, para as etapas de validação e de teste das RNs, respectivamente, considerando os métodos de seleção pelo Melhor Componente, Seleção pela Média, Construtivo e de Poda, para os quatro

grupos de *ensembles*. Para isto, efetuou-se um processo de inversão da normalização nos valores dos dados de saída dos *ensembles*, para expressá-los na unidade de ton/ha.

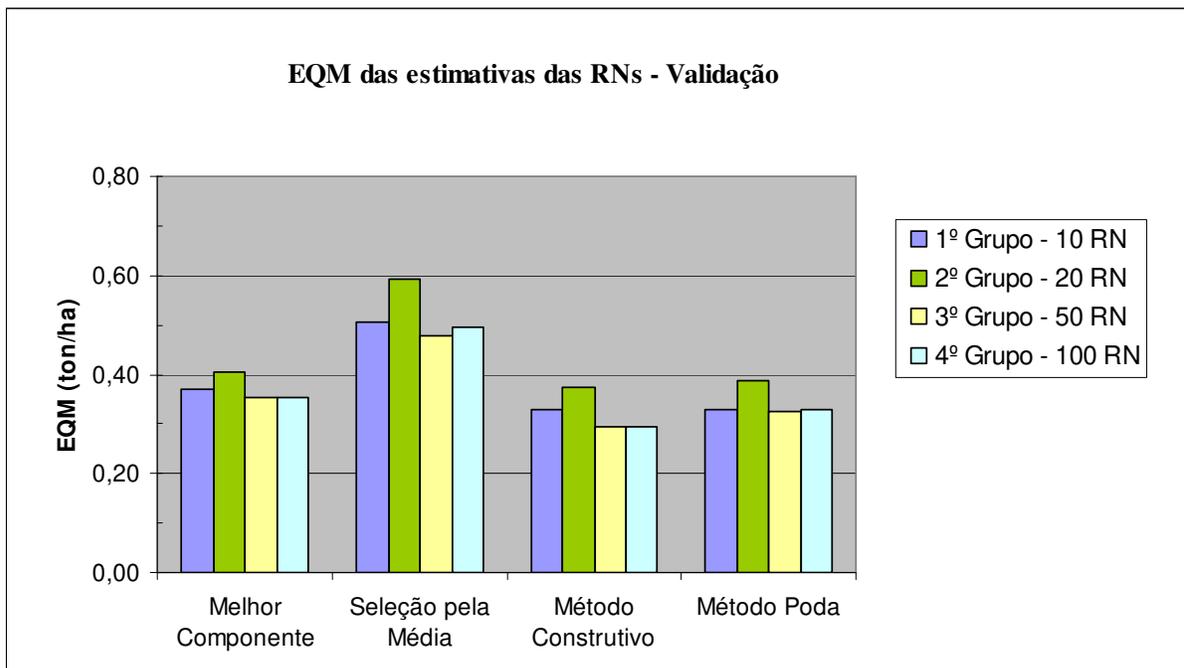


FIGURA 24 – EQM obtido na etapa de validação, para 4 métodos de seleção de RNs, considerando os 4 grupos de *ensembles*: 10, 20, 50 e 100 RNs.

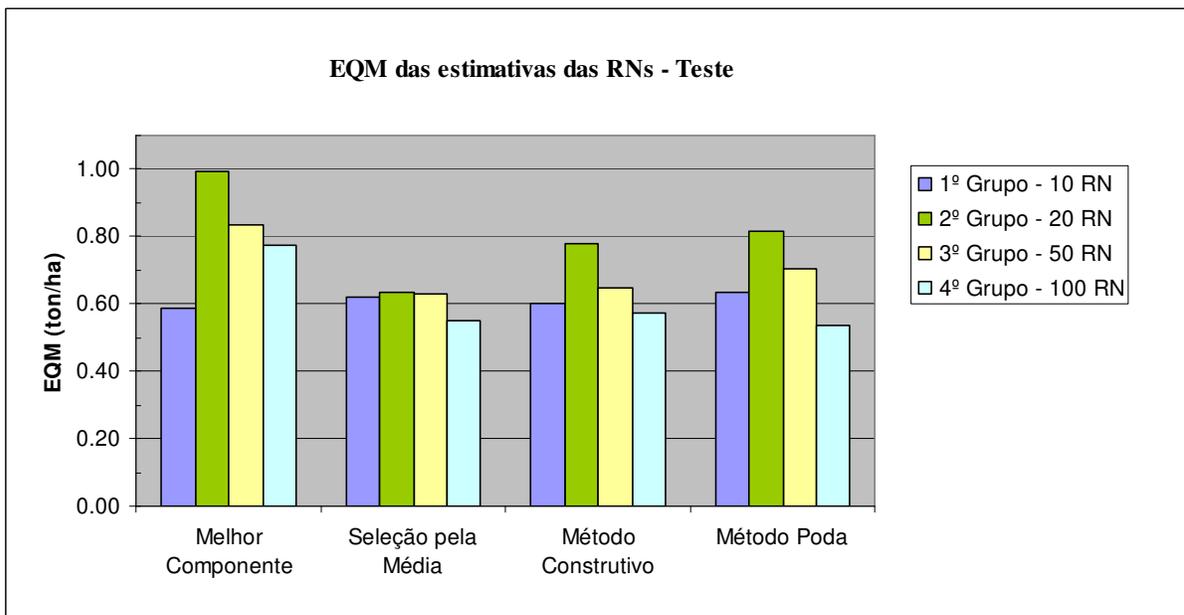


FIGURA 25 – EQM obtido na etapa de teste, para os 4 métodos de seleção de RNs, considerando os 4 grupos de *ensembles*: 10, 20, 50 e 100 RNs

Observando a Figura 24, pode-se comparar os EQMs dos métodos de seleção de componentes de *ensembles* na etapa de validação. O método da Melhor Componente apresentou EQM variando entre 0,35 a 0,40 ton/ha; o Método da Seleção pela Média entre 0,48 a 0,59 ton/ha; o Construtivo entre 0,29 a 0,37 ton/ha e o Método de Poda apresentou valores entre 0,33 e 0,39 ton/ha. A Figura 25 permitiu a comparação entre os EQMs dos métodos de seleção dos *ensembles* na etapa de teste. Os valores para o Método da Melhor Componente variaram entre 0,59 e 0,99 ton/ha; para o Método da Seleção pela Média entre 0,55 e 0,64 ton/ha; para o Método Construtivo entre 0,57 e 0,78 ton/ha e para o Método de Poda os valores variaram entre 0,54 e 0,82 ton/ha. Analisando os EQMs das Figuras 24 e 25, observa-se que, cada grupo de *ensemble* de 10, 20, 50 e 100 RNs demonstrou desempenho semelhante em relação aos 4 métodos de seleção de componentes, apresentando mínima variação nos valores de EQM, o que demonstrou estabilidade no desempenho dos dados, tanto na etapa de validação, quanto na etapa de teste. Entretanto, entre os *ensembles*, o grupo composto por 20 RNs foi o que apresentou a maior tendência de EQM, o que demonstrou que o acréscimo de RNs aos *ensembles* melhorou o desempenho dos mesmos, compensando o seu tempo de implementação.

A partir da integração dos dados espectrais e agrometeorológicos, realizada por meio das RNs, foi possível determinar o erro quadrático médio (EQM) entre a produtividade encontrada pelos *ensembles* de RNs e a produtividade real coletada no campo. O erro determinado pelas RNs foi então comparado com o erro obtido pelo método de estimativa da usina (FIGURA 26).

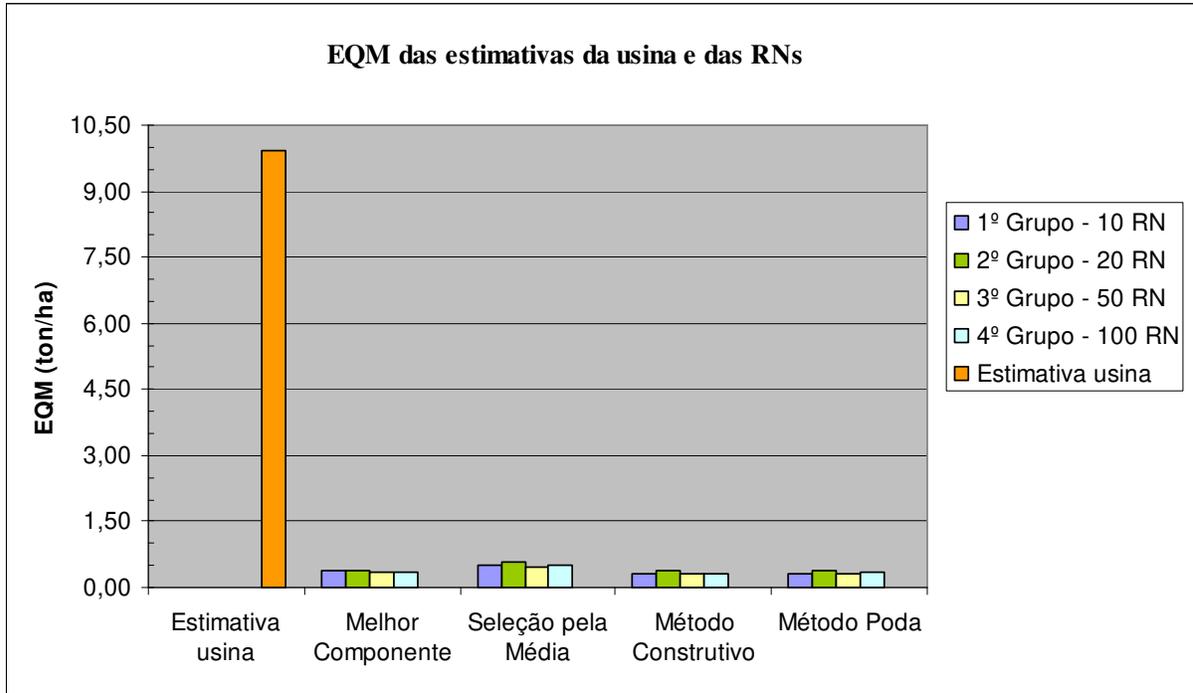


FIGURA 26 – EQM em ton/ha, obtido pela estimativa da usina e pelos quatro métodos de seleção de RN, considerando os quatro grupos de *ensembles*: 10, 20, 50 e 100 RNs.

Analisando a Figura 26, pode-se evidenciar que os métodos utilizados para seleção dos *ensembles* apresentaram um desempenho melhor quando comparados ao método utilizado pela usina. As RNs apresentaram um erro de estimativa de produtividade variando entre 0,03 e 0,51 ton/ha, enquanto que o erro de estimativa encontrado pela usina foi de 9,93 ton/ha em média, e o erro encontrado por Machado (2003), no estudo de estimativa por modelo espectral, foi de 4 ton/ha. Independente do método de seleção de componentes, as RNs demonstraram um desempenho muito além da estimativa da usina e do modelo espectral, provavelmente devido à sua capacidade de generalização. Estes resultados mostram o quanto o erro determinado pelas RNs foi menor do que o erro obtido pelo método de estimativa da usina, corroborando desta forma, a competitividade e a possibilidade de utilização das redes neurais como método de estimativa de produtividade.

5. CONCLUSÕES E RECOMENDAÇÕES

A aplicação de redes neurais na estimativa de produtividade de cana-de-açúcar, por meio de índice de vegetação, B4 e coeficiente de produtividade, confirmou a hipótese inicialmente firmada de que esta metodologia pode ser uma ferramenta eficiente para a estimativa de produtividade, considerando o perfil amostral do estudo.

O coeficiente de produtividade k_p , obtido a partir da inversão do modelo agrometeorológico de Doorenbos e Kassam, apresentou resultados satisfatórios para o estudo.

A utilização do aplicativo de banco de dados permitiu estruturar os dados de maneira lógica e simples, e facilitou a organização dos padrões de entrada/saída para o treinamento, validação e teste das redes neurais.

A correlação amostral e os diagramas de dispersão das variáveis da banda B4, do índice GVI, do coeficiente de produtividade k_p e da produtividade colhida, permitiram evidenciar as relações dos índices de vegetação e do k_p com a produtividade: quanto maior a reflectância da B4 e do índice GVI, maior a produtividade; assim como quanto menor o k_p , maior a produtividade.

A implementação da arquitetura neural proposta, baseada em *ensembles*, alcançou a convergência nos treinamentos, isto é, obteve baixos valores de EQM no mapeamento dos padrões de entrada/ saída. Isto garantiu um ajuste adequado das redes neurais quanto à topologia, às amostras de treinamento, ao número de iterações executadas e aos algoritmos de aprendizagem, permitindo a integração dos dados espectrais de imagens Landsat 7 ETM⁺, dados meteorológicos e de produtividade da cana-de-açúcar.

No processo de avaliação do desempenho da rede neural, o grupo de *ensembles* com 100 redes neurais (componentes) mostrou melhor desempenho, apresentando o menor valor de EQM, indicando haver uma tendência à redução do erro, à medida que aumenta o número de componentes.

Independente do método de seleção de componentes dos *ensembles*, as redes neurais demonstraram um desempenho melhor do que a estimativa obtida pela usina, servindo como uma técnica para se obter resultados objetivos satisfatórios, demonstrando uma vantagem em relação ao método utilizado pela usina até o presente momento.

Este estudo poderá ser aprimorado empregando-se outras variedades de cana-de-açúcar, o que garantirá a ampliação dos conjuntos de treinamento, validação e teste. Este procedimento permitirá que a rede neural aperfeiçoe o reconhecimento de padrões de entrada/saída, ampliando o seu campo de aplicação, já que os treinamentos foram realizados com dados oriundos de unidades amostrais, compostas pelas variedades de cana-de-açúcar SP80-1816 e SP80-1842.

Sugere-se, para o aperfeiçoamento desta metodologia, que se realizem estudos em relação às etapas de coleta de dados, considerando o ciclo de crescimento da cana-de-açúcar. Este procedimento auxiliará no mapeamento dos padrões de reconhecimento das redes neurais e fornecerá uma estimativa de produtividade mais apropriada.

Cabe ainda concluir sobre a importância da realização de estudos desta natureza para a resolução de problemas de estimativa de produtividade de cana-de-açúcar, sendo o setor sucroalcooleiro de fundamental importância para a economia do Estado de São Paulo.

REFERÊNCIAS BIBLIOGRÁFICAS

- AGUIAR, C. D. de. **Integração de sistemas de banco de dados heterogêneos em aplicações de planejamento urbano.** 169p. Dissertação (Mestrado em Ciência da Computação) – Instituto de Matemática, Estatística e Ciência da Computação, Universidade Estadual de Campinas, Campinas, 1995.
- Al ABBAS, A. et al. Spectra of normal and nutrient deficient maize leaves. **Agronomy Journal**, v.66, n.1, p.16-20, jan./fev. 1974.
- ALFONSI, R. R. et al. **Condições climáticas para a cana-de-açúcar.** In: PARANHOS, Sérgio Bicudo. Cana-de-açúcar: cultivo e utilização. Campinas: Fundação Cargill, v.1, n.135, p.42-81, set. 1987.
- BACA, J. F. M. Redes neurais artificiais (RNA) aplicadas na modelagem numérica do terreno. **Congresso Brasileiro de Cartografia.** Porto Alegre, out. 2001, CD-Rom.
- BARROS NETO, B. de.; SCARMINIO, I. S.; BRUNS, R. E. **Como fazer experimentos: pesquisa e desenvolvimento na ciência e na indústria.** 2ed. Campinas-SP: Editora da Unicamp, 2002. 401p.
- BENVENUTI, F. A. **Estudo de índices de vegetação conhecidos e sua aplicabilidade como parâmetro para estimar a produtividade da cultura da cana-de-açúcar.** Monografia – Curso de Especialização em Geoprocessamento, Universidade Estadual de Campinas, Campinas, 2002.
- BRAGA, H. J. **Previsão agrícola: uma nova abordagem – uso de scanner aerotransportável e redes neurais.** Tese (Doutorado em Engenharia de Produção) – Programa de Pós-Graduação em Engenharia de Produção, Centro Tecnológico, Universidade Federal de Santa Catarina, Florianópolis, 1995.

BREIMAN, L. Bagging Predictors. **Machine Learning**, New York, v. 24, n. 2, p. 123-140, ago. 1996.

CAMARGO, A P. de; CAMARGO, M. B. P. de. Uma revisão analítica da evapotranspiração potencial. **Bragantia**, Campinas, v.59, n.2, p.125-137, 2000.

CAMARGO, M. B. P. de. **Exigências bioclimáticas e estimativa da produtividade para quatro cultivares de soja no estado de São Paulo**. 96p. Dissertação (Mestrado em Agrometeorologia) – Faculdade de Agronomia, Escola Superior de Agricultura Luiz de Queiroz, Universidade de São Paulo, Piracicaba, 1984.

CARVALHO, A. P. L. F. **Redes Neurais Artificiais**. Disponível em: <http://www.icmsc.sc.usp.br/~andre/neural1.html#hist>>. Acesso em: 21 de agosto de 2002.

CASTRO, L. N. de. **Análise e síntese de estratégias de aprendizado para redes neurais artificiais**. 248p. Dissertação (Mestrado em Automação) – Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, Campinas, 1998.

CASTRO, L. N. de; VON ZUBEN, F. J.; MARTINS, W. Hybrid and Constructive Neural Networks Applied to a Prediction Problem in Agriculture. **Proceedings of the IEEE International Joint Conference on Neural Networks**, vol. 3, p. 1932-1936, maio 1998.

COPERSUCAR. **Boletim Técnico Copersucar: Quarta geração de variedades de cana-de-açúcar** [da] Copersucar. Piracicaba: CTC, 1993.

COPERSUCAR. **Boletim Técnico Copersucar: Sexta geração de variedades de cana-de-açúcar** [da] Copersucar. Piracicaba: CTC, 1997a.

COPERSUCAR. **Censo varietal quantitativo 1996**. Piracicaba: CTC, 1997b.

COPERSUCAR. **Recomendação de adubação para a cultura da cana-de-açúcar.** Piracicaba: CTC, 1988.

De CAROLIS, C.; AMOEDO, P. Basic problems in the reflectance and emittance properties of vegetations. In: FRAYSSE, G. **Remote sensing application in agriculture and hidrology.** Luxemburg: Balkema, 1980.

DOORENBOS, J.; KASSAM, A. H. **Yield response do water.** Roma: FAO, 1979.

DRUMMOND, S. T.; SUDDUTH, K. A.; JOSHI, A. Predictive Ability of neural Networks for Site-Specific Yield Estimation. **Second International Conference on Geospatial Information in Agriculture and Forestry**, vol. 1, pp. 136-143, janeiro 2000.

FURTADO, A. L.; SANTOS, C. S. **Organização de banco de dados.** 7ed. Rio de Janeiro: Campus, 1989.

GALO, M. L. B. T. **Aplicação de redes neurais artificiais e sensoriamento remoto na caracterização ambiental do Parque Estadual Morro do Diabo.** 205p. Tese (Doutorado em Ciências da Engenharia Ambiental) - Escola de Engenharia de São Carlos, da Universidade de São Paulo, São Carlos, 2000.

GONÇALVES, M. L. **Uma arquitetura neural modular para classificação de imagens multiespectrais de sensoriamento remoto.** 99p. Dissertação (Mestrado em Engenharia Elétrica) – Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, Campinas, 1997.

HAYKIN, S. **Neural Networks: a comprehensive foundation.** 2ed. Saddle River: Prentice Hall, 1999.

HOFFER, R. M.; JOHANSEN, C. J. Ecological potentials in spectral signature analysis. In: JOHANSEN, P. L. **Remote sensing in ecology**. Athens: University of Georgia Press, 1969. p. 1-16.

HOFFER, R. M. Biological and physical consideration in applying computer aided analysis techniques to remote sensor data. In: SWAIN, P. H.; DAVIS, S. M. **Remote sensing the quantitative approach**. New York: McGraw Hill, 1978.

JOAQUIM, A. C. **Identificação de variedades de cana-de-açúcar em três classes texturais de solos, na região de Araraquara - SP, através de análise de nível de cinza em imagens Landsat/TM**. 118p. Dissertação (Mestrado em Planejamento e Desenvolvimento Rural Sustentável) – Faculdade de Engenharia Agrícola, Universidade Estadual de Campinas, Campinas, 1998.

KNIPLING, E. B.; LAMBECK, P. F.; CRIST, E. P. Physical and physiological basis for the reflectance of visible and near infrared radiation from vegetation. **Remote Sensing of Environment**, v.1, n.3, p.155-159, 1970.

KORTH, H. F.; SILBERSCHATZ, A. **Sistema de banco de dados**. São Paulo: McGraw-Hill, 1989.

KOSKO, B. **Neural Networks and Fuzzy Systems: a dynamical Systems Approach to Machine Intelligence**. California: Prentice-Hall, 1992.

LEISCH, F.; HORNIK, K. Error-dependent Resampling for Artificial Neural Network Classifiers. In: KRÖPLIN, B. **Neuronal Netze in den Ingenieurwissenschaften**. Stuttgart: Universität Stuttgart Presse, 1997. p. 1-14.

LIMA, C. A. M. **Comitê de Máquinas: uma abordagem unificada empregando Máquinas de Vetores-Suporte**. 314p. Tese (Doutorado em Engenharia Elétrica) - Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas,

Campinas, 2004.

MACHADO, H. M. **Determinação da biomassa de cana-de-açúcar considerando a variação espacial de dados espectrais do satélite Landsat 7 - ETM⁺**. 59p. Dissertação (Mestrado em Planejamento e Desenvolvimento Rural Sustentável) - Faculdade de Engenharia Agrícola, Universidade Estadual de Campinas, Campinas, 2003.

MEDEIROS, C. B.; PIRES, F. Banco de dados e sistemas de informações geográficas. In: ASSAD, E. D.; SANO, E. E. (Org.). **Sistema de Informações Geográficas: aplicações na agricultura**. 2ed. Brasília: EMBRAPA – CPAC, 1998. p. 31-45.

MEDEIROS, J. S. **Bancos de dados geográficos e redes neurais artificiais: tecnologias de apoio à gestão do território**. 221p. Tese (Doutorado em Geografia Física) – Departamento de Geografia, Faculdade de Filosofia, Letras e Ciências Humanas, Universidade de São Paulo, São Paulo, 1999.

MOLLER, M. F. A Scaled Conjugate Gradient Algorithm for Fast Supervised Learning. **Neural Networks**. v.6, p.525-533, 1993.

MORAES, A. V. C. **Desenvolvimento e análise de modelos agrometeorológicos de estimativa de produtividade para a cultura da soja na região de Ribeirão Preto, SP**. 95p. Dissertação (Mestrado em Agrometeorologia) – Faculdade de Agronomia, Escola Superior de Agricultura Luiz de Queiroz, Universidade de São Paulo, Piracicaba, 1998.

PELLEGRINO, G. Q. **Utilização de dados espectrais do satélite NOAA14-AVHRR como fonte de dados para modelos matemáticos de estimativa da fitomassa da cana-de-açúcar**. 109p. Tese (Doutorado em Água e Solo) – Faculdade de Engenharia Agrícola, Universidade Estadual de Campinas, Campinas, 2000.

PERRONE, M.; COOPER, L. N. When networks disagree: ensemble method for neural networks. In: MAMMONE, R. J. (Org.). **Artificial Neural Networks for Speech and**

Vision. New York: Champman & Hall, 1993. p.126-142.

RAMOS, J. P. S. **Estudo de redes neurais artificiais na seleção de frutos.** 255p. Tese (Doutorado em Engenharia Agrícola) – Faculdade de Engenharia Agrícola, Universidade Estadual de Campinas, Campinas, 2001.

RIBEIRO, S. R. A.; CENTENO, J. S. Integração de dados de diferentes origens na classificação através da técnica de redes neurais. **Congresso Brasileiro de Cartografia.** Porto Alegre, out. 2001, CD-Rom.

RUDORFF, B. F. T.; BATISTA, G. T. **Relatório da fase I do Projeto ESTIMA:** desenvolvimento de um modelo para estimativa da produtividade agrícola da cana-de-açúcar baseado em dados Landsat e Agrometeorológicos. 93p. Relatório Técnico – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 1988.

SANO, E. E. et al. Estruturação de dados geoambientais no contexto de fazenda experimental. In: ASSAD, E. D.; SANO, E. E. (Org.). **Sistema de Informações Geográficas:** aplicações na agricultura. 2ed. Brasília: EMBRAPA – CPAC, 1998. p. 95-118.

SIMPSON, G. Crop yield prediction using a CMAC neural network. **SPIE**, v.2315, p.160-171, 1998.

THORNTHWAITE, C. W.; MATHER, J. R. **The water balance.** Centerton, N. J., 1955. (Publications in Climatology, v.8, n.1)

UNICA. Posição da safra 04/05. **Informação UNICA**, São Paulo, ano 7, n. 62, p.4-5, nov/dez 2004.

UNIVERSIDADE ESTADUAL DE CAMPINAS. **Sistema de simulação de crescimento e produtividade econômica da cana-de-açúcar.** 128p. Relatório técnico final -

Departamento de Fisiologia Vegetal, Instituto de Biologia, Universidade Estadual de Campinas, 1983.

VON ZUBEN, F. J. **Modelos paramétricos e não-paramétricos de redes neurais artificiais e aplicações.** Tese (Doutorado em Engenharia Elétrica) - Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, Campinas, 1996.

VON ZUBEN, F. J.; LIMA, C. A. M.; VILLANUEVA, W. J. P. **Programa computacional de estimativa de produtividade para cana-de-açúcar.** Laboratório de Bioinformática e Computação Bio-Inspirada – LBiC, Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, Campinas, 2004. Programa não publicado.

ZULLO JUNIOR, J. **Correção atmosférica de imagens de satélite e aplicações.** Tese (Doutorado em Engenharia Elétrica) – Faculdade de Engenharia Elétrica, Universidade Estadual de Campinas, Campinas, 1994.

ZULLO JUNIOR, J. **Programa computacional BHSEQ – Balanço Hídrico Seqüencial.** Campinas-SP: CEPAGRI/UNICAMP. 2002. Programa não publicado.

BIBLIOGRAFIA CONSULTADA

CAMARGO, A. P. et al. Ajuste da equação de Thornthwaite para estimar a evapotranspiração potencial em climas áridos e superúmidos, com base na amplitude térmica diária. **Revista Brasileira de Agrometeorologia**, Santa Maria, v.7, n.2, p.251-257, 1999.

DELGADO-ROJAS; J. S.; BARBIERI, V. Modelo agrometeorológico de estimativa da produtividade da cana-de-açúcar. **Revista Brasileira de Agrometeorologia**, Santa Maria, v.7, n.1, p.67-73, 1999.

FARIA, R. A. et al. Influência do método de estimativa da evapotranspiração de referência na demanda de irrigação suplementar para o milho (*Zea mays* L.), na Bacia do Rio Verde (MG). **Ciência Agrotéc**, Lavras, v.24 (edição especial), p.187-196, dez., 2000.

FAUSETT, L. V. **Fundamentals of neural networks: architectures, algorithms and applications**. Saddle River: Prentice Hall, 1994.

IYODA, E. M. **Inteligência computacional no projeto automático de redes neurais híbridas e redes neurofuzzy heterogêneas**. 167p. Dissertação (Mestrado em Engenharia Elétrica) - Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, Campinas, 2000.

MACHADO, E. C. **Um modelo matemático-fisiológico para simular o acúmulo de matéria seca na cultura de cana-de-açúcar (*Saccharum* sp)**. 115p. Dissertação (Mestrado em Biologia) – Instituto de Biologia, Universidade Estadual de Campinas, Campinas, 1981.

MORAES, A. V. C. et al. Teste e análise de modelos agrometeorológicos de estimativa de produtividade para a cultura da soja na região de Ribeirão Preto. **Bragantia**, Campinas, v.57, n.2, p.393-406, 1998.

RAIA JUNIOR, A. A. **Acessibilidade e mobilidade na estimativa de um índice de potencial de viagens utilizando redes neurais artificiais e Sistemas de Informações Geográficas.** 217p. Tese (Doutorado em Engenharia Civil) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2000.

RANGSANSERI, Y.; PROMCHAROEN, S.; THITIMAJSHIMA, P. A fuzzy neural network approach for multispectral imagery analysis. **Second International Conference on Geospatial Information in Agriculture and Forestry**, vol. 1, pp. 383-390, Janeiro 2000.

SUDDUTH, Kenneth A. et al. Integrating spatial data collection, modeling and analysis for precision agriculture. **First International Conference on Geospatial Information in Agriculture and Forestry**, vol. 1, Junho 1998.

ZHENG, D.; KAINZ, W.; GROTEN, S. Integrated approach of GIS and neural fuzzy network for linguistic decision-making on land use management. **Second International Conference on Geospatial Information in Agriculture and Forestry**, vol. 1, pp. 95-102, Janeiro 2000.

ANEXOS

ANEXO 1 - Planilha de dados de produção de cana-de-açúcar da usina.

Acompanhamento de produção - Anos 2001 / 2002											
Zona	Talhão	Ambiente		Estágio de corte	Área total (ha)	Variedade	Data corte	Produção (ton)		Produtividade (ton/ha)	
		de solo						Real	Estimada	Real	Estimada
110004	5	B		4	40.61	SP80-1816	5/11/2001	3772.31	4061	92.9	100
110004	6	B		4	25.42	SP80-1816	5/11/2001	2206.66	2542	86.8	100
21519	1	B		4	36.76	SP80-1816	9/5/2002	2977.4	2940.8	81	80
21519	3	B		4	4.16	SP80-1816	11/9/2002	451.7	332.8	108.6	80
21519	4	B		4	16.9	SP80-1816	11/9/2002	1041.4	1352	61.6	80
21519	5	B		4	17.54	SP80-1816	13/9/2002	1770.9	1403.2	101	80
21519	6	B		4	28.82	SP80-1816	11/9/2002	2356.5	2305.6	81.8	80
21509	2	B		4	22.97	SP80-1816	31/7/2002	2465.7	2297	107.3	100
21509	3	B		4	23.64	SP80-1816	14/8/2002	2164.4	2127.6	91.6	90
21509	4	B		4	6.25	SP80-1816	26/8/2002	600.5	625	96.1	100
21509	5	B		4	34.42	SP80-1816	4/8/2002	3664.3	3442	106.5	100
21509	6	B		4	9.98	SP80-1816	5/8/2002	1171.6	998	117.4	100
21509	7	B		4	18.34	SP80-1816	5/8/2002	1463.1	1834	79.8	100
21509	8	B		4	5.97	SP80-1816	30/8/2002	711.4	597	119.2	100
21509	9	B		4	17.46	SP80-1816	30/8/2002	1443.2	1746	82.7	100
21509	10	B		4	14.32	SP80-1816	5/8/2002	2044.4	1288.8	142.8	90
21509	11	B		4	8.45	SP80-1816	7/8/2002	590.7	760.5	69.9	90
21509	12	B		4	8.6	SP80-1816	23/8/2002	1022.7	946	118.9	110
21509	13	B		4	7.81	SP80-1816	24/8/2002	872.7	859.1	111.7	110
21509	14	B		4	7.56	SP80-1816	25/8/2002	702.1	831.6	92.9	110
21509	15	B		4	11.18	SP80-1816	27/8/2002	1301.2	1229.8	116.4	110
21509	16	B		4	3.72	SP80-1816	26/8/2002	439.4	409.2	118.1	110
21509	17	B		4	7.08	SP80-1816	27/8/2002	653.2	708	92.3	100
21509	18	B		4	4.75	SP80-1816	27/8/2002	490.5	522.5	103.3	110
21509	19	B		4	26.52	SP80-1816	2/9/2002	2966	2917.2	111.8	110
21509	20	B		4	33.37	SP80-1816	2/9/2002	3703.3	3670.7	111	110
21509	21	B		4	38.02	SP80-1816	3/9/2002	3918.4	4942.6	103.1	130
21032	5	A		4	9.39	SP80-1816	26/7/2002	276.8	751.2	29.5	80
21032	6	A		4	24.71	SP80-1816	13/8/2002	1282.7	1976.8	51.9	80
21032	7	A		4	3.32	SP80-1816	8/7/2002	213	282.2	64.2	85
21032	8	B		4	20.75	SP80-1816	6/7/2002	1745.3	1867.5	84.1	90
21032	1	A		4	33.56	SP80-1842	22/7/2002	3237.9	3017.7	96.6	90
21032	2	A		4	55.84	SP80-1842	25/7/2002	3336	5025.6	59.7	90
21032	3	B		4	15.59	SP80-1842	22/7/2002	951.6	1400.4	61.2	90
21032	4	A		4	55.96	SP80-1842	12/8/2002	4298.2	5036.4	76.8	90

1º Ano	Amostra	B4	GVI	Produtividade (ton/ha)		2º Ano	Amostra	B4	GVI	Produtividade (ton/ha)	
		(reflectância real %)	(reflectância real %)	Colhida	Estimada usina			(reflectância real %)	(reflectância real %)	Colhida	Estimada usina
2/11/2001	1	23,63	17,27	82,35	100	27/4/2002	52	36,00	26,42	69,12	80
	2	21,76	15,35	64,47	100		53	33,78	24,20	55,66	80
	3	22,84	16,11	73,14	100		54	42,67	32,02	91,17	90
	4	21,96	15,26	55,79	100		55	36,44	25,86	62,57	90
	5	22,25	15,67	60,64	100		56	36,89	26,10	63,59	90
	6	24,22	17,75	67,56	100		57	36,89	26,54	64,97	80
	7	23,04	16,26	67,50	100		58	44,89	34,09	88,36	80
	8	24,12	17,60	75,18	100		59	43,56	34,28	92,39	80
	9	25,49	18,99	82,72	100		60	38,22	29,30	71,29	80
	10	22,45	15,94	74,81	100		61	42,67	33,41	84,24	130
	11	22,45	16,12	69,33	100		62	40,44	31,96	65,84	110
	12	23,82	17,33	63,46	100		63	40,44	31,69	62,72	80
	13	24,71	18,03	67,36	100		64	37,33	29,08	55,61	110
	14	22,94	16,20	68,73	100		65	47,56	37,59	83,68	110
	15	25,39	18,55	70,78	100		66	45,78	36,70	94,59	110
	16	23,63	17,23	66,67	100		67	47,11	37,11	82,54	110
	17	24,12	17,70	78,67	100		68	45,33	35,87	77,89	110
	18	24,90	18,37	83,56	100		69	38,67	29,85	40,13	90
	19	25,10	18,61	73,78	100		70	37,78	28,67	72,49	110
	20	24,51	17,93	72,86	100		71	40,44	31,56	75,55	130
	21	25,20	18,67	78,67	100		72	32,44	24,53	71,81	100
	22	24,80	18,33	81,33	100	73	32,00	24,72	61,17	100	
	23	24,61	18,18	69,35	100	74	33,78	26,00	79,61	100	
	24	24,90	18,50	80,00	100	75	36,00	27,31	79,99	100	
	25	24,80	18,38	78,67	100	76	32,89	24,74	59,33	90	
	26	24,90	18,54	72,44	100	77	28,89	21,85	61,54	100	
	27	25,29	18,73	81,78	100	78	32,00	23,90	55,62	100	
	28	25,00	18,60	82,38	100	79	33,78	26,62	78,07	110	
	29	24,51	17,99	77,33	100	80	31,56	23,39	109,70	80	
	30	24,61	18,28	83,56	100	81	37,78	29,10	118,48	110	
	31	24,51	18,32	75,11	100	82	34,22	26,66	67,12	100	
	32	25,69	19,06	77,33	100	83	32,44	24,51	64,06	80	
	33	24,41	18,01	80,95	100	84	36,44	28,78	57,86	90	
	34	24,61	18,13	80,89	100	85	40,89	30,44	100,20	100	
	35	24,90	18,34	80,44	100	86	44,44	33,70	82,03	110	
	36	24,12	17,78	74,85	100	87	41,33	31,22	80,59	110	
	37	26,37	19,66	94,22	100	88	39,11	30,70	72,32	100	
	38	24,41	18,03	78,57	100	89	32,00	25,08	39,36	110	
	39	24,22	17,81	78,67	100	90	30,22	22,55	81,11	110	
	40	24,51	18,00	74,67	100	91	36,00	27,18	70,67	130	
	41	24,71	18,22	88,13	100						
	42	25,20	18,77	85,90	100						
	43	24,71	18,07	71,92	100						
	44	24,12	17,73	71,73	100						
	45	25,29	18,72	90,72	100						
	46	25,39	18,78	81,35	100						
	47	24,41	17,88	72,63	100						
	48	24,22	17,59	79,14	100						
	49	24,61	18,03	74,01	100						
	50	24,61	18,28	76,17	100						
	51	24,80	18,37	76,05	100						

ANEXO 2 – Dados de reflectância da B4, GVI e produtividade (MACHADO, 2003).

APÊNDICES

APÊNDICE 1 – Código fonte da função principal **bagging.m**

```
20/09/2004
% bagging.m
% (1) gera um conjunto de dados de treinamento para cada rede neural
%     a partir de um conjunto original
% (2) adota o mesmo conjunto de teste para todas as redes neurais
% (3) adota o mesmo conjunto de validacao para todas as redes neurais
% Funcoes auxiliares: mlp.m / treina_rn.m / carrega.m / normaliza.m /
%     divide_dataset.m / geranum.m / result.m / grava.m
%
clear all;format long;format compact;

[X,Y]=carrega;

perc_tr=60;
perc_va=20;
perc_se=0;
perc_ts=20;

[N,m]=size(X);

[X,param_input] = normaliza(X,-1,1);

[Y,param_output] = normaliza(Y,-1,1);

n = [15;1]; % Dimensions of the neural network candidates
r = n(2);
N_NN = 10; % Para emsemble com 10 NN
%N_NN = 20; % Para emsemble com 20 NN
%N_NN = 50; % Para emsemble com 50 NN
%N_NN = 100; % Para emsemble com 100 NN

% Divisao do conjunto de dados
Ntr=round(N*perc_tr/100);
Nva=round(N*perc_va/100);
Nse=round(N*perc_se/100);
Nts=N-Ntr-Nva-Nse;

nRun = 10; % Numero de simulacoes

vet=zeros(nRun,16);

for i=1:nRun

    [Xtr,Ytr,Xva,Yva,Xse,Yse,Xts,Yts] =
divide_dataset(X,Y,Ntr,Nva,Nse,Nts);

    % Inicializa alguns paramentros
    FVU = [];
```

```

EQM = [];
NITER = [];
for n_NN=1:N_NN,
    % Gera os pesos das redes
    w1 = randn(n(1),m+1);
    w2 = randn(n(2),n(1)+1);
    % Realiza o processo de amostragem
    amostra=geranum(Ntr);
    % Escolhe as entradas
    X_bag = Xtr(amostra,:);
    S_bag = Ytr(amostra,:);
    % Treina a rede neural
    [w1,w2,niter,niter_glob,FVU_t,EQM_t] =
treina_rn(X_bag,S_bag,Xva,Yva,Xts,Yts,w1,w2,n_NN);
    FVU = [FVU;FVU_t];
    EQM = [EQM;EQM_t];
    NITER = [NITER;niter_glob niter];
    save(strcat('w',sprintf('%d',n_NN)), 'X_bag', 'S_bag', 'w1', 'w2')
end

Sbag = zeros(Ntr,n(2));
for n_NN=1:N_NN,
    load(strcat('w',sprintf('%d',n_NN)));
    y = mlp(Xtr,w1,w2);
    Sbag = Sbag+y;
end

Sbag = Sbag./N_NN; % Media simples
verro = reshape(Ytr-Sbag,Ntr*r,1);
eqf = 0.5*(verro'*verro);
disp(sprintf('Final Bagging squared error = %.12g',eqf));
eqm = sqrt((1/(Ntr*r))*(verro'*verro));
erro = Ytr-Sbag;
disp('-----');

if r > 1,
    for k=1:r,
        veqf(k,1) = 0.5*(erro(:,k)'*erro(:,k));
        disp(sprintf('Final squared error (output %d) =
%.12g',k,veqf(k,1)));
        veqm(k,1) = sqrt((1/Ntr)*(erro(:,k)'*erro(:,k)));
        disp(sprintf('Final mean squared error (output %d) =
%.12g',k,veqm(k,1)));
    end
end

disp('-----');
for k=1:r,
    figure(k);subplot(111);plot(Ytr(:,k), 'r');hold
on;plot(Ytr(:,k), '*r');
    plot(Sbag(:,k), 'g');plot(Sbag(:,k), '*g');hold off;
    title('Desired (r)  NN (g)');
end

for k=(r+1):(r+r),
    figure(k);subplot(111);plot(Ytr(:,k-r)-Sbag(:,k-r), 'r');
    hold on;plot(Ytr(:,k-r)-Sbag(:,k-r), '*g');hold off;

```

```

        title('Error = Desired-NN');
    end

    for k=1:r,
        Smedio(1,k) = (1/Nva)*Yts(:,k)'*ones(Nts,1); % Duvida
    end

    den = 0; num = 0;
    for l=1:Nts,
        for k=1:r,
            num = num+(Yts(l,k)-Sbag(l,k))^2;
            den = den+(Yts(l,k)-Smedio(1,k))^2;
        end
    end
    fvu = num/den;
    disp(sprintf('FVU = %.12g', fvu));
    disp(FVU);
    disp(sprintf('Final mean squared error = %.12g', eqm));
    disp(EQM);
    disp(NITER);

    save
    (strcat('dados', sprintf('%d', i)), 'Xtr', 'Ytr', 'Xva', 'Yva', 'Xts', 'Yts')

    result

    pause
end
grava

```

APÊNDICE 2 – Código fonte da função auxiliar **mlp.m**

```

%
% function [S] = mlp(X,w1,w2)
% Presentation of input-output patterns: batch mode
% All neurons have bias
%
function [S] = mlp(X,w1,w2)
N = length(X(:,1));
x1 = [X ones(N,1)];
y1 = tanh(x1*w1');
x2 = [y1 ones(N,1)];
% y2 = tanh(x2*w2');
S = x2*w2';

```

APÊNDICE 3 – Código fonte da função auxiliar **carrega.m**

```
function [X,Y]=carrega()

disp(sprintf('*****Escolha o conjunto de
treinamento*****'))
disp(sprintf('[1] - Friedman # 1'))
disp(sprintf('[2] - Friedman # 2 [por implementar]'))
disp(sprintf('[3] - Friedman # 3 [por implementar]'))
disp(sprintf('[4] - Body Fat considerando saida 1'))
disp(sprintf('[5] - Body Fat considerando saida 2 [por implementar]'))
disp(sprintf('[6] - Producao de Cana Acucar'))
type=input('Digite a opcao escolhida ');

switch type

case 1 % Friedman #1
    load dados_friedman1
case 2 % Friedman #2
    load dados_friedman2
case 3 % Friedman #3
    load dados_friedaman3
case 4
    load dados_bodyfat1
case 5
    load dados_bodyfat2
case 6
    load inoutput.dat
    X=inoutput(:,1:3);
    Y=inoutput(:,4);
otherwise
    disp('Escolha inadequada')
end
```

APÊNDICE 4 – Código fonte da função auxiliar **normaliza.m**

```
function [X,param] = normaliza(X,lb,ub)
[N,m] = size(X);

disp('Escolha o criterio de normalizacao')
disp('[0] - Normalizacao isotropica (Total)')
disp('[1] - Normalizacao anisotropica (Por coluna)')
isotropic=input('Digite a opcao desejada ');
```

```

if isotropic % Normaliza coluna a coluna

    maior=max(X);
    menor=min(X);
    sca=maior-menor;

    X=ub-(ub-lb)*(ones(N,1)*maior-X)./(ones(N,1)*sca);

else
    maior=max(max(X));
    menor=min(min(X));
    sca=maior-menor;

    X=ub-(ub-lb)*(ones(N,m)*maior-X)./(ones(N,m)*sca);

end

param.isotropic=isotropic;
param.maior=maior;
param.menor=menor;
param.ub=ub;
param.lb=lb;

% if (nargin <1 | nargin>2) % check correct number of arguments
%     help normaliza
% else
%     if (nargin < 2)
%         isotropic = 0;;
%     end
%
%     lb = -1;; ub = 1;
%
%     n = size(X,2); % input dimension
%
%     sca = zeros(n,1);
%     mina = zeros(n,1);
%     maxa = zeros(n,1);
%     A = zeros(n,1);
%     B = zeros(n,1);
%     for i=1:n
%         mina(i) = min(X(:,i));
%         maxa(i) = max(X(:,i));
%         sca(i) = maxa(i) - mina(i);
%     end
%
%     for i=1:n
%         if (isotropic)
%             sca(i) = max(sca);
%         end
%         if sca(i)
%             A(i) = (ub - lb)/sca(i);
%             B(i) = lb - A(i)*mina(i);
%             X(:,i) = A(i)*X(:,i) + B(i);
%         end
%     end
end

```

```
%  
% end
```

APÊNDICE 5 – Código fonte da função auxiliar **divide_dataset.m**

```
function [Xtr,Ytr,Xva,Yva,Xse,Yse,Xte,Yte] =  
divide_dataset(X,Y,train,validate,selection,test)  
  
[N,m] = size(X);  
  
if (train + validate + selection + test) ~= N  
    disp('valores de divisao nao sumam o total de linhas');  
end  
  
indices = randperm(N);  
  
Xtr(1:train ,:) = X( indices(1:train)  
, :);  
Xva(1:validate ,:) = X( indices(train+1 : train+validate)  
, :);  
Xse(1:selection,:) = X( indices(train+validate+1 :  
train+validate+selection)  
, :);  
Xte(1:test ,:) = X( indices(train+validate+selection+1 :  
train+validate+selection+test), :);  
  
Ytr(1:train ,:) = Y( indices(1:train)  
, :);  
Yva(1:validate ,:) = Y( indices(train+1 : train+validate)  
, :);  
Yse(1:selection,:) = Y( indices(train+validate+1 :  
train+validate+selection)  
, :);  
Yte(1:test ,:) = Y( indices(train+validate+selection+1 :  
train+validate+selection+test), :);
```

APÊNDICE 6 – Código fonte da função auxiliar **geranum.m**

```
function amostra=geranum(N)  
  
W=ones(N,1)/N;  
cW = cumsum(W);  
randnum = rand(N,1);  
amostra = zeros(N,1);
```

```

for i = 1:N
    loc = sum([max(find(randnum(i) > cW)),1]);
    amostra(i,1) = loc;
end

```

APÊNDICE 7 – Código fonte da função auxiliar **result.m**

```

%load dados

%N_NN = 10;

yvmat=[]; % matriz N*M com os elementos de todos os componentes

for n_NN=1:N_NN,
    load(strcat('w', sprintf('%d', n_NN)));
    y = mlp(Xva,w1,w2);
    yvmat=[yvmat,y];

    verro = reshape(Yva-y,Nva,1);
    eqfvcomp(n_NN,1)=0.5*(verro'*verro);
    eqmvcomp(n_NN,1)=sqrt((1/(Nva))*(verro'*verro));

end

[Icomp1, ycomp1]=select(yvmat, Yva,'construct'); % Realiza selecao usando
metodo construtivo

[Icomp2, ycomp2]=select(yvmat, Yva,'poda'); % Realiza selecao usando metodo
poda

Sbagv=sum(yvmat,2)/N_NN; % Realiza a media de todos os componentes sem
selecao

verro = reshape(Yva-Sbagv,Nva,1);
eqfv = 0.5*(verro'*verro);
eqmv = sqrt((1/(Nva))*(verro'*verro));

[eqfbest Ibest]=min(eqfvcomp); % Melhor componente da validacao

disp(sprintf('\n *** Result for validation dataset *** '))
disp('-----');
disp(sprintf('Squared error for the best component =
%.12g', eqfvcomp(Ibest)))
disp(sprintf('Mean Squared error for the best component =
%.12g', eqmvcomp(Ibest)))
disp('-----');

```

```

disp(sprintf('Squared error without selection          =
%.12g',eqfv))
disp(sprintf('Mean squared error without selection    =
%.12g',eqmv))
disp('-----');

yvsel=sum(ycomp1,2)/length(Icomp1);
verro = reshape(Yva-yvsel,Nva,1);
eqfvsel1 = 0.5*(verro'*verro);
eqmvsel1 = sqrt((1/(Nva))*(verro'*verro));

disp(sprintf('Squared error with selection via method construct      =
%.12g',eqfvsel1))
disp(sprintf('Mean squared error with selection via method construct =
%.12g',eqmvsel1))
disp('-----');

yvsel=sum(ycomp2,2)/length(Icomp2);
verro = reshape(Yva-yvsel,Nva,1);
eqfvsel2 = 0.5*(verro'*verro);
eqmvsel2 = sqrt((1/(Nva))*(verro'*verro));

disp(sprintf('Squared error with selection via method prune          =
%.12g',eqfvsel2))
disp(sprintf('Mean squared error with selection via method prune    =
%.12g',eqmvsel2))
disp('-----');

disp('-----');

ytmat=[]; % matriz N*M com os elementos de todos os componentes

for n_NN=1:N_NN,
    load(strcat('w',sprintf('%d',n_NN)));
    y = mlp(Xts,w1,w2);
    ytmat=[ytmat,y];

    verro = reshape(Yts-y,Nts,1);
    eqftcomp(n_NN,1)=0.5*(verro'*verro);
    eqmtcomp(n_NN,1)=sqrt((1/(Nts))*(verro'*verro));

end

Sbagt=sum(ytmat,2)/N_NN; % Realiza a media de todos os componentes sem
selecao

verro = reshape(Yts-Sbagt,Nts,1);
eqft = 0.5*(verro'*verro);
eqmt = sqrt((1/(Nts))*(verro'*verro));

disp(sprintf('\n *** Result for test dataset *** '))
disp('-----');

```

```

disp(sprintf('Squared error for the best component           =
%.12g',eqftcomp(Ibest)))
disp(sprintf('Mean Squared error for the best component     =
%.12g',eqmtcomp(Ibest)))
disp('-----');

disp(sprintf('Squared error without selection               =
%.12g',eqft))
disp(sprintf('Mean squared error without selection          =
%.12g',eqmt))
disp('-----');

ycomp1=ytmat(:,Icomp1); %Seleciona os dados de teste
ytsel=sum(ycomp1,2)/length(Icomp1);
verro = reshape(Yts-ytsel,Nts,1);
eqftsel1 = 0.5*(verro'*verro);
eqmtsel1 = sqrt((1/(Nts))*(verro'*verro));

disp(sprintf('Squared error with selection via method construct =
%.12g',eqftsel1))
disp(sprintf('Mean squared error with selection via method construct =
%.12g',eqmtsel1))
disp('-----');

ycomp2=ytmat(:,Icomp2); %Seleciona os dados de teste
ytsel=sum(ycomp2,2)/length(Icomp2);
verro = reshape(Yts-ytsel,Nts,1);
eqftsel2 = 0.5*(verro'*verro);
eqmtsel2 = sqrt((1/(Nts))*(verro'*verro));

disp(sprintf('Squared error with selection via method prune   =
%.12g',eqftsel2))
disp(sprintf('Mean squared error with selection via method prune   =
%.12g',eqmtsel2))

%save(strcat('res',sprintf('%d',rand)),min(eqfvcomp),min(eqmvcomp),eqfv,eqm
v,eqfvsel1,eqmvsel1,eqfvsel2,eqmvsel2,
min(eqftcomp),min(eqmtcomp),eqft,eqmt,eqftsel1,eqmtsel1,eqftsel2,eqmtse
l2);

vet(i,:)=[eqfvcomp(Ibest),eqmvcomp(Ibest),eqfv,eqmv,eqfvsel1,eqmvsel1,eqfvs
el2,eqmvsel2,...

eqftcomp(Ibest),eqmtcomp(Ibest),eqft,eqmt,eqftsel1,eqmtsel1,eqftsel2,eqmtse
l2];

```

APÊNDICE 8 – Código fonte da função auxiliar **grava.m**

```

fid = fopen('arquivo.txt','w');

```

```

fprintf(fid, 'RESULTADO CONJUNTO DE VALIDACAO');
fprintf(fid, '\n');

for i=1:nRun,
    for j=1:8
        fprintf(fid, '%6.9f\t', vet(i, j));
    end
    fprintf(fid, '\n');
end
fprintf(fid, '\n');
fprintf(fid, '\n');

fprintf(fid, 'RSEULTADO CONJUNTO DE TESTE');
fprintf(fid, '\n');

for i=1:nRun,
    for j=9:16
        fprintf(fid, '%6.9f\t', vet(i, j));
    end
    fprintf(fid, '\n');
end
fprintf(fid, '\n');
fprintf(fid, '\n');

fclose(fid);

```

APÊNDICE 9 – Código fonte da função auxiliar `treina_rn.m`

```

% 20/09/2004
% treina_rn.m
% Training of a one hidden layer feedforward neural network
% Multilayer Perceptron
% Second-order optimization: extended conjugate gradient algorithm
% Exact computation of the Hessian matrix (product H*p)
% Input data:
% (1) X - matrix with one input training pattern per row
% (2) S - matriz with one output training pattern per row
% (3) Xv - matrix with one input validating pattern per row
% (4) Sv - matriz with one output validating pattern per row
% (5) Xt - matrix with one input testing pattern per row
% (6) St - matriz with one output testing pattern per row
% (7) w1 - matrix with the initial hidden layer weights
% (8) w2 - matriz with the initial output layer weights
% (9) n_NN - index of the neural network
% X: [N] x [m]
% S: [N] x [n(2)]
% Xv: [Nv] x [m]

```

```

% Sv: [Nv] x [n(2)]
% Xt: [Nt] x [m]
% St: [Nt] x [n(2)]
% w1: [n(1)] x [m+1]
% w2: [n(2)] x [n(1)+1]
% Auxiliary functions: processa.m / procval.m / hprocess.m / norma.m /
testarn.m
%
function [w1,w2,niter,niter_glob,FVU_t,eqm_t] =
treina_rn(X,S,Xv,Sv,Xt,St,w1,w2,n_NN)
disp(sprintf('Training process for Neural Network %d',n_NN));
Nv = length(Xv(:,1));
N = length(X(:,1));
m = length(X(1,:));
[n(1,1),m1] = size(w1);
[n(2,1),n1] = size(w2);
n2 = size(S(1,:));
if m ~= (m1-1),
    error('Matrices X and w1 indicate different number of inputs');
elseif n(1) ~= (n1-1),
    error('Matrices w1 and w2 indicate different number of hidden
neurons');
elseif n(2) ~= n2,
    error('Matrices S and w2 indicate different number of outputs');
end
limiar = 1.0e-5;
taxa0 = 0.25;
taxa = taxa0;
corte = 0.25;
it1 = 0; % for lamb
it2 = 0; % for comp
it1 = it1+1;lamb(it1) = 0.0;
blamb = 0;
npesas = n(1)*(m+1)+n(2)*(n(1)+1);
[Ew,dEw] = processa(X,S,w1,w2,n,m,N);
[Ewv] = procval(Xv,Sv,w1,w2,n,m,Nv);
eq = [Ew];
eqv = [Ewv];
eq_glob = eqv;
w1_glob = w1;
w2_glob = w2;
itermenor = 1;
niter = 1;
niter_glob = niter;
p = -dEw;p_1 = p;r = -dEw;sucesso = 1;
contador = 0;
while norma(dEw) > limiar & (contador < 6 | eq(niter) > 0.0005*N) & niter <
100000,
    if sucesso,
        p1 = reshape(p(1:n(1)*(m+1)),m+1,n(1))';
        p2 = reshape(p(n(1)*(m+1)+1:npesas),n(1)+1,n(2))';
        s = hprocess(X,S,w1,w2,p1,p2,n,m,N);
        delta = p'*s;
    end
    delta = delta+(lamb(it1)-blamb)*(p'*p);
    if delta <= 0, % positivando delta
        blamb = 2*(lamb(it1)-delta/(p'*p));
    end
end

```

```

        delta = -delta+lamb(it1)*(p'*p);
        it1 = it1+1;lamb(it1) = blamb;
    end
    mi = p'*r;
    alfa = mi/delta;
    vw = [reshape(w1',n(1)*(m+1),1);reshape(w2',n(2)*(n(1)+1),1)];
    vw1 = vw + alfa*p;
    w11 = reshape(vw1(1:n(1)*(m+1)),m+1,n(1))';
    w21 = reshape(vw1(n(1)*(m+1)+1:npesos),n(1)+1,n(2))';
    [Ew1,dEw1] = processa(X,S,w11,w21,n,m,N);
    it2 = it2+1;comp(it2) = (Ew-Ew1)/(-dEw'*(alfa*p)-0.5*(alfa^2)*delta);
% Em lugar de comp(it2) = 2*delta*(Ew-Ew1)/(mi^2); (da' na mesma)
    if comp(it2) > 0,
        Ew = Ew1;eq = [eq;Ew];
        dEw = dEw1;
        deltaw1 = norma(w1-w11);deltaw2 = norma(w2-w21);
        w1 = w11;w2 = w21;
        [Ewv] = procval(Xv,Sv,w1,w2,n,m,Nv);
        if Ewv < eq_glob,
            w1_glob = w1;
            w2_glob = w2;
            eq_glob = Ewv;
            niter_glob = niter;
        end
        if Ewv >= eqv(niter),
            contador = contador+1;
        else
            contador = 0;
        end
        eqv = [eqv;Ewv];
        niter = niter+1;
        disp(sprintf('%d %5d %d %.12g %.12g
%d',n_NN,niter,itermenor,Ew,Ewv,contador));
        r1 = r;
        r = -dEw;
        blamb = 0;
        sucesso = 1;
        if (itermenor == npesos),
            p_1 = p;p = r;
            itermenor = 1;
        else
            itermenor = itermenor + 1;
            beta = (r'*r-r'*r1)/(r1'*r1); % Polak-Ribiere (Luenberger,
pg 253)
            p_1 = p;p = r+beta*p;
        end
        if comp(it2) >= corte,
            it1 = it1+1;lamb(it1) = taxa*lamb(it1-1); % /4
            taxa = taxa*taxa0;
        end
    else
        blamb = lamb(it1);
        sucesso = 0;
    end
    if comp(it2) < corte,
        it1 = it1+1;lamb(it1) = lamb(it1-1) + (delta*(1-
comp(it2))/(p_1'*p_1));

```

```

        taxa = taxa0;
    end
end
w1 = w1_glob;
w2 = w2_glob;
[FVU_t,eqm_t] = testarn(Xt,St,w1,w2);
disp(sprintf('End of the process - Neural Network %d',n_NN));

```

APÊNDICE 10 – Código fonte da função auxiliar **processa.m**

```

%
% function [Ew,dEw] = processa(X,S,w1,w2,n,m,N)
% Output: squared error and gradient vector
% Presentation of input-output patterns: batch mode
% All neurons have bias
%
function [Ew,dEw] = processa(X,S,w1,w2,n,m,N)
x1 = [X ones(N,1)];
y1 = tanh(x1*w1');
x2 = [y1 ones(N,1)];
% y2 = tanh(x2*w2');
y2 = x2*w2';
erro = y2-S;
% erro2 = erro.*(1.0-y2.*y2);
erro2 = erro;
dw2 = erro2'*x2;
erro1 = (erro2*w2(:,1:n(1))).*(1.0-y1.*y1);
dw1 = erro1'*x1;
verro = reshape(erro,N*n(2),1);
Ew = 0.5*(verro'*verro);
dEw = [reshape(dw1',n(1)*(m+1),1);reshape(dw2',n(2)*(n(1)+1),1)];

```

APÊNDICE 11 – Código fonte da função auxiliar **norma.m**

```

% 02/01/1998
% norma.m
% Gives a kind of mean squared error for a matrix
%
function [E] = norma(S)
[nr,nc] = size(S);
E = sum(sum(S.*S));
E = sqrt(E/(nr*nc));

```

APÊNDICE 12 – Código fonte da função auxiliar **hprocess.m**

```
%
% function [s] = hprocess(X,S,w1,w2,p1,p2,n,m,N)
% s = product H*p (computed exactly)
%
function [s] = hprocess(X,S,w1,w2,p1,p2,n,m,N)
x1 = [X ones(N,1)];
rx1 = zeros(N,m+1);
y1 = tanh(x1*w1');
ry1 = (x1*p1'+rx1*w1').*(1.0-y1.*y1);
x2 = [y1 ones(N,1)];
rx2 = [ry1 zeros(N,1)];
% y2 = tanh(x2*w2');
y2 = x2*w2';
% ry2 = (x2*p2'+rx2*w2').*(1.0-y2.*y2);
ry2 = x2*p2'+rx2*w2';
erro = y2-S;
% erro2 = erro.*(1.0-y2.*y2);
erro2 = erro;
rerro2 = ry2;
rw2 = erro2'*rx2+rerro2'*x2;
errol = (erro2*w2(:,1:n(1))).*(1.0-y1.*y1);
rerrol = (rerro2*w2(:,1:n(1))+erro2*p2(:,1:n(1))).*(1.0-
y1.*y1)+(erro2*w2(:,1:n(1))).*(-2*y1.*ry1);
rw1 = errol'*rx1+rerrol'*x1;
rEw = [reshape(rw1',n(1)*(m+1),1);reshape(rw2',n(2)*(n(1)+1),1)];
s = rEw;
```

APÊNDICE 13 – Código fonte da função auxiliar **procval.m**

```
% function [Ew,dEw] = procval(X,S,w1,w2,n,m,N)
% Output: squared error
% Presentation of input-output patterns: batch mode
% All neurons have bias
%
function [Ew] = procval(X,S,w1,w2,n,m,N)
x1 = [X ones(N,1)];
y1 = tanh(x1*w1');
x2 = [y1 ones(N,1)];
% y2 = tanh(x2*w2');
y2 = x2*w2';
erro = y2-S;
verro = reshape(erro,N*n(2),1);
Ew = 0.5*(verro'*verro);
```

APÊNDICE 14 – Código fonte da função auxiliar **testarn.m**

```
% Verification of the performance of the neural network
% when a test set is considered
% Use of the weights obtained after training the neural network
% Presentation of graphical results
%
function [fvu,eqm] = testarn(X,S,w1,w2)
N = length(X(:,1));
X = [X ones(N,1)];
n(1,1) = length(w1(:,1));
n(2,1) = length(w2(:,1));
r = n(2);
m = length(w1(1,:))-1;
np1 = n(1)*(m+1);np2 = n(2)*(n(1)+1);
npesos = np1+np2;
disp(sprintf('No. of training patterns = %d',N));
disp(sprintf('No. of hidden layer neurons = %d',n(1)));
disp(sprintf('No. of weights = %d',npesos));
Srn = [tanh(X*w1') ones(N,1)]*w2';
verro = reshape(S-Srn,N*r,1);
eqf = 0.5*(verro'*verro);
disp(sprintf('Final squared error = %.12g',eqf));
eqm = sqrt((1/(N*r))*(verro'*verro));
disp(sprintf('Final mean squared error = %.12g',eqm));
erro = S-Srn;
if r > 1,
    for k=1:r,
        veqf(k,1) = 0.5*(erro(:,k)'*erro(:,k));
        disp(sprintf('Final squared error (output %d) =
%.12g',k,veqf(k,1)));
        veqm(k,1) = sqrt((1/N)*(erro(:,k)'*erro(:,k)));
        disp(sprintf('Final mean squared error (output %d) =
%.12g',k,veqm(k,1)));
    end
end
for k=1:r,
    figure(k);subplot(111);plot(S(:,k),'r');hold on;plot(S(:,k),'*r');
    plot(Srn(:,k),'g');plot(Srn(:,k),'*g');hold off;
    title('Desired (r) NN (g)');
end
for k=(r+1):(r+r),
    figure(k);subplot(111);plot(S(:,k-r)-Srn(:,k-r),'r');
    hold on;plot(S(:,k-r)-Srn(:,k-r),'*g');hold off;
    title('Error = Desired-NN');
end
for k=1:r,
    Smedio(1,k) = (1/N)*S(:,k)'*ones(N,1);
end
den = 0;num = 0;
for l=1:N,
    for k=1:r,
```

```

        num = num+(S(l,k)-Srnl(k))^2;
        den = den+(S(l,k)-Smedio(l,k))^2;
    end
end
fvu = num/den;
disp(sprintf('FVU = %.12g', fvu));
drawnow;

```

APÊNDICE 15 – Código fonte da função auxiliar **select.m**

```

% y - saída da o compunto de rede
% M - numero de rede componentes
% N - Numero de pontos do conjunto selecao
% Ind - Indice das redes selecionadas
% yd - saída desejada

function [Icomp, ycomp]=select(y, yd,type)

if nargin<3
    type='construct';
elseif nargin<2
    error('Numero de parametro inadequado')
end

switch lower(type)

case 'construct'
    [Icomp,ycomp]=construct(y,yd);

case 'poda'
    [Icomp,ycomp]=poda(y,yd);
otherwise
    disp('Tipo de metodo de selecao inadequado')
end

function [Icomp,ycomp]=construct(y,yd)

% ns    - numero de saída
% N     - numero de padroes de treinamento
% M     - numero de redes componentes
% Icomp - Indice das redes componentes selecionadas
% y     - saída das redes componentes
% yd    - saída desejada

[N,M]=size(y);

[N,ns]=size(yd);

```

```

% Verifica se o numero de saidas maior que 1
if ns>1
    error('Numero de saidas maior que 1')
end

% Calcula o EQM para cada componente
for i=1:M,
    verro = reshape(yd-y(:,i),N,1);
    eqm(i,1) = verro'*verro;
end

% Ordena as redes componentes em ordem crescente de EQM
[eqm, I]=sort(eqm);

% Ordena as saidas das redes componentes
y = y(:,I);

% Armazena os dados da melhor rede
ycomp=y(:,1);
Icomp=I(1);
eqmcomp=eqm(I(1),1);

% Contador com o numero de redes
ncomp=1;

% Tenta adiciona as rede um a uma
for i=2:M,

    % Calcula o erro cometido pela rede i
    mnew=yd-y(:,i);

    % Inicializa o valor de b
    b=0;

    % Mede a correlacao da rede i com todas as redes ja adicionadas
    for j=1:ncomp,

        % Calcula o erro da rede j
        mj=yd-ycomp(:,j);

        b = b + mnew'*mj;
    end

    % Calcula o primeiro termo da formula de Perrone
    a=(2*ncomp+1)*eqmcomp;

    % Termo da formula de Perrone
    c=mnew'*mnew;

    if a > (2*b+c) % Condicao para adciona a rede

        disp(sprintf('Adiciona a rede %d',i))

        % Atualiza o contador
        ncomp=ncomp+1;
    end
end

```

```

    % Adiciona a saida da rede i para a saida da ensemble
    ycomp(:,ncomp)=y(:,i);

    % Adiciona o indice da rede
    Icomp=[Icomp;I(i)];

    % Calcula a saida da nova ensemble
    ys=sum(ycomp,2)/ncomp;

    % Atualiza o EQM da ensemble
    verro = reshape(yd-ys,N,1);
    eqmcomp = (verro'*verro); % Calcula o EQM das componentes
else
    disp(sprintf('Nao Adiciona a rede %d',i))
end
end
end

```

```
function [Icomp,ycomp]=poda(y,yd)
```

```

% ns    - numero de saida
% N     - numero de padroes de treinamento
% M     - numero de redes componentes
% Icomp - Indice das redes componentes selecionadas
% y     - saida das redes componentes
% yd    - saida desejada

[N,M]=size(y);

[N,ns]=size(yd);

% Verifica se o numero de saidas maior que 1
if ns>1
    error('Numero de saidas maior que 1')
end

% Calcula a saida da ensemble por media simples de M componentes
ys=sum(y,2)/M;

% Calcula o erro da ensemble
verro = reshape(yd-ys,N,1);
eqmcomp = verro'*verro;

% Calcula o EQM para cada componente
for i=1:M,
    verro = reshape(yd-y(:,i),N,1);
    eqm(i,1) = verro'*verro;
end

% Ordena as redes componentes em ordem decrescente de EQM
[eqm, I]=sort(-eqm);

% Ordena as saidas das redes componentes
y = y(:,I);

% Armazena os dados da ensemble
ycomp=y;

```

```

Icomp=I;
cont=1:M;

% Contador com o numero de redes
ncomp=M;

% Tenta adiciona as rede um a uma
for i=1:M,

    % Executa a exclusao somente se existe um numero de rede maior que 1
    if ncomp>1
        % Calcula o erro cometido pela rede i
        mnew=yd-y(:,i);

        % Inicializa o valor de b
        b=0;

        % Mede a correlacao da rede i com todas as redes ja adicionadas
        for j=1:M,
            if cont(j)~=0 % Verifica se a rede ja saiu
                if j~=i
                    % Calcula o erro da rede j
                    mj=yd-y(:,j);
                    b = b + mnew'*mj;
                end
            end
        end

        % Calcula o primeiro termo da formula de Perrone
        a=(2*ncomp-1)*eqmcomp;

        % Termo da formula de Perrone
        c=mnew'*mnew;

        erro1=yd-sum(y(:,cont(find(cont>0))),2)/ncomp;

        erro2=yd-(sum(y(:,cont(find(cont>0))),2)-y(:,i))/(ncomp-1);

        disp(sprintf('Erro antes da retirada da %.12g depois de retira a
rede %.12g',erro1*erro1,erro2*erro2))
        if a <= (2*b+c) % Condicao para exclusao

            disp(sprintf('Exluindo a rede %d',i))

            % Atualiza o contador
            ncomp=ncomp-1;

            % Exclusao da saida da rede i da ensemble
            cont(i)=0;

            Icomp(i)=0;

            ycomp=y(:,cont(find(cont>0)));

            % Calcula a saida da nova ensemble
            ys=sum(ycomp,2)/ncomp;

```

```

        % Atualiza o EQM da ensemble
        verro = reshape(yd-ys,N,1);
        eqmcomp = (verro'*verro); % Calcula o EQM das componentes
    else
        disp(sprintf('Nao exclui a rede %d',i))
    end
else
    disp('Existe somente uma rede na ensemble')
end
end

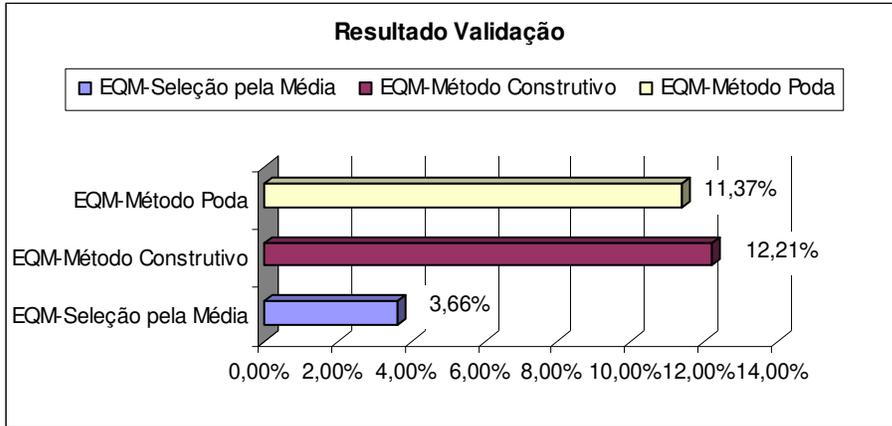
end
Icomp=Icomp(find(Icomp>0));

```

APÊNDICE 16 – Resultados dos *ensembles* aplicados aos dados Body_Fat

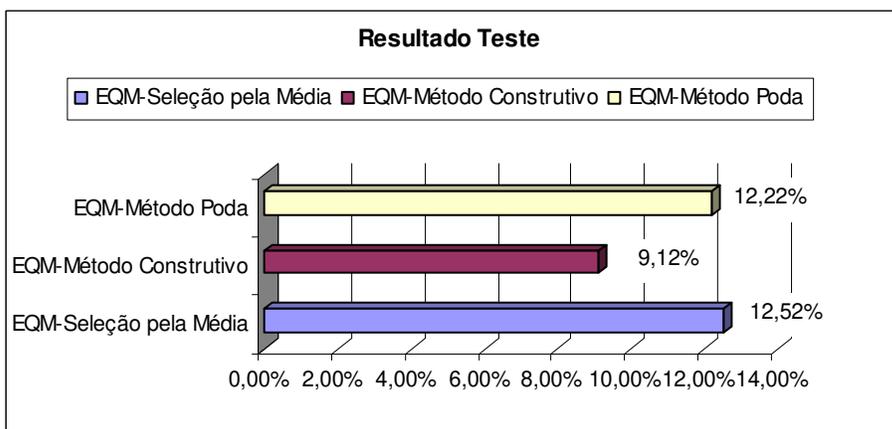
1) *Ensembles* com 10 RNs

VALIDAÇÃO - <i>Ensembles</i> com 10 RNs								
Simulação	Melhor Componente		Seleção pela Média		Método Construtivo		Método Poda	
	EQ	EQM	EQ	EQM	EQ	EQM	EQ	EQM
1	0,8893	0,1886	0,8080	0,1798	0,6593	0,1624	0,6641	0,1630
2	0,8150	0,1806	0,7929	0,1781	0,6922	0,1664	0,7085	0,1683
3	0,8972	0,1894	0,9095	0,1907	0,7008	0,1674	0,7235	0,1701
4	0,9024	0,1900	0,9284	0,1927	0,7879	0,1775	0,7604	0,1744
5	1,0530	0,2052	0,8582	0,1853	0,7424	0,1723	0,7578	0,1741
6	0,8821	0,1878	0,9576	0,1957	0,7648	0,1749	0,7993	0,1788
7	0,9121	0,1910	0,7135	0,1689	0,6512	0,1614	0,6421	0,1603
8	1,0217	0,2022	1,0117	0,2012	0,8488	0,1843	0,9021	0,1900
9	1,1213	0,2118	0,9133	0,1911	0,7749	0,1761	0,8307	0,1823
10	0,7511	0,1733	0,6904	0,1662	0,5103	0,1429	0,4926	0,1404
Média	0,9245	0,1920	0,8584	0,1850	0,7133	0,1686	0,7281	0,1702



* Porcentagem em que o erro melhorou em relação à “Melhor Componente”.

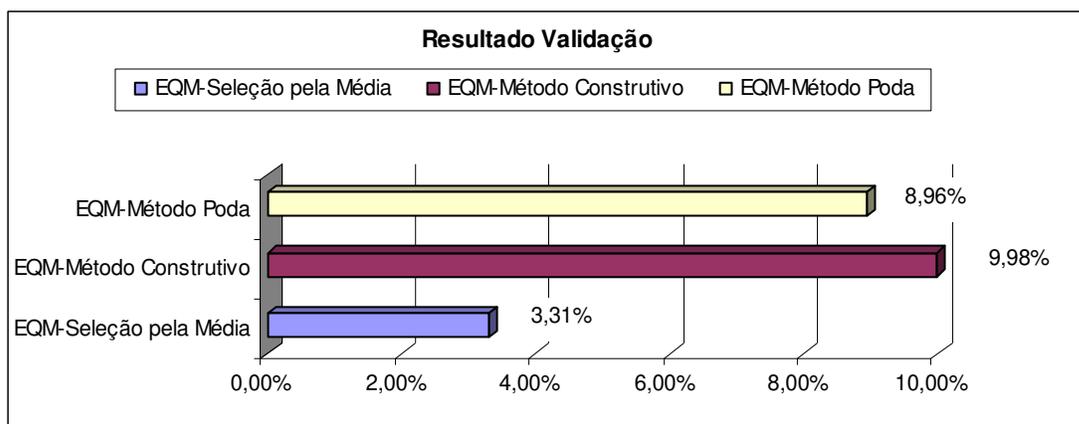
TESTE - <i>Ensembles</i> com 10 RNs								
Simulação	Melhor Componente		Seleção pela Média		Método Construtivo		Método Poda	
	EQ	EQM	EQ	EQM	EQ	EQM	EQ	EQM
1	1,1000	0,2077	1,2669	0,2229	1,1676	0,2140	1,1843	0,2155
2	1,4955	0,2422	1,0102	0,1990	1,1912	0,2161	1,0668	0,2045
3	1,5823	0,2491	0,9130	0,1892	1,1515	0,2125	1,0749	0,2053
4	1,0712	0,2050	0,8648	0,1842	1,0110	0,1991	0,9317	0,1911
5	0,9550	0,1935	0,9180	0,1897	1,0479	0,2027	0,9876	0,1968
6	1,0020	0,1982	0,6712	0,1622	0,8299	0,1804	0,7019	0,1659
7	1,6652	0,2555	1,2674	0,2229	1,5358	0,2454	1,2136	0,2182
8	0,9889	0,1969	0,8182	0,1791	0,7035	0,1661	0,7394	0,1703
9	1,3122	0,2268	1,3141	0,2270	1,1248	0,2100	1,3130	0,2269
10	2,4131	0,3076	1,2383	0,2204	1,3275	0,2282	1,1160	0,2092
Média	1,3585	0,2283	1,0282	0,1997	1,1091	0,2075	1,0329	0,2004



* Porcentagem em que o erro melhorou em relação à “Melhor Componente”.

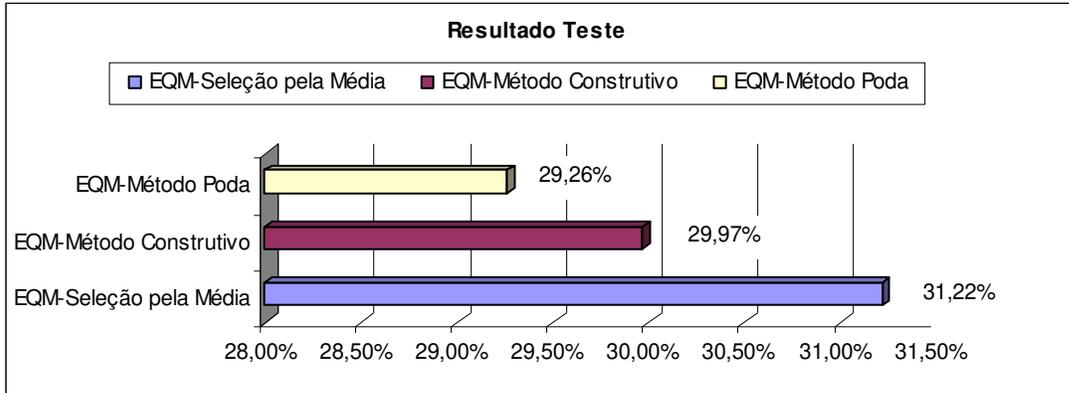
b) *Ensembles* com 20 RNs

VALIDAÇÃO - <i>Ensembles</i> com 20 RNs								
Simulação	Melhor Componente		Seleção pela Média		Método Construtivo		Método Poda	
	EQ	EQM	EQ	EQM	EQ	EQM	EQ	EQM
1	0,8070	0,1797	0,7621	0,1746	0,6717	0,1639	0,6807	0,1650
2	1,0617	0,2061	0,8997	0,1897	0,7889	0,1776	0,8103	0,1800
3	1,0168	0,2017	0,9808	0,1981	0,8315	0,1824	0,8526	0,1847
4	0,9079	0,1906	0,8812	0,1877	0,7697	0,1755	0,7848	0,1772
5	0,9779	0,1978	0,9607	0,1960	0,7408	0,1721	0,7408	0,1721
6	0,8386	0,1831	0,7211	0,1698	0,6430	0,1604	0,6348	0,1594
7	0,9413	0,1940	0,8825	0,1879	0,7723	0,1758	0,8022	0,1791
8	0,9837	0,1984	0,8849	0,1881	0,7557	0,1739	0,8035	0,1793
9	1,0590	0,2058	0,9920	0,1992	0,9273	0,1926	0,9552	0,1955
10	1,0317	0,2031	1,0427	0,2042	0,9076	0,1905	0,9251	0,1924
Média	0,9626	0,1960	0,9008	0,1895	0,7809	0,1765	0,7990	0,1785



* Porcentagem em que o erro melhorou em relação à “Melhor Componente”.

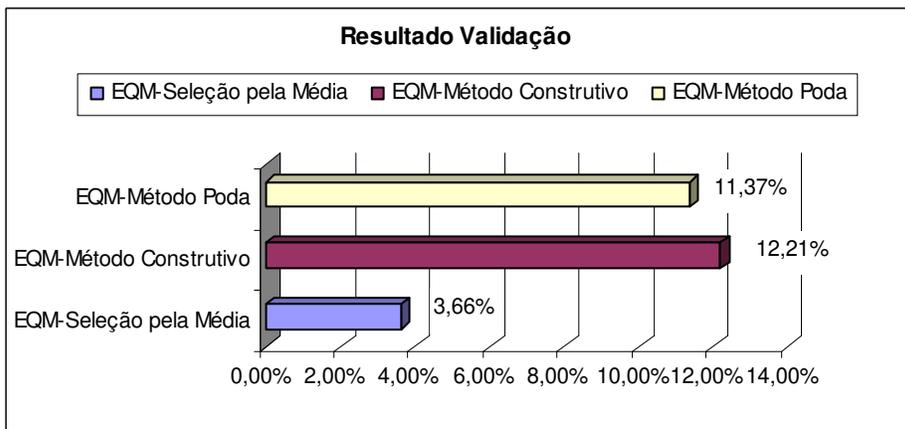
TESTE - <i>Ensembles</i> com 20 RNs								
Simulação	Melhor Componente		Seleção pela Média		Método Construtivo		Método Poda	
	EQ	EQM	EQ	EQM	EQ	EQM	EQ	EQM
1	1,0497	0,2029	0,7785	0,1747	0,8145	0,1787	0,9060	0,1885
2	1,1104	0,2087	0,9190	0,1898	1,1258	0,2101	0,9662	0,1947
3	3,2273	0,3558	1,4162	0,2357	0,7204	0,1681	0,9641	0,1944
4	3,2175	0,3552	0,8624	0,1839	1,0873	0,2065	1,0741	0,2052
5	4,6964	0,4292	0,9371	0,1917	0,9976	0,1978	0,9976	0,1978
6	4,3526	0,4131	0,7763	0,1745	0,9119	0,1891	1,1540	0,2127
7	1,4763	0,2406	0,9434	0,1923	1,1062	0,2083	1,0381	0,2018
8	1,1126	0,2089	1,0750	0,2053	1,0616	0,2040	1,0288	0,2009
9	0,8987	0,1877	0,9505	0,1931	1,1492	0,2123	0,9660	0,1946
10	0,8189	0,1792	0,7540	0,1720	0,7618	0,1728	0,7965	0,1767
Média	2,1961	0,2781	0,9412	0,1913	0,9736	0,1948	0,9891	0,1967



* Porcentagem em que o erro melhorou em relação à “Melhor Componente”.

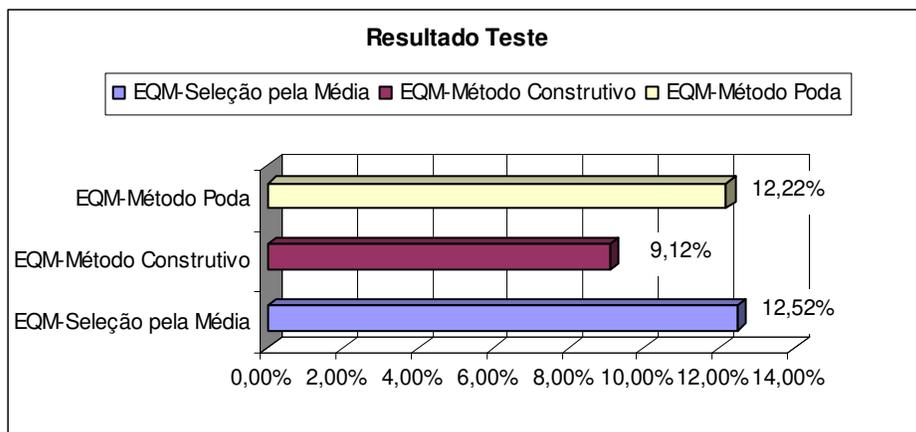
c) *Ensembles* com 50 RNs

VALIDAÇÃO - <i>Ensembles</i> com 50 RNs								
Simulação	Melhor Componente		Seleção pela Média		Método Construtivo		Método Poda	
	EQ	EQM	EQ	EQM	EQ	EQM	EQ	EQM
1	0,8893	0,1886	0,8080	0,1798	0,6593	0,1624	0,6641	0,1630
2	0,8150	0,1806	0,7929	0,1781	0,6922	0,1664	0,7085	0,1683
3	0,8972	0,1894	0,9095	0,1907	0,7008	0,1674	0,7235	0,1701
4	0,9024	0,1900	0,9284	0,1927	0,7879	0,1775	0,7604	0,1744
5	1,0530	0,2052	0,8582	0,1853	0,7424	0,1723	0,7578	0,1741
6	0,8821	0,1878	0,9576	0,1957	0,7648	0,1749	0,7993	0,1788
7	0,9121	0,1910	0,7135	0,1689	0,6512	0,1614	0,6421	0,1603
8	1,0217	0,2022	1,0117	0,2012	0,8488	0,1843	0,9021	0,1900
9	1,1213	0,2118	0,9133	0,1911	0,7749	0,1761	0,8307	0,1823
10	0,7511	0,1733	0,6904	0,1662	0,5103	0,1429	0,4926	0,1404
Média	0,9245	0,1920	0,8584	0,1850	0,7133	0,1686	0,7281	0,1702



* Porcentagem em que o erro melhorou em relação à “Melhor Componente”.

TESTE - <i>Ensembles</i> com 50 RNs								
Simulação	Melhor Componente		Seleção pela Média		Método Construtivo		Método Poda	
	EQ	EQM	EQ	EQM	EQ	EQM	EQ	EQM
1	1,1000	0,2077	1,2669	0,2229	1,1676	0,2140	1,1843	0,2155
2	1,4955	0,2422	1,0102	0,1990	1,1912	0,2161	1,0668	0,2045
3	1,5823	0,2491	0,9130	0,1892	1,1515	0,2125	1,0749	0,2053
4	1,0712	0,2050	0,8648	0,1842	1,0110	0,1991	0,9317	0,1911
5	0,9550	0,1935	0,9180	0,1897	1,0479	0,2027	0,9876	0,1968
6	1,0020	0,1982	0,6712	0,1622	0,8299	0,1804	0,7019	0,1659
7	1,6652	0,2555	1,2674	0,2229	1,5358	0,2454	1,2136	0,2182
8	0,9889	0,1969	0,8182	0,1791	0,7035	0,1661	0,7394	0,1703
9	1,3122	0,2268	1,3141	0,2270	1,1248	0,2100	1,3130	0,2269
10	2,4131	0,3076	1,2383	0,2204	1,3275	0,2282	1,1160	0,2092
Média	1,3585	0,2283	1,0282	0,1997	1,1091	0,2075	1,0329	0,2004

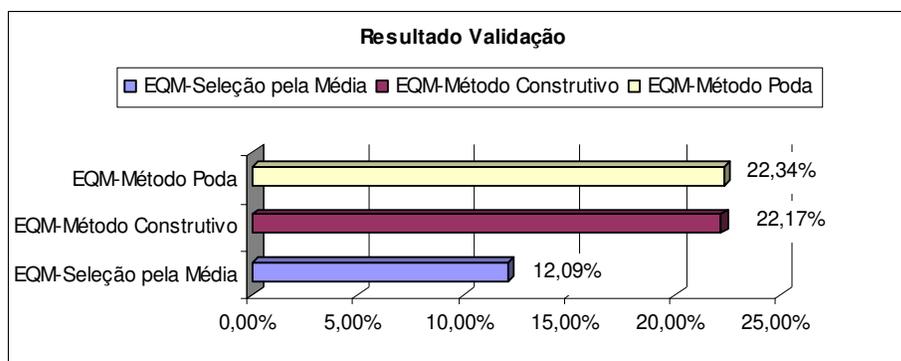


* Porcentagem em que o erro melhorou em relação à “Melhor Componente”.

APÊNDICE 17 – Resultados dos *ensembles* aplicados aos dados da Função de Friedman-1

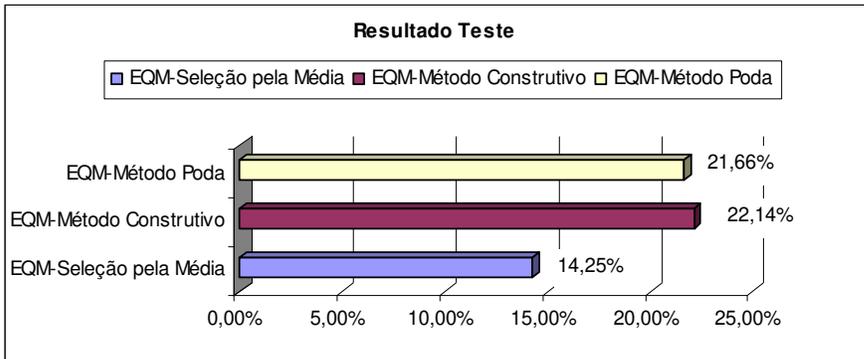
1) *Ensembles* com 10 RNs

VALIDAÇÃO - <i>Ensembles</i> com 10 RNs								
Simulação	Melhor Componente		Seleção pela Média		Método Construtivo		Método Poda	
	EQ	EQM	EQ	EQM	EQ	EQM	EQ	EQM
1	1,2552	0,1584	1,1468	0,1514	0,8378	0,1294	0,8539	0,1307
2	1,0360	0,1439	0,8153	0,1277	0,6429	0,1134	0,6286	0,1121
3	1,0224	0,1430	0,8700	0,1319	0,7270	0,1206	0,7232	0,1203
4	1,7113	0,1850	1,2447	0,1578	1,0091	0,1421	1,0098	0,1421
5	1,1535	0,1519	0,8541	0,1307	0,6684	0,1156	0,6724	0,1160
6	1,3681	0,1654	0,8123	0,1275	0,7130	0,1194	0,6940	0,1178
7	1,2223	0,1564	1,2917	0,1607	0,8270	0,1286	0,8456	0,1300
8	1,4206	0,1686	0,9152	0,1353	0,7354	0,1213	0,7122	0,1193
9	1,3392	0,1637	0,9870	0,1405	0,7775	0,1247	0,7775	0,1247
10	1,1925	0,1544	0,9098	0,1349	0,7563	0,1230	0,7478	0,1223
Média	1,2721	0,1591	0,9847	0,1398	0,7695	0,1238	0,7665	0,1235



* Porcentagem em que o erro melhorou em relação à “Melhor Componente”.

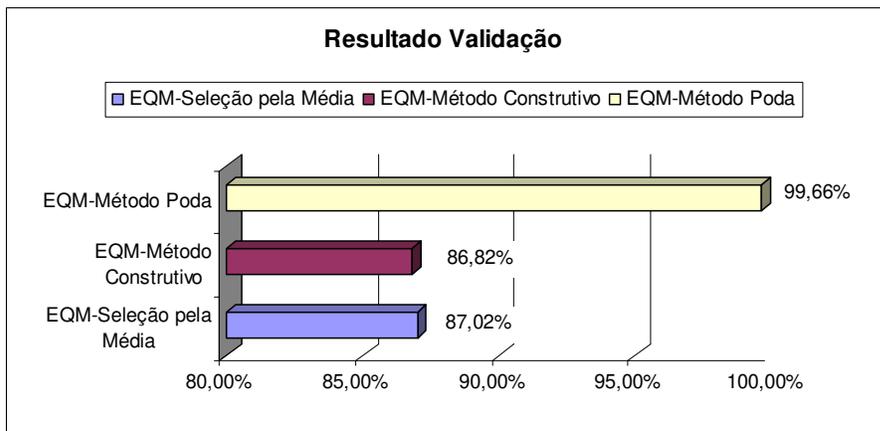
TESTE - <i>Ensembles</i> com 10 RNs								
Simulação	Melhor Componente		Seleção pela Média		Método Construtivo		Método Poda	
	EQ	EQM	EQ	EQM	EQ	EQM	EQ	EQM
1	1,2880	0,1605	1,0905	0,1477	1,0583	0,1455	1,0434	0,1445
2	1,4384	0,1696	1,1542	0,1519	1,0133	0,1424	0,9648	0,1389
3	1,0608	0,1457	1,0269	0,1433	0,8604	0,1312	0,9009	0,1342
4	1,3455	0,1640	0,7833	0,1252	0,6208	0,1114	0,6848	0,1170
5	1,6072	0,1793	1,0984	0,1482	0,8384	0,1295	0,9338	0,1367
6	1,8183	0,1907	0,8861	0,1331	0,8727	0,1321	0,9050	0,1345
7	1,5827	0,1779	1,5776	0,1776	1,0054	0,1418	0,9227	0,1358
8	1,7710	0,1882	1,1004	0,1483	0,8563	0,1309	0,9066	0,1347
9	1,4304	0,1691	0,9002	0,1342	0,7164	0,1197	0,7164	0,1197
10	0,9756	0,1397	0,9132	0,1351	0,8103	0,1273	0,7656	0,1237
Média	1,4318	0,1685	1,0531	0,1445	0,8652	0,1312	0,8744	0,1320



* Porcentagem em que o erro melhorou em relação à “Melhor Componente”.

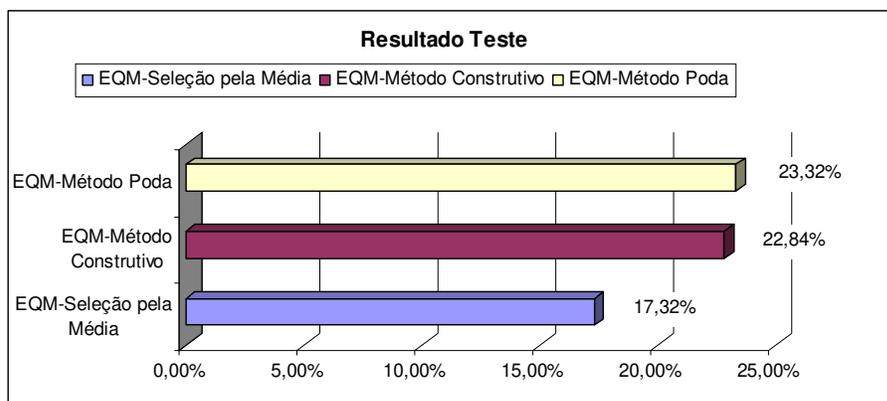
2) Ensembles com 20 RNs

VALIDAÇÃO - Ensembles com 20 RNs								
Simulação	Melhor Componente		Seleção pela Média		Método Construtivo		Método Poda	
	EQ	EQM	EQ	EQM	EQ	EQM	EQ	EQM
1	1,2275	0,1567	0,7290	0,1207	0,6059	0,1101	0,5885	0,1085
2	1,0893	0,1476	0,8090	0,1272	0,5742	0,1072	0,5742	0,1072
3	1,1684	0,1529	0,6747	0,1162	0,5705	0,1068	0,5670	0,1065
4	1,3962	0,1671	1,1799	0,1536	0,8135	0,1276	0,8134	0,1275
5	1,2786	0,1599	0,9481	0,1377	0,7084	0,1190	0,6978	0,1181
6	1,3185	0,1624	1,0645	0,1459	0,8414	0,1297	0,8369	0,1294
7	1,4351	0,1694	1,1914	0,1544	0,8431	0,1299	0,8378	0,1294
8	1,0885	0,1475	1,1051	0,1487	0,8058	0,1269	0,8090	0,1272
9	1,1614	0,1524	0,7443	0,1220	0,5842	0,1081	0,5784	0,1076
10	1,5475	0,1759	1,2607	0,1588	0,9437	0,1374	0,9402	0,1371
Média	1,2711	0,1592	0,9707	0,1385	0,7291	0,1203	0,7243	0,1199



* Porcentagem em que o erro melhorou em relação à “Melhor Componente”.

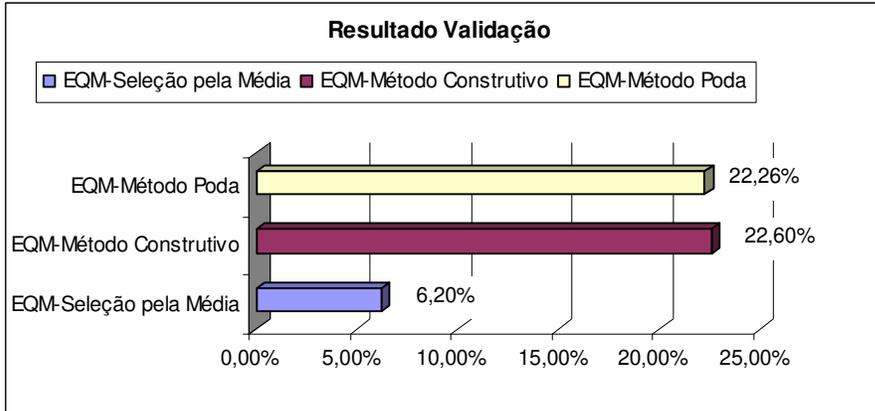
TESTE - <i>Ensembles</i> com 20 RNs								
Simulação	Melhor Componente		Seleção pela Média		Método Construtivo		Método Poda	
	EQ	EQM	EQ	EQM	EQ	EQM	EQ	EQM
1	1,6992	0,1843	0,9838	0,1403	0,8894	0,1334	0,8370	0,1294
2	1,4021	0,1675	1,3868	0,1665	0,9730	0,1395	0,9730	0,1395
3	1,5982	0,1788	1,0277	0,1434	1,0319	0,1437	0,9538	0,1381
4	1,3809	0,1662	0,8597	0,1311	0,7753	0,1245	0,7970	0,1263
5	1,1012	0,1484	0,8448	0,1300	0,7715	0,1242	0,7806	0,1249
6	1,7613	0,1877	0,9812	0,1401	0,9626	0,1387	0,9560	0,1383
7	1,7381	0,1864	1,1649	0,1526	1,1720	0,1531	1,2080	0,1554
8	1,4697	0,1714	0,9852	0,1404	0,7465	0,1222	0,7761	0,1246
9	1,9035	0,1951	1,2464	0,1579	0,9497	0,1378	0,9116	0,1350
10	1,3458	0,1641	1,0444	0,1445	0,8855	0,1331	0,8484	0,1303
Média	1,5400	0,1750	1,0525	0,1447	0,9157	0,1350	0,9041	0,1342



* Porcentagem em que o erro melhorou em relação à “Melhor Componente”.

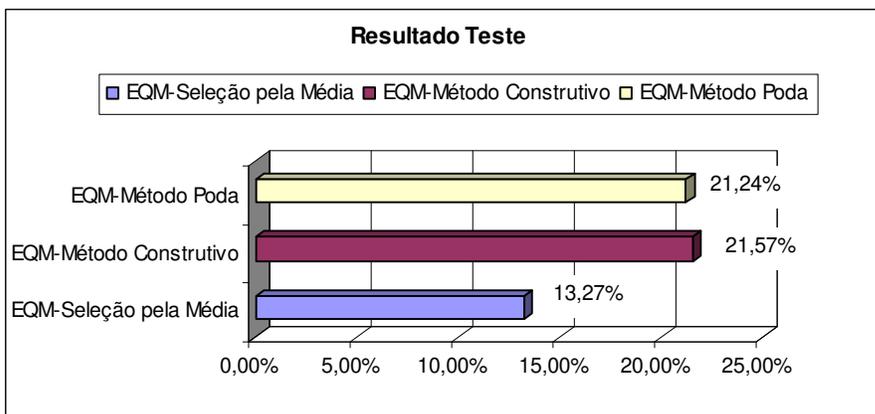
3) *Ensembles* com 50 RNs

VALIDAÇÃO - <i>Ensembles</i> com 50 RNs								
Simulação	Melhor Componente		Seleção pela Média		Método Construtivo		Método Poda	
	EQ	EQM	EQ	EQM	EQ	EQM	EQ	EQM
1	1,6168	0,1798	1,0620	0,1457	0,9459	0,1375	0,9343	0,1367
2	1,3023	0,1614	1,3474	0,1642	0,8960	0,1339	0,9100	0,1349
3	1,0153	0,1425	0,8997	0,1341	0,6318	0,1124	0,6532	0,1143
4	0,8737	0,1322	0,7849	0,1253	0,5098	0,1010	0,5414	0,1041
5	1,4189	0,1685	1,2760	0,1598	0,8517	0,1305	0,8517	0,1305
6	1,2992	0,1612	0,9723	0,1395	0,7351	0,1213	0,7402	0,1217
7	1,0494	0,1449	1,0502	0,1449	0,7050	0,1187	0,7214	0,1201
8	0,8713	0,1320	0,7768	0,1246	0,4961	0,0996	0,4963	0,0996
9	1,0042	0,1417	1,1877	0,1541	0,5674	0,1065	0,5674	0,1065
10	1,3812	0,1662	1,0262	0,1433	0,7565	0,1230	0,7364	0,1214
Média	1,1832	0,1530	1,0383	0,1435	0,7095	0,1184	0,7152	0,1190



* Porcentagem em que o erro melhorou em relação à “Melhor Componente”.

TESTE - <i>Ensembles</i> com 50 RNs								
Simulação	Melhor Componente		Seleção pela Média		Método Construtivo		Método Poda	
	EQ	EQM	EQ	EQM	EQ	EQM	EQ	EQM
1	1,8712	0,1935	0,8595	0,1311	0,8730	0,1321	0,8934	0,1337
2	0,9982	0,1413	1,1200	0,1497	1,0710	0,1464	1,0877	0,1475
3	1,5626	0,1768	1,2347	0,1571	1,0203	0,1429	0,9682	0,1392
4	1,1607	0,1524	0,9206	0,1357	0,8762	0,1324	0,8014	0,1266
5	1,9148	0,1957	0,9039	0,1345	0,8248	0,1284	0,8248	0,1284
6	1,5620	0,1767	0,9502	0,1379	0,9188	0,1356	0,8973	0,1340
7	1,2741	0,1596	1,2918	0,1607	0,9293	0,1363	0,9603	0,1386
8	1,6429	0,1813	1,4591	0,1708	1,0294	0,1435	1,0942	0,1479
9	1,3044	0,1615	1,5219	0,1745	0,7920	0,1259	0,7920	0,1259
10	1,4416	0,1698	0,8430	0,1298	0,6805	0,1167	0,7685	0,1240
Média	1,4733	0,1709	1,1105	0,1482	0,9015	0,1340	0,9088	0,1346



* Porcentagem em que o erro melhorou em relação à “Melhor Componente”.