

MINISTÉRIO DA EDUCAÇÃO
UNIVERSIDADE FEDERAL DOS VALES DO JEQUITINHONHA E MUCURI
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA FLORESTAL

EDUARDO PELLI

COMPARAÇÃO DOS ALGORITMOS MÁQUINA DE
APRENDIZAGEM EXTREMA E RETROPROPAGAÇÃO DO
ERRO PARA ESTIMAÇÃO DE ALTURA E VOLUME DE
ÁRVORES

DIAMANTINA - MG
2013

EDUARDO PELLI

COMPARAÇÃO DOS ALGORITMOS MÁQUINA DE
APRENDIZAGEM EXTREMA E RETROPROPAGAÇÃO DO
ERRO PARA ESTIMAÇÃO DE ALTURA E VOLUME DE
ÁRVORES

Dissertação apresentada à Universidade Federal dos Vales do Jequitinhonha e Mucuri, como parte das exigências do Programa de Pós-Graduação em Ciência Florestal, área de concentração em Manejo Florestal, para a obtenção do título de “Mestre”.

Orientador: Prof. Gilciano Saraiva Nogueira
Coorientador: Prof. Euler Guimarães Horta

DIAMANTINA - MG
2013

Ficha Catalográfica - Serviço de Bibliotecas/UFVJM
Bibliotecária: Jullyele Hubner Costa CRB-6/2972

P391c Pelli, Eduardo
2013 Comparação dos algoritmos máquina de aprendizagem extrema e retropropagação do erro para estimação de altura e volume de árvores. / Eduardo Pelli. – Diamantina: UFVJM, 2013.
74 p. : il.

Orientador: Prof. Dr. Gilciano Saraiva Nogueira
Coorientador: Prof. Me. Euler Guimarães Horta

Dissertação (mestrado) –Universidade Federal dos Vales do Jequitinhonha e Mucuri. Faculdade de Ciências Agrárias. Programa de Pós-Graduação em Produção Vegetal, 2013.

1. Inteligência computacional. 2. Regressão. 3. Pinus. 4. Cerrado. I. Nogueira, Gilciano Saraiva. II. Horta, Euler Guimarães. III. Título.

CDD 582.16

Elaborada com os dados fornecidos pelo(a) autor(a).

**COMPARAÇÃO DOS ALGORITMOS MÁQUINA DE
APRENDIZAGEM EXTREMA E RETROPROPAGAÇÃO DO ERRO
PARA ESTIMAÇÃO DE ALTURA E VOLUME DE ÁRVORES**

Eduardo Pelli

Dissertação apresentada ao Programa de Pós-Graduação em Ciência Florestal, nível de Mestrado, como parte dos requisitos para obtenção do título de Mestre.

APROVADO EM 09 / 08 / 2013

Prof. Helio Garcia Leite – UFV

Prof.^a Mayra Luiza Marques da Silva Binoti – UFVJM

Prof. Marcio Leles Romarco de Oliveira – UFVJM

Prof. Gilciano Saraiva Nogueira – UFVJM
Presidente

DIAMANTINA
2013

Dedico este trabalho à minha família, em especial aos meus pais Lúvia Maria Neves Pelli e Luciano Pelli pelo apoio, compreensão e incentivos demonstrados nesses anos de faculdade.

Agradecimentos

Aos meus pais Livia Maria Neves Pelli e Luciano Pelli, pelo carinho, pelo apoio dado as minhas decisões e pelo incessante incentivo ao meu crescimento.

A Andreza Lemos Meira, por ajudar e estar presente nos momentos difíceis no caminho de mais essa conquista.

Ao amigo irmão Humberto Antônio dos Santos, por todo apoio dado e pela presença em todos os momentos

A toda minha família e amigos.

A todos os colegas do mestrado, em especial ao Leonidas Soares Murta Júnior e Rafael Ribeiro Souza pela amizade e apoio durante todo o mestrado

Aos professores, Euler Guimarães Horta e Gilciano Saraiva Nogueira pelas sugestões, contribuições ao conhecimento e amizade

A professora Dra. Alba Valéria Rezende por ter gentilmente cedido os dados possibilitando este estudo

Aos professores da comissão examinadora, Prof. Helio Garcia Leite, Prof. Marcio Leles Romarco de Oliveira e a Prof.^a Mayra Luiza Marques da Silva Binoti pelas sugestões e contribuições ao trabalho

À UFVJM e CAPES, pela concessão das bolsas de estudo

Aos professores e a todos os funcionários da UFVJM, que contribuíram na minha formação intelectual.

À todos aqueles que, de alguma forma, contribuíram para a realização deste trabalho.

Resumo

PELLI, E. **Comparação dos algoritmos máquina de aprendizagem extrema e retropropagação do erro para estimação de altura e volume de árvores**. 2013. 74 p. Dissertação - Departamento de Engenharia Florestal, Universidade Federal dos Vales do Jequitinhonha e Mucuri, Minas Gerais, 2013.

O uso do algoritmo de aprendizado para as redes neurais artificiais (RNA) do tipo *feed-forward*, nomeado máquina de aprendizagem extrema (*Extreme Learning Machine* - ELM), permite que o treinamento possa ser realizado com melhor desempenho do que com o uso dos métodos de aprendizagem tradicionais, baseados em gradiente descendente, tanto em termos de generalização como na velocidade de aprendizagem. Neste estudo objetivou-se a aplicação das redes neurais artificiais utilizando o algoritmo ELM em problemas de estimativa da altura árvores de *Pinus*, e também, em problema de estimativa do volume de madeira dos componentes, fuste e galhos, de árvores do Cerrado, de maneira consistente. Na estimativa da altura de árvores de *Pinus* as redes neurais artificiais apresentaram bons resultados em comparação com métodos estatísticos já utilizados para este fim. Como já era esperado, a máquina de aprendizagem extrema se mostrou mais eficiente, do ponto de vista do custo computacional, no treinamento das RNAs em relação ao algoritmo *back-propagation*, mantendo a eficácia do método. Na aplicação das RNAs ao problema de estimativa do volume dos componentes de árvores do Cerrado foi possível verificar que as redes neurais artificiais podem estimar o volume dos componentes (fuste e galhos) destas árvores. Não foi possível identificar qual é o melhor método para se estimar o volume de fuste e de galhos de árvores do Cerrado de maneira consistente, tendo em vista que, as RNAs apresentaram resultados semelhantes aos modelos de regressão estudados.

Palavras-chave: *Inteligência Computacional, Regressão, Pinus, Cerrado*

Abstract

PELLI, E. **Comparison of extreme learning machine and error backpropagation algorithms to estimate height and volume of trees.** 2013. 74 p. Dissertação - Departamento de Engenharia Florestal, Universidade Federal dos Vales do Jequitinhonha e Mucuri, Minas Gerais, 2013.

The use of the learning algorithm for artificial neural networks (ANN) feedforward, named extreme learning machine (ELM), allows the training can be done with better performance than using the traditional methods of learning based on gradient descent both in terms of generalization as learning speed. This study analyzes the application of artificial neural networks using the ELM algorithm in problems such as estimate of the height of pine trees, and also in the problem of estimating the volume of wood components, stem and twigs of trees in the Cerrado, consistently. In estimating the height of trees of *Pinus* artificial neural networks have shown good results in comparison with statistical methods already used for this purpose. As already expected, the extreme learning machine is more efficient from the point of view of computational costs, in the training of ANNs, in relation to the back-propagation algorithm, keeping the efficacy of the method. In the application of ANNs to the problem of estimating the volume of the components of the Cerrado trees it was verified that artificial neural networks can estimate the volume of components (stem and twigs) of these trees. It was not possible to identify which is the best method to estimate the volume of stem and twigs of trees of the Cerrado consistently, considering that the ANNs were similar to those studied regression models.

Keywords: *Computational Intelligence, Regression, Pinus, Cerrado*

Sumário

I	INTRODUÇÃO	1
II	USO DE MÁQUINA DE APRENDIZAGEM EXTREMA E ALGORITMO BACK-PROPAGATION NO TREINAMENTO DE REDES NEURAIS ARTIFICIAIS APLICADOS À ESTIMATIVA DA ALTURA DE <i>PINUS</i>	3
1	Introdução	4
2	Objetivos	5
3	Redes Neurais Artificiais (RNAs)	5
3.1	Topologia	6
3.2	Aprendizagem	8
3.3	Máquina de Aprendizagem Extrema (ELM)	9
4	Material e Métodos	10
4.1	Modelo Estatístico (ME)	13
4.2	Redes Neurais Artificiais	13
4.3	Avaliação dos métodos estudados	15
5	Resultados e Discussão	16
6	Conclusões	33
III	TREINAMENTO DE REDES NEURAIS ARTIFICIAIS UTILIZANDO A MÁQUINA DE APRENDIZAGEM EXTREMA PARA ESTIMAR VOLUME DE VEGETAÇÃO LENHOSA NO CERRADO <i>SENSU STRICTO</i>	34
1	Introdução	35
2	Objetivos	36
3	Material e Métodos	36
3.1	Modelos Estatísticos	41
3.2	Redes Neurais Artificiais (RNAs)	43

3.3	Avaliação dos métodos estudados	43
4	Resultados e Discussão	44
5	Conclusões	57
IV	CONSIDERAÇÕES FINAIS	58

Lista de Abreviaturas

BKP	Back-propagation
CAP	Circunferência da árvore em <i>cm</i> medido á 1,3 <i>m</i> do solo
CPU	Unidade central de processamento de um computador
DAP	Diâmetro medido a 1,3 <i>m</i>
Db	Diâmetro ao nível do solo
ELM	Máquina de aprendizagem extrema (<i>Extreme learn machine</i>)
EMQ	Erro médio quadrático
Hd	Altura das árvores dominantes
Hf	Altura comercial da árvore
Ht	Altura total da árvore
ME	Modelo estatístico hipsométrico
MLP	<i>Perceptron</i> de múltiplas camadas (<i>Multilayer Perceptrons</i>)
REG	Referência ao modelo hipsométrico estudado
RNA	Rede neural artificial
S&H	Modelo Schumacher e Hall (1933)
SLFN	Rede neural artificial de única camada oculta (<i>Single layer forward network</i>)
TR1	Etapa 1 do primeiro artigo
TR2	Etapa 2 do primeiro artigo

Lista de Figuras

1	Neurônio artificial (HAYKIN, 2001)	5
2	Exemplos de funções de ativação	6
3	Exemplo de um Rede Neural Artificial MLP (NETO, 2013)	7
4	Validação cruzada (<i>k-Fold-cross validation</i>)	8
5	Dispersão de dados de altura em relação ao DAP para cada estrato	11
6	Dispersão de dados de altura em relação ao DAP para todos os dados	11
7	Fluxograma para descrição da divisão dos grupos de dados	12
8	Definição da topologia para 80% de árvores para o treinamento de RNA por BKP	16
9	Definição da topologia para 3 árvores por parcela para o treinamento de RNA por BKP	17
10	Definição da topologia para 80% de árvores para o treinamento de RNA por ELM	18
11	Definição da topologia para 3 árvores por parcela de árvores para o treinamento de RNA por ELM	19
12	Erro médio quadrático calculado para cada uma das 50 aplicações de RNA BKP aos grupos de validação e teste, referente à etapa TR1	21
13	Erro médio quadrático calculado para cada uma das 50 aplicações de RNA ELM aos grupos de validação e teste, referente à etapa TR1	22
14	Erro médio quadrático calculado para os grupos de validação e teste para cada ajuste efetuado pelo treinamento BKP, referente a etapa TR2	24
15	Relação entre o EMQ calculado para os grupos de validação e teste para cada ajuste efetuado pelo treinamento ELM, referente a etapa TR2	25
16	Distribuição dos erros para aplicação do modelo de regressão referente a base de dados com 80% das árvores por parcela	27
17	Distribuição dos erros para aplicação do modelo de regressão referente à base de dados com 3 árvores por parcela.	29
18	Distribuição dos erros para aplicação das metodologias estudadas, referente ao treinamento efetuado com 80% dos dados.	30
19	Frequência percentual dos erros percentuais referentes às aplicações dos métodos ELM, BKP e ME, respectivamente para etapa TR1.	31
20	Distribuição dos erros para metodologia com treinamento efetuado com 3 árvores por parcela.	32
21	Frequência percentual dos erros percentuais referente às aplicações dos métodos ELM, BKP e ME, respectivamente, para etapa 2 deste estudo.	32
22	Volume em m^3 de fuste e galho para cada árvore em função do Db	37
23	Volume em m^3 de fuste e galho para cada árvore em função da altura das árvores	37
24	Volume em m^3 de fuste e galho para cada árvore em função da altura comercial .	38

25	Fluxograma para descrição da divisão dos grupos de dados	39
26	Dispersão dos dados de volume de fuste e galhos, em relação ao diâmetro de base (Db), altura total (Ht) e altura comercial (Hf), referente ao grupo de treinamento para cada combinação	40
27	Dispersão dos dados de volume de fuste e galhos, em relação ao diâmetro de base (Db), altura total (Ht) e altura comercial (Hf), referente ao grupo de validação para cada combinação	40
28	Dispersão dos dados de volume de fuste e galhos, em relação ao diâmetro de base (Db), altura total (Ht) e altura comercial (Hf), referente ao grupo de teste para cada combinação	41
29	Definição de sistema para aplicação do modelo S&H para fuste e galho.	42
30	Definição da topologia de rede para treinamento BKP	46
31	Definição da topologia de rede para treinamento ELM	46
32	Histograma dos resultados de erro médio quadrático referente à estimativa do volume de fuste para cada combinação de dados	47
33	Histograma dos resultados de erro médio quadrático referente a estimativa do volume de galhos para cada combinação dos dados	49
34	Histograma dos resultados de erro médio quadrático referente à estimativa do volume total de forma consistente para cada combinação dos dados	50
35	Dispersão de erros percentuais referentes à estimativa do volume de fuste para cada combinação dos métodos estudados	51
36	Frequência percentual dos erros percentuais referente ao uso dos métodos REG, ELM, BKP e S&H, respectivamente, para cada combinação, na estimativa do volume de fuste das árvores do Cerrado	52
37	Dispersão de erros percentuais referentes à estimativa do volume de galhos para cada aplicação dos métodos estudados	53
38	Frequência percentual dos erros percentuais referentes ao uso dos métodos REG, ELM, BKP e S&H, respectivamente, para cada combinação, na estimativa do volume de galhos das árvores do Cerrado.	54
39	Dispersão de erros percentuais referentes à estimativa do volume de forma consistente para, com cada combinação dos métodos estudados	56
40	Frequência percentual dos erros percentuais referentes ao uso dos métodos REG, ELM, BKP e S&H, respectivamente, para cada combinação, do volume total das árvores do Cerrado	57

Lista de Tabelas

1	Análise descritiva dos dados	10
2	Definição do tamanho dos grupos de dados para primeira etapa do estudo	12
3	Definição do tamanho dos grupos de dados para segunda etapa do estudo	12
4	Tempo decorrido para cálculo da definição de topologia para as RNAs	19
5	Erro médo quadrático calculado para os grupos de validação e teste para cada aplicação efetuada, referente a etapa TR1 - 80% de árvores para treinamento das RNAs	19
6	Média do EMQ e desvio padrão das 50 aplicações de RNAs BKP e ELM realizadas para etapa TR1 - 80% das árvores	21
7	Tempo para ajuste e aplicação das metodologias estudadas	22
8	Média do EMQ e desvio padrão das 50 aplicações de RNAs BKP e ELM realizadas para etapa TR2 - 3 árvores por parcela	23
9	Média e Desvio Padrão dos 50 ajustes realizados para etapa TR2 - 3 árvores por parcela	24
10	Parâmetros ajustados do modelo estatístico proposto para cada estrato referente a base de dados com 80% das árvores por parcelas	26
11	Parâmetros ajustados do modelo estatístico proposto para cada estrato com 3 árvores por parcela	28
12	Resultados por metodologia com treinamento efetuado com 80% dos dados	30
13	Erro médio quadrático calculado por metodologia referente a treinamento efetuado para 3 árvores por parcela:	31
14	Resutados de EMQ referentes a cada metodologia estudada e aumento do EMQ em % referentes à variação no tamanho do grupo de treinamento	33
15	Análise descritiva dos dados	36
16	Definição do tamanho dos grupos de dados	39
17	Parâmetros ajustados para modelo estatístico S&H proposto para dados de fuste para cada combinação:	44
18	Parâmetros ajustados para modelo estatístico S&H proposto para dados de galho para cada combinação:	45
19	Parâmetros referentes ao ajuste de modelo de regressão REG para cada combinação	45
20	Resultados de erro médio quadrático referente à estimativa do volume de fuste de árvores do Cerrado, para cada combinação dos métodos estudados	46
21	Resultados de erro médio quadrático referente à estimativa do volume de galhos de árvores do Cerrado, para cada combinação dos dados	48
22	Resultados de erro médio quadrático referente à consistência na estimativa do volume total de árvores do Cerrado, para cada combinação dos dados	49

Parte I

INTRODUÇÃO

O campo da inteligência computacional investiga formas de habilitar o computador a realizar tarefas onde o ser humano tem melhor desempenho. A evolução dos computadores nas últimas décadas, dada principalmente pelo aumento do potencial de processamento das máquinas, propiciou um novo fôlego à área da inteligência computacional, tendo em vista que, a maioria dos “agentes inteligentes” demandam alto processamento, muitas vezes em sistemas paralelos ou distribuídos.

Russell e Norvig (2003) descrevem algumas abordagens relacionadas às ferramentas da inteligência computacional, as principais são: Abordagem Simbólica, em que se tem como base a representação do mundo através de símbolos que representam conceitos. A manipulação destes símbolos permite a obtenção de conclusões e geração de novos conhecimentos sobre o mundo; Abordagem Estatística, que estuda modelos matemáticos e estatísticos para gerar novos conhecimentos; e a Abordagem Conexionista, que tem o cérebro humano como fonte de inspiração para o desenvolvimento de sistemas inteligentes.

O estudo e implementação de ferramentas da inteligência computacional podem prover redução de custos, obtenção de produtos e serviços de maior qualidade, por meio da otimização de processos e recursos. As aplicações de sistemas especialistas, contemplando ferramentas da inteligência computacional, podem resultar em empresas mais competitivas. Várias pesquisas na ciência florestal (XIAO et al., 1998; DIAMANTOPOULOU, 2005, 2006; GÖRGENS, 2006; GÖRGENS et al., 2009; SILVA et al., 2009; BINOTI, 2010; ÖZÇELİK et al., 2010; DIAMANTOPOULOU; MILIOS, 2010; SOARES et al., 2011, 2012; BINOTI, 2012) têm atentado para aplicação das ferramentas da inteligência computacional ao setor, em geral, por meio de estudos da aplicação das redes neurais artificiais à problemas ligados ao setor florestal.

Nestes estudos predomina o uso de algoritmos de treinamento de redes baseados em gradiente descendente, que demandam várias iterações para obtenção de redes treinadas, com capacidade de generalização do conhecimento. Tais algoritmos apresentam alto custo computacional, e portanto, tendem a serem lentos.

Huang et al. (2004) desenvolveram uma técnica de treinamento, chamada de máquina de aprendizagem extrema (*Extreme learn machine* - ELM), para um tipo específico de redes neurais artificiais, as feedforward de única camada escondida (*Single layer forward networks* - SLFNs). Nesta técnica, os pesos dos neurônios da camada escondida são ajustados aleatoriamente e os pesos entre a camada oculta e de saída são ajustados analiticamente. Este algoritmo tende a proporcionar bom desempenho na generalização associado a boa velocidade de aprendizagem.

Neste trabalho objetivou-se avaliar a eficácia e eficiência do treinamento de redes neurais artificiais aplicadas à problemas de estimativa de altura de árvores, implementando o algoritmo de treinamento: máquina de aprendizagem extrema (ELM). Outro objetivo deste trabalho foi estimar de forma precisa e consistente o volume de diferentes componentes de árvores do Cerrado

usando redes neurais artificiais, e comparar os resultados com métodos estatísticos tradicionais utilizados atualmente.

Este trabalho foi dividido em dois artigos, sendo que o primeiro artigo é referente ao estudo, implementação e aplicação da técnica máquina de aprendizagem extrema (ELM) na estimativa de altura de árvores de *Pinus*. Já o segundo artigo, refere-se à aplicação de redes neurais artificiais, para estimar de forma consistente os componentes, fuste e galhos, de árvores do Cerrado.

Parte II

USO DE MÁQUINA DE APRENDIZAGEM EXTREMA E ALGORITMO BACK-PROPAGATION NO TREINAMENTO DE REDES NEURAIS ARTIFICIAIS APLICADOS À ESTIMATIVA DA ALTURA DE *PINUS*

Resumo

Este trabalho teve como objetivo a avaliação do método de treinamento de redes neurais artificiais, definido como máquina de aprendizagem extrema (ELM) para estimativa de altura de árvores de *Pinus*. O treinamento ELM foi comparado com o treinamento *back-propagation* a fim de verificar a eficiência em tempo de processamento e a eficácia por meio do cálculo da estatística erro médio quadrático e análise gráfica de resíduos. Foi utilizado um modelo estatístico hipsométrico, como base de comparação entre os métodos. Foram estudadas duas formas de aplicação das metodologias, sendo a primeira etapa o estudo da aplicação dos métodos propostos sob uma base de dados em que foi analisada a medição da altura de 10 árvores por parcela; e, na segunda etapa, foi feita a aplicação dos métodos numa base de dados reduzida, utilizando-se apenas a medição da altura de 3 árvores por parcela. O método de treinamento de redes neurais artificiais ELM se mostrou apto para estimar a altura de árvores de *Pinus*, apresentando custo computacional reduzido em relação ao algoritmo de treinamento *back-propagation*. A redução da base de dados na medição de altura por parcela afetou o poder de generalização das redes neurais artificiais aumentando o erro médio quadrático na ordem de 4%, sendo que cabe aos gestores do setor florestal relacionar custo e precisão para prescrever o nível de amostragem.

Palavras-chave: *Inteligência Computacional, Regressão, Relação Hipsométrica*

Abstract

This study aimed to evaluate the method of training artificial neural networks defined as extreme learning machine (ELM) to estimate height of pine trees. The ELM training was compared with the back-propagation in order to check the efficiency in processing time and effectiveness by means of statistical calculation of RMSE and graphical analysis of residuals. We used a statistical model based on hypsometric comparison between the methods. We studied two ways of applying the methodologies, the first step to study the application of the proposed methods in a database in which we analyzed the height measurement of 10 trees per plot, and the second step was made to apply the methods a database reduced by using only the measurement of the height of three plants per plot. The training method of artificial neural networks ELM proved able to estimate the height of trees of *Pinus*, with reduced computational cost compared to the back-propagation. The reduction of the database in height measurement per plot affected the generalization of the artificial neural networks by increasing the mean square error in the order of 4%, and it is up to the managers of the forestry sector relate cost and accuracy to prescribe the level of sampling.

Keywords: *Computational Intelligence, Regression, Hypsometric relation*

1 Introdução

O setor florestal lida com o produto árvores, que, por sua vez, possuem ciclo de corte longo, em torno de 7 a 15 anos para florestas equiâneas e ciclos maiores para florestas naturais. Portanto, um bom planejamento é imprescindível para organizar a produção e obter sucesso no empreendimento florestal.

No manejo florestal é necessário o estudo de variáveis que se relacionam ao crescimento e a produção florestal. A principal variável associada à produção de um povoamento florestal, que possibilita que tal produção seja quantificada é o volume das árvores.

Para se estimar o volume de árvores individuais é necessário o conhecimento da altura total da árvore que, em associação com o diâmetro medido a 1,3 metros de altura (*DAP*) alimentam modelos estatísticos que expressam o volume de árvores do povoamento. De acordo com Mendonça et al. (2011), a relação entre o *DAP* e outras variáveis relacionadas com a altura de árvores é denominada relação hipsométrica.

O *DAP* é medido com o emprego de suta ou fita métrica de forma direta aplicada ao tronco das árvores. Já a altura (*Ht*) é medida indiretamente empregando-se hipsômetros, aparelhos que obtêm a altura por meio de relações trigonométricas, ou por meio de modelos de regressão. No caso de florestas nativas, na maioria dos inventários todas as árvores são medidas.

Atualmente a altura de árvores é estimada empregando-se modelos estatísticos, que apresentam bom nível de precisão nos resultados. Uma alternativa aos modelos de regressão é a utilização de ferramentas de inteligência computacional como, por exemplo, as redes neurais artificiais (RNAs). De acordo com Haykin (2001) as redes neurais de múltiplas camadas (MLP – *Multilayer Perceptron*) são capazes de aproximar qualquer função não-linear.

De acordo com Braga et al. (2007, p. 3) as redes neurais artificiais são:

“Sistemas paralelos distribuídos compostos por unidades de processamento simples (neurônios artificiais) que calculam determinadas funções matemáticas (normalmente não-lineares). Tais unidades são dispostas em uma ou mais camadas e interligadas por um grande número de conexões, geralmente unidirecionais. Na maioria dos modelos essas conexões estão associadas a pesos, os quais armazenam o conhecimento adquirido pelo modelo e servem para ponderar a entrada recebida por cada neurônio da rede.

A concentração de esforços na utilização das RNAs tem o foco na determinação da arquitetura de rede e topologia que melhor se adequa ao problema, e na determinação dos pesos. (SILVA et al., 2010)

Recentemente, um novo algoritmo de aprendizagem para as redes neurais de única camada escondida (SLFN - *Single layer forward network*), chamado de máquina de aprendizagem extrema (ELM), foi proposto por Huang et al. (2004, 2006). Diferentemente das abordagens tradicionais (como os algoritmos *back-propagation*), nos quais se pode enfrentar dificuldades para ajustar os parâmetros de controle, como a taxa de aprendizagem, épocas de aprendizagem etc, associados a problemas de mínimos locais. A ELM evita esses problemas e alcança boas soluções analiticamente, com velocidade de aprendizagem maior em comparação com outros métodos tradicionais.

2 Objetivos

Os objetivos deste trabalho foram:

- Avaliar o método de treinamento de redes neurais artificiais “máquina de aprendizagem extrema” (ELM), aplicado à estimativa da altura de árvores de *Pinus*
- Comparar os resultados obtidos pelo método ELM com os obtidos pelo algoritmo *back-propagation* em um problema de estimativa de altura de árvores da espécie *Pinus*.

Como objetivo secundário:

- Avaliar o tempo para o treinamento e aplicação das redes neurais artificiais no problema de estimação de altura de árvores, implementando o algoritmo de treinamento máquina de aprendizagem extrema (ELM).

3 Redes Neurais Artificiais (RNAs)

Uma Rede Neural Artificial (RNA) é um modelo computacional que foi desenvolvido por meio da abstração do funcionamento de células do cérebro humano.

De acordo com Haykin (2001), as semelhanças existentes entre as RNAs e o cérebro humano estão relacionadas ao fato do conhecimento ser adquirido por meio da experiência e pelo fato do conhecimento estar armazenado nas sinapses. Um modelo matemático baseado na estrutura de um neurônio biológico é apresentado na Figura 1.

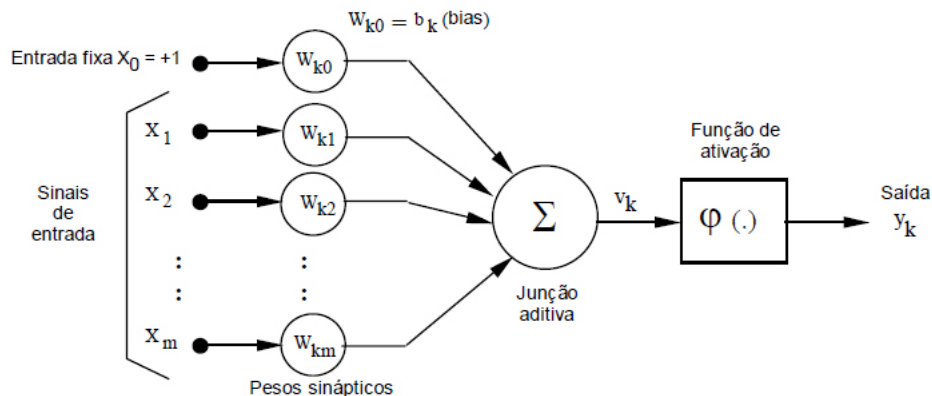


Figura 1: Neurônio artificial (HAYKIN, 2001)

Este modelo representa os pesos sinápticos pela variável “ W_{ki} ”, uma junção aditiva e uma função de ativação. Os pesos sinápticos se relacionam aos sinais de entrada que são recebidos. Os pesos associados às sinapses podem ser alterados por um processo de aprendizado (RUSSELL; NORVIG, 2003). A junção aditiva faz a soma do produto dos sinais de entrada pelos respectivos pesos que, por sua vez, alimentam a função de ativação que determina o sinal de saída.

De acordo com Braga et al. (2007), a utilização de diferentes funções de ativação possibilitam valores de saídas variados, não apenas binários, com zero ou um. Alguns modelos de funções de ativação, como função degrau (a), função sigmoideal (b) e função tangente hiperbólica (c) podem ser vistos na Figura 2.




Figura 2: Exemplos de funções de ativação

Redes neurais artificiais com apenas uma camada e um neurônio simples (*Perceptron*) podem tratar apenas casos linearmente separáveis. A maioria dos problemas reais se enquadram no tipo de problemas não-lineares. Uma estrutura de múltiplas camadas de neurônios (MLP), composta por neurônios com funções de ativação sigmoideais nas camadas intermediárias, é capaz de solucionar problemas do tipo não-linear. Assim sendo, para que a MLP seja eficaz, ela precisa ter os neurônios organizados sob uma certa arquitetura e topologia da RNA que se adeque a cada problema (SILVA et al., 2010).

3.1 Topologia

De acordo com Silva et al. (2010) a arquitetura de uma rede neural artificial define a forma que os neurônios que a compõem estão dispostos em relação aos demais, estabelecendo principalmente o direcionamento das conexões sinápticas destes neurônios.

A topologia está ligada às diferentes formas de composições estruturais que uma RNA pode assumir. Ou seja, a topologia de uma RNA condiz com a forma com que as conexões estão organizadas, levando em conta o número de neurônios nas camadas ocultas e as funções de ativação de cada neurônio. A definição da topologia pode afetar diretamente o resultado final obtido (SILVA et al., 2010).

Algumas RNAs com arquitetura do tipo *feedforward* são determinadas pela disposição dos neurônios em camadas, sendo que estas, apresentam como característica a propagação do sinal em apenas uma direção, ou seja, o sinal é propagado somente da entrada para a saída da rede. Os neurônios que compõem uma camada não mantêm ligação com outros neurônios da mesma camada (HAYKIN, 2001).

As redes neurais do tipo *Multilayer Perceptrons* (MLP), ou seja, as redes neurais com múltiplas camadas de *Perceptrons* são uma importante classe dentre as RNAs *feedforward*, por pos-

suírem a capacidade de aproximação de qualquer função contínua (CYBENKO, 1989).

As MLPs são compostas por uma camada de entrada responsável por receber os sinais de entrada, uma ou mais camadas ocultas (intermediárias), em que todos os *Perceptrons* das camadas ocultas estão interligados com todos os nós das camadas anteriores e seguintes. Por fim uma camada de saída, que apresenta o sinal computado. Os sinais de entrada se propagam da entrada para a saída, percorrendo camada por camada. Um exemplo de uma rede neural MLP pode ser visto na Figura 3 (BRAGA et al., 2007).




Figura 3: Exemplo de um Rede Neural Artificial MLP (NETO, 2013)

De acordo com Braga et al. (2007) o número de neurônios artificiais que compõem uma camada intermediária ou oculta de uma rede é dependente de vários fatores como a variação dos dados de treinamento, quantidade de ruído ou viés contido nos dados de treinamento, complexidade da função a ser aprendida e a proximidade a uma distribuição estatística dos dados para treinamento da rede.

De acordo com Silva et al. (2010) para cada tipo de problema que é plausível à utilização de redes neurais artificiais, deve ser avaliada a melhor topologia ou arquitetura que se adeque ao problema. Para se definir a topologia adequada ao problema é preciso utilizar uma metodologia de validação de modelos.

Um método de validação que pode ser utilizado na determinação da topologia e validação das RNAs é o *k-fold-cross validation* (KOHAVI, 1995; BOUCKAERT, 2003; SILVA et al., 2010). Este método implica na divisão dos dados conhecidos, em k partes iguais, é comum que $k = 10$. Então é feito um processo iterativo que determina 9 partes que definem o conjunto de treinamento e uma parte selecionada que define o conjunto de validação, conforme pode ser observado na Figura 4. Em cada passo do processo, o conjunto de validação é alternado. A cada iteração realizada são feitos “ k ” treinamentos e aplicações de cada RNA treinada ao grupo de validação. Depois é calculado e armazenado o erro médio quadrático referente à cada aplicação de topologias testadas. Como resultado, para cada topologia testada são obtidos “ k ” vetores contendo “ k ” erros médios quadráticos (EMQ) computados para cada iteração.

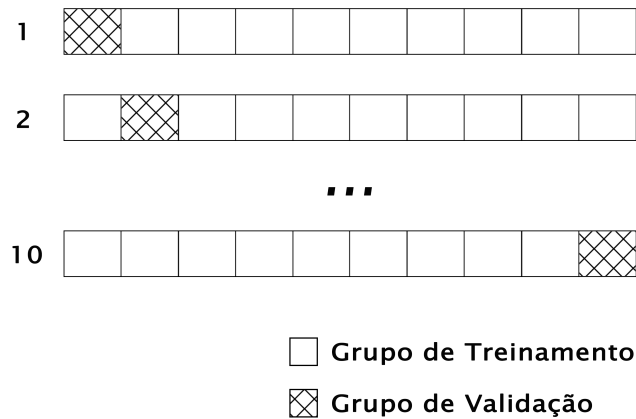


Figura 4: Validação cruzada (*k-Fold-cross validation*)

A determinação da topologia se dá pelo menor EMQ médio, associado ao desvio padrão dos erros.

Após a topologia ser definida são feitos treinamentos da RNA com essa topologia. E assim sendo, é preciso escolher qual é a melhor rede treinada. Devido as RNAs serem da categoria de algoritmos chamados de heurísticas, a cada treinamento é obtido um resultado diferente. O que se espera é que seja escolhida a RNA com maior precisão na generalização.

Uma vez de posse da rede treinada é esperado que esta seja capaz de aproximar ao máximo as saídas a serem geradas, de acordo com a generalização contida na base de dados. Assim sendo, valores que apresentam características semelhantes a uma entrada específica da base de dados irão obter resultados equivalentes aos que foram definidos no treinamento, para aquela entrada. Assim sendo, as RNAs por meio de uma generalização do conhecimento são capazes de estimar soluções que até então eram desconhecidas (SILVA et al., 2010).

3.2 Aprendizagem

Uma rede neural artificial é capaz de gerar conhecimento a partir de um processo de aprendizagem. Este processo é feito de forma que os neurônios artificiais são agrupados em camadas estruturadas. A partir deste ponto cada neurônio em cada camada aplica uma função de ativação nos sinais recebidos vindos de camadas anteriores. Esta função é responsável pela determinação do valor de ativação de cada neurônio.

O processo de treinamento de uma rede neural artificial consiste em encontrar valores para os pesos relativos às conexões entre os neurônios, que mais aproximem a RNA de obter resultados mais precisos. A maneira como os pesos são ajustados é determinada por um algoritmo de treinamento.

O treinamento das RNAs pode ser realizado por meio do aprendizado supervisionado ou do aprendizado não supervisionado.

O aprendizado supervisionado da RNA tem como premissa um conjunto de dados de entradas

com saídas equivalentes conhecidas. A partir de uma entrada que alimenta a rede, um sinal é percorrido por todos os nós até gerar uma saída, que é então comparada com o valor esperado. O ajuste dos pesos é feito por meio da minimização do erro calculado entre a saída gerada e a esperada. O algoritmo mais utilizado para efetuar o aprendizado supervisionado em RNAs do tipo MLP é o *back-propagation* (HAYKIN, 2001).

Já no aprendizado não supervisionado a rede não mantém padrões de comparação para se obter a saída desejada. Este tipo de treinamento pode ser efetuado por reforço, mantendo interações com o ambiente ou de forma auto-organizada, onde os pesos são ajustados por meio de regras de medida de qualidade. Os algoritmos de aprendizado não supervisionado mais utilizados são: Algoritmo de Hopfield e Mapas de Kohonen (HAYKIN, 2001).

Um algoritmo popular que faz o treinamento de uma rede é conhecido por retropropagação do erro (*error back-propagation*), onde o treinamento é feito de forma supervisionada. Este algoritmo é baseado em regras de aprendizagem que propiciam um melhor ajuste, avaliando o erro e tentando corrigi-lo (RUMELHART; MCCLELLAND, 1986).

3.3 Máquina de Aprendizagem Extrema (ELM)

O método de treinamento conhecido como máquina de aprendizagem extrema, ou *extreme learn machine* (ELM) foi proposto por Huang et al. (2004, 2006) como uma nova abordagem para se treinar uma rede neural artificial. Neste método não é necessário o ajuste manual de parâmetros de controle das RNAs, como taxa de aprendizagem, número de iterações e performance relacionada a critérios de parada como EMQ associado a cada problema. A aplicação da ELM também resolve o problema dos mínimos locais em relação ao algoritmo *back-propagation*, sendo que o método ELM não é baseado nas teorias de gradiente descendente.

A ELM pode ser aplicada às redes neurais artificiais do tipo *feedforward* com apenas uma camada oculta de neurônios (*single layer forward networks* SLFNs). O processo de ajuste de pesos não é feito na camada oculta, e sim numa camada intermediária, entre a camada oculta e a camada de saída. (HUANG et al., 2004, 2006) Os pesos dos neurônios da camada oculta são calculados de forma aleatória, independentemente dos dados de treinamento. A ELM tem foco em atingir um erro de treinamento menor, tal como, uma menor norma de pesos de saída. Tal implicação reduz o tempo computacional pois os pesos passam a ser ajustados por mínimos quadrados diretamente.

De acordo com Huang et al. (2006) ao se treinar uma SLFNs com K neurônios na camada oculta e função de ativação $g(x)$ e com conjunto de dados de entrada a se aprender com N amostras distintas (x_i, t_i) , sendo $x_i = [x_{i1}, x_{i2}, \dots, x_{in}]^T \in R^n$ e $t_i = [t_{i1}, t_{i2}, \dots, t_{in}]^T \in R^m$, se os pesos de entradas e o bias da camada oculta forem gerados aleatoriamente, o sistema não-linear é convertido para um sistema linear descrito na equação abaixo:

$$\mathbf{H}\beta = \mathbf{T} \quad (1)$$

Em que: $\mathbf{H} = h_{ij}(i = 1, \dots, N \text{ e } j = 1, \dots, K)$ ou seja, a matriz de saída da camada oculta, $h_{ij} = g(w_j \cdot x_i + b_j)$ referente à saída do j -ésimo neurônio da camada oculta relacionado a x_i ; $w_i = [w_{i1}, w_{i2}, \dots, w_{in}]^T$ é o vetor de pesos das conexões do j -ésimo neurônio da camada oculta e os neurônios de entrada; b_j é referente ao bias de j -ésimo neurônio da camada oculta; $\beta_i = [\beta_1, \beta_2, \dots, \beta_K]^T$ denota o vetor de pesos que conectam o j -ésimo neurônio da camada oculta e os neurônios da camada de saída da rede; $\mathbf{T} = [t_1, t_2, \dots, t_n]^T$ é o vetor referente às saídas desejadas.

Desta forma, os valores dos pesos entre a camada oculta e a camada de saída podem ser obtidos por meio do método de mínimos quadrados. A norma mínima dos mínimos quadrados que é a solução da Equação 1 é dada por:

$$\hat{\beta} = \mathbf{H}^\dagger \mathbf{T} \quad (2)$$

Em que: \mathbf{H}^\dagger é a matriz pseudo-inversa generalizada (Matriz inversa generalizada de *Moore-Penrose*) de \mathbf{H} (RAO; MITRA, 1971).

4 Material e Métodos

Os dados utilizados neste estudo foram obtidos a partir de um inventário florestal realizado em povoamentos de *Pinus*, localizados na região norte do Estado de Minas Gerais, pertencentes a empresa PITANGUI AGRO FLORESTAL LTDA. A população de 16.864,56 *ha* foi subdividida com base no material genético, na idade e na região, resultando em 34 estratos. Foram instaladas 679 parcelas retangulares de 600 m^2 . Em cada parcela foram medidas as circunferências a 1,30 *m* (*CAP*) de todas as árvores, a altura total (*Ht*) de aproximadamente 17% do número de árvores (10 árvores por parcela) e a altura total de 6 árvores dominantes. A altura total das demais árvores das parcelas foram estimadas por meio de modelos hipsométricos.

Tabela 1: Análise descritiva dos dados

Variável	Mínimo	Máximo	Média	Desvio Padrão
Altura(<i>m</i>)	4.0	32.5	17.1	4.5
DAP(<i>cm</i>)	5.4	47.4	22.6	6.3
Altura Dominante(<i>m</i>)	5.5	30.9	18.1	4.3

Foi efetuada a consistência dos dados e a disposição destes foi feita em estratos pré-definidos, conforme apresentado na Figura 5. Foram utilizadas neste estudo 621 parcelas das 679 parcelas medidas. Foram consideradas árvores com altura igual ou superior a 4 *m*. Parcelas com medição da altura de menos de 8 árvores também foram removidas da base de dados, para evitar testes em parcelas com pouca informação.




Figura 5: Dispersão de dados de altura em relação ao DAP para cada estrato

A nuvem de dados de todos os estratos em conjunto pode ser vista na Figura 6.




Figura 6: Dispersão de dados de altura em relação ao DAP para todos os dados

Os dados obtidos da medição de altura dos 34 estratos foram divididos aleatoriamente em três conjuntos. A definição do tamanho dos grupos foi realizada de modo empírico, determinando o número mínimo de árvores clones de *Pinus* para se treinar adequadamente uma rede neural artificial a fim de se prever a altura das demais árvores de um povoamento desta espécie. Cabe ressaltar que a coleta desta base de dados não foi planejada para o uso direto de RNAs, e foi ajustada para a utilização neste estudo. No planejamento para utilização das RNAs deve ser considerada a coleta de um percentual extra de dados destinados à validação do modelo a ser utilizado.

Os dados primeiramente foram aleatorizados e divididos seguindo o esquema mostrado na Figura 7.

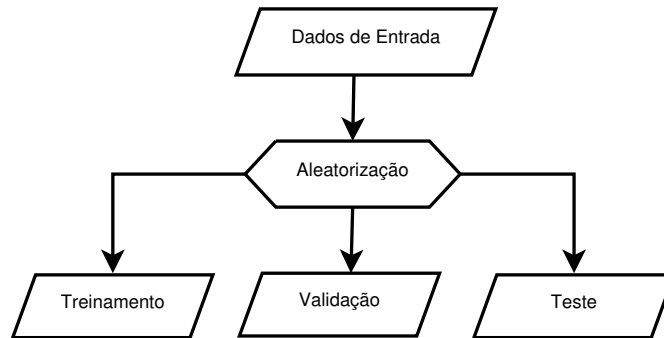


Figura 7: Fluxograma para descrição da divisão dos grupos de dados

O grupo de treinamento foi utilizado no ajuste do modelo estatístico e como base para o treinamento das RNAs. O grupo de validação foi utilizado para escolha das melhores RNAs treinadas, tal como a definição das topologias das redes. O grupo de teste foi determinado para se efetuar a comparação direta entre os métodos estudados, ou seja, para aplicação dos modelos estatísticos e RNAs treinadas.

A metodologia proposta foi dividida em duas etapas, nas quais foram realizadas duas divisões de dados:

- Primeira etapa (TR1): Na primeira etapa, foi realizada a divisão dos dados, perfazendo 80% das árvores por estrato para o grupo de treinamento, 10% para o grupo de validação e 10% para o grupo de testes. Cabe salientar que a divisão dos dados foi feita de modo aleatória, visando reduzir o risco de obter amostras tendenciosas.

Como os dados foram estratificados em 34 partes, para manter a coerência na divisão dos dados, foi mantida a proporção de divisão dentro de cada estrato.

Na Tabela 2 pode ser visto o número de árvores definido para cada grupo de dados.

Tabela 2: Definição do tamanho dos grupos de dados para primeira etapa do estudo

Grupo	%	Nº de árvores
Treinamento	80	6.145
Validação	10	788
Teste	10	788

- Segunda etapa (TR2): Foram mantidos os grupos de teste e validação com os mesmos dados. Foi então, realizada uma nova divisão do grupo de treinamento, de forma que fosse selecionada aleatoriamente 3 árvores por parcela que compunha este grupo de dados.

O grupo de teste permaneceu inalterado para que fosse verificada uma comparação consistente entre as metodologias estudadas.

A nova definição do tamanho dos grupos de dados pode ser vista na Tabela 3.

Tabela 3: Definição do tamanho dos grupos de dados para segunda etapa do estudo

Grupo	%	Nº de árvores
Treinamento	80(3 árvores/parcela)	1863
Validação	10	788
Teste	10	788

Para cada uma das etapas da metodologia foram efetuados ajustes de modelo estatístico por estrato, determinação das melhores topologias para as RNAs BKP e ELM validadas pelo grupo de validação. Foram então aplicados os modelos estatísticos ajustados, e as melhores RNAs BKP e ELM sob o grupo de teste, sendo comparados os resultados obtidos por cada aplicação.

4.1 Modelo Estatístico (ME)

Existem vários modelos para expressar a altura de árvores. Campos e Leite (2013) relatam que o Modelo 3 é frequentemente utilizado no inventário contínuo de plantações de *Pinus*.

$$Ht = e^{(\beta_0 + \beta_1 \frac{1}{DAP} + \beta_2 \ln Hd)} \times \varepsilon \quad (3)$$

Sendo:

Ht = altura da árvore;

DAP = diâmetro da árvore medido a 1,3 m de altura;

Hd = altura dominante média da parcela;

β_i = parâmetros de ajuste da equação;

\ln = logaritmo neperiano;

ε = erro associado ao ajuste.

Este modelo foi utilizado como base de comparação para a aplicação das metodologias de RNAs utilizadas.

Para cada estrato foi averiguado um ajuste de parâmetros deste modelo, visando obter resultados compatíveis com a metodologia tradicional utilizada em inventários florestais.

Os dados utilizados no ajuste de cada equação foi referente ao grupo de treinamento de cada etapa do estudo, primeiramente, com 80% das árvores de cada estrato, e posteriormente, com 3 árvores por parcela contida em cada estrato, pertencente ao grupo de treinamento.

4.2 Redes Neurais Artificiais

Neste estudo, foram utilizadas as RNAs com mais de uma camada de neurônios artificiais (Multi Layer Perceptron - MLP), sendo que estas demonstraram a obtenção de bons resultados no uso em alternativa a modelos estatísticos. (XIAO et al., 1998; DIAMANTOPOULOU, 2005, 2006; GÖRGENS et al., 2009; SILVA et al., 2009; ÖZÇELİK et al., 2010; DIAMANTOPOULOU; MILIOS, 2010; SOARES et al., 2011, 2012)

Foram utilizados dois procedimentos de treinamento das RNAs: o Extreme Learn Machine e o *back-propagation*.

Para se obterem melhores ajustes das RNAs, foram feitos 50 treinamentos para cada método, sendo escolhidos os que apresentaram menor EMQ calculado, quando aplicados ao grupo de validação.

A organização dos dados para entrada nas redes foi feita de acordo com o esquema apresentado a seguir, em que a variável alvo é a altura da árvore (Ht).

Alvo	Numérica	Numérica	Categórica
Ht	DAP	Hd	$Estrato$

Sendo:

Ht = Altura da árvore;

DAP = Diâmetro medido à 1,3 m de altura;

Hd = Altura dominante média da parcela;

$Estrato$ = Variável categórica, entrada binária com 6 dígitos.

Os dados foram normalizados com desvio padrão 1 e média 0, colocando-se os dados em uma mesma escala, visando à melhoria da capacidade de estimativa das RNAs (WRAY et al., 1994). Apenas a variável alvo não foi normalizada, tendo em vista que esta não participa diretamente do treinamento. A saída da RNA é comparada com a variável alvo para determinação e minimização do erro, em busca do melhor ajuste.

Foi realizada a validação cruzada utilizando o método *K-fold* para se obter as topologias de RNAs mais adequadas ao problema, tanto para as RNAs treinadas pelo algoritmo *back-propagation* (BKP), quanto para a máquina de aprendizagem extrema (ELM).

Na validação cruzada das RNAs utilizando-se o treinamento BKP o número de neurônios na camada oculta foi variado de 1 até 20. Para a definição da topologia da RNA utilizando-se o treinamento ELM, o número de neurônios na camada oculta foi variado de 20 até 300 na camada oculta. Pois de acordo com Huang et al. (2004) a ELM necessita um número maior de neurônios na camada oculta em relação ao *back-propagation* para utilização adequada deste método.

De posse da melhor topologia, escolhida na validação cruzada, foram treinadas um número de 50 redes utilizando o treinamento BKP e 50 utilizando a ELM.

Para definir qual RNA seria utilizada, após a definição da topologia, foi novamente utilizado o grupo de validação, sendo que a rede que retornou o menor EMQ calculado, quando aplicado ao grupo de validação, foi definida como melhor rede treinada. A melhor rede treinada foi aplicada ao grupo de teste.

Os parâmetros de configuração da RNA, utilizando o algoritmo de treinamento BKP, foram definidos da seguinte maneira: o ponto de parada do treinamento foi definido para valores de EMQ abaixo que 0,1 e para cada treinamento foram definidas um número máximo de 100 iterações do algoritmo *back-propagation*; a taxa de aprendizado foi definida como 0,001.

A função de ativação utilizada na configuração das RNAs, nos treinamentos BKP e ELM foi a sigmoideal na camada oculta. Foram feitos testes iniciais com outras funções de ativação e a sigmoideal apresentou melhores resultados.

Foram avaliados os tempos dos processamentos para obtenção da topologia mais adequada, e da definição do melhor modelo.

4.3 Avaliação dos métodos estudados

Para se efetuar a comparação entre os métodos estudados, foram utilizadas análises de gráficos de dispersão dos erros percentuais, frequência de erros, assim como a estatística erro médio quadrático (EMQ):

$$EMQ = \frac{1}{n} \sum_{i=0}^n (y_{est} - y_{obs})^2 \quad (4)$$

O cálculo da dispersão dos erros percentuais foi feita utilizando-se a Equação 5

$$E_{\%} = \frac{(y_{est} - y_{obs})}{y_{obs}} \times 100 \quad (5)$$

Para o processamento de cálculos, estatísticas e análises gráficas foi utilizado o *Software* MATLAB 2012. (MATHWORKS, 2013)

Todas as simulações e cálculos de tempo foram realizadas em ambiente MATLAB 2012 executado em um computador Intel Core i5, com CPU de 2.3GHz

5 Resultados e Discussão

O resultado da validação cruzada para a primeira etapa do estudo TR1, utilizando-se o método de treinamento BKP é apresentado na Figura 8.




Figura 8: Definição da topologia para 80% de árvores para o treinamento de RNA por BKP

A partir de 5 neurônios na camada escondida ocorreu uma estabilização do EMQ referente à variação das topologias de RNA aplicadas para os treinamentos. A topologia de RNA com 17 neurônios na camada escondida se apresentou com menor EMQ calculado, em média, e com desvio padrão menor que as outras topologias testadas. Por se tratar de heurísticas, as topologias de rede com mais de 5 neurônios na camada escondida podem ser consideradas como adequadas para este problema específico.

Ao se efetuar a validação cruzada utilizando-se o método de treinamento BKP sob os dados com 3 árvores por parcela, foi averiguada uma estabilização de neurônios em torno 4 e 10 na camada escondida. Foi escolhida a topologia com 5 neurônios na camada escondida para este estudo. Como foram utilizadas menos árvores do que na etapa anterior, houve uma pequena instabilidade nos testes da validação cruzada, o que se deve ao fato de generalização mais dificultada, em reação ao montante completo de dados da etapa TR1. Tal instabilidade pode ser visualizada na Figura 9.




Figura 9: Definição da topologia para 3 árvores por parcela para o treinamento de RNA por BKP

A topologia para RNA, utilizando-se o treinamento ELM foi definida com 145 neurônios na camada escondida, para etapa TR1 deste estudo, de acordo com a aplicação da validação cruzada. Huang et al. (2004) descreveram que as RNAs treinadas com ELM necessitam de um número maior de neurônios na camada escondida em relação ao algoritmo *back-propagation*, sendo que o número de neurônios da camada oculta deve ser menor ou igual ao número de amostras de treinamento. Assim sendo, foi realizada uma variação do número dos neurônios da camada oculta iniciando-se de 20 até 300, variando com passo de 2 a 2 neurônios.

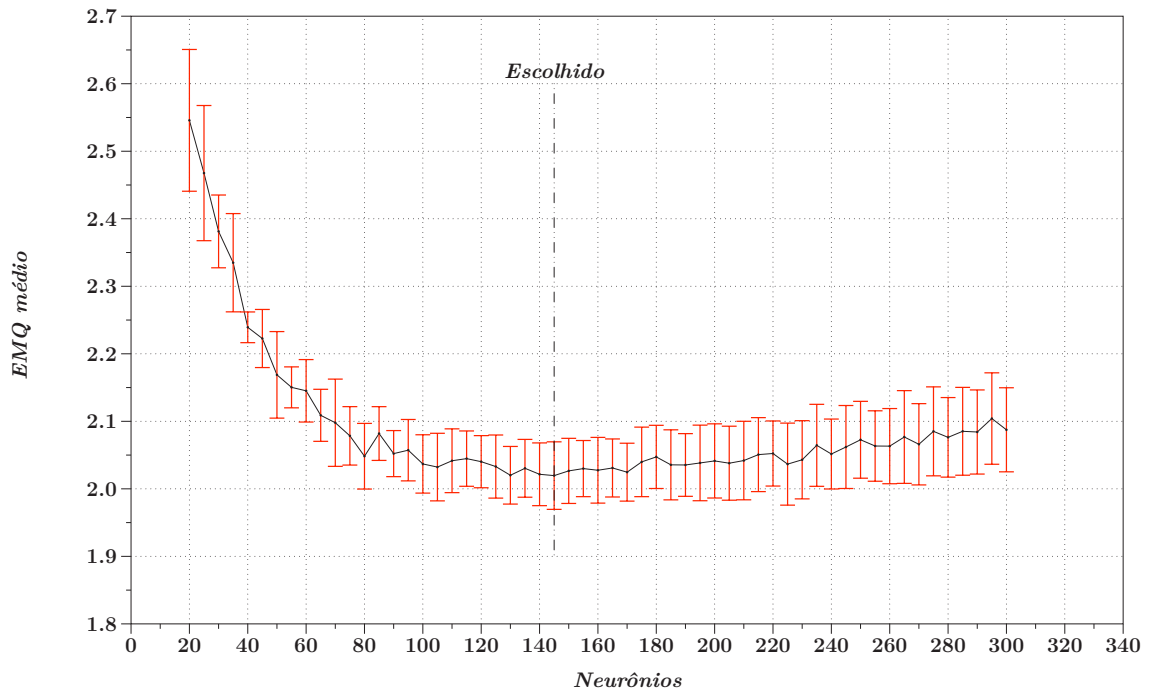


Figura 10: Definição da topologia para 80% de árvores para o treinamento de RNA por ELM

Pôde-se perceber uma estabilização na curva de relação entre o EMQ médio e número de neurônios, a partir de 100 neurônios. Ao se analisar o resultado da validação cruzada, foi possível observar na Figura 10 uma constância no desvio padrão para cada teste *K-Fold*, o que denota boa confiança na utilização deste método.

Na Figura 11 é apresentada a validação cruzada para a segunda etapa do estudo TR2, utilizando-se o método de treinamento ELM. Assim como no treinamento das RNAs por BKP, foi possível constatar um aumento do EMQ médio em topologias que apresentavam a partir de 140 neurônios na camada escondida. Tal como para o treinamento BKP, essa inconsistência é derivada da diminuição do número de árvores por parcela.

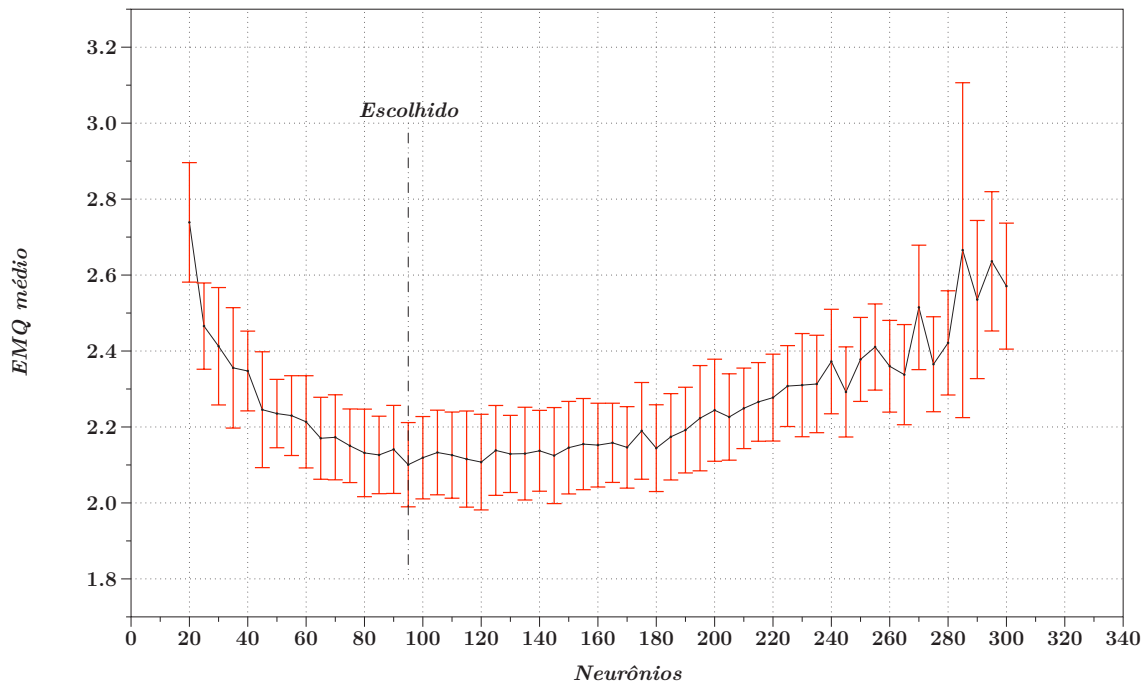


Figura 11: Definição da topologia para 3 árvores por parcela de árvores para o treinamento de RNA por ELM

Com menos árvores, a aplicação da validação cruzada determinou um número menor de neurônios na camada escondida. A topologia de RNA utilizando-se o treinamento ELM foi determinada por este método com 95 neurônios na camada escondida.

Ao se avaliar o tempo computado para se efetuar a validação cruzada na definição das topologias de RNAs com os treinamentos BKP e ELM, foi possível perceber que o treinamento ELM apresentou-se muito mais rápido do que o treinamento por BKP, como pode ser visto na Tabela 4.

Tabela 4: Tempo decorrido para cálculo da definição de topologia para as RNAs

	TR1	TR2	Nº de Ajustes	TR1 médio	TR2 médio
ELM	02m:25s	01m:25s	560	0,260s	0,152s
BKP	12m:55s	09m:51s	200	3,875s	2,955s

Como foi realizado um número de treinamento de RNAs diferente, entre os métodos BKP e ELM, foi feita também a estimativa do tempo médio para a aplicação dos métodos de treinamento. O treinamento de RNAs utilizando-se a ELM apresentou-se muito mais rápido do que o BKP, conforme apresentado em outros estudos (HUANG et al., 2004, 2006; FENG et al., 2009).

Foram feitos 50 treinamentos para cada método estudado, ELM e BKP. Os resultados referentes ao EMQ da melhor rede ajustada, aplicada ao grupos de teste e validação, podem ser vistos na Tabela 5. Este processo é conhecido como validação da RNA, ou seja, processo de escolha da RNA que será aplicada ao grupo de teste. Essa escolha se dá pela aplicação do treinamento de RNA que apresentou menor EMQ, quando aplicada ao grupo de validação.

Tabela 5: Erro médo quadrático calculado para os grupos de validação e teste para cada aplicação efetuada, referente a etapa TR1 - 80% de árvores para treinamento das RNAs

<i>Apliação</i>	ELM		BKP	
	<i>Validação</i>	<i>Teste</i>	<i>Validação</i>	<i>Teste</i>
1	2.03350	1.96449	2.10680	2.02368
2	2.02062	1.94316	2.04865	1.98807
3	2.03493	1.95693	2.03803	1.97448
4	2.00789	1.96338	2.02117	1.96491
5	2.01063	1.98827	2.03861	1.95144
6	2.03726	2.00443	2.02838	1.96935
7	2.03535	1.97077	2.05857	2.03949
8	2.05441	1.97399	2.05316	1.97473
9	2.00707	1.99186	2.10545	1.99220
10	2.02519	1.94926	2.09880	2.03176
11	2.04817	1.99891	2.01677	1.98840
12	1.98958	1.99774	2.05251	1.97317
13	2.01296	1.96360	2.07579	2.00710
14	2.02537	1.98631	2.03551	1.94341
15	2.02721	1.95486	2.00656	1.94491
16	2.03479	1.93218	2.07701	1.94545
17	2.00887	1.95920	2.02771	1.98063
18	2.03118	1.94657	2.04823	1.96481
19	1.99116	1.94428	1.99769	1.95180
20	1.99913	1.99324	2.04357	2.01663
21	2.01494	1.96777	2.04920	1.96924
22	2.01698	2.01184	2.08358	2.01303
23	2.05996	1.99457	2.09201	1.97146
24	1.99977	1.96495	2.02336	1.96405
25	2.00833	1.96359	2.04296	1.99836
26	2.01072	1.95004	2.01253	1.94172
27	1.98371	1.96677	2.10852	1.98410
28	2.03793	2.00010	2.04287	2.00127
29	2.01121	1.94490	2.01397	1.96121
30	2.01810	1.94533	2.09307	1.99676
31	2.03207	1.94144	2.04867	1.97714
32	1.99951	1.99647	2.05240	1.99140
33	2.01461	1.98003	2.05973	2.02357
34	2.00475	1.97799	2.02977	1.96646
35	2.00832	1.96983	2.07069	1.98565
36	2.01054	1.96372	2.07690	1.97424
37	2.03158	1.95662	2.08760	1.98847
38	2.05750	1.98135	2.05554	1.99206
39	2.00637	2.00947	2.06788	1.91198
40	1.99613	1.94532	2.07913	1.95074
41	2.05077	1.98883	2.08543	1.98504
42	2.01023	1.93932	2.07399	1.96954
43	2.01028	1.94322	2.07482	2.03198
44	2.02080	1.93589	2.03329	2.03579
45	2.00521	1.95700	2.02353	1.99573
46	2.01209	1.97651	2.05354	2.00284
47	2.02331	2.00603	2.01255	1.95332
48	2.03072	1.96511	2.04372	1.98677
49	2.01808	1.98445	2.01237	1.95157
50	2.02195	1.98507	2.01255	1.96134

Em uma situação real, o grupo de teste não é conhecido previamente. Assim sendo, a escolha da melhor rede treinada se dá pelo grupo de validação. Podemos observar que a RNA, utilizando-se treinamento ELM, que melhor se ajustou ao grupo de teste foi a RNA treinada referente a aplicação 16, mesmo assim, por se tratar de um estudo com caráter prático, foi definida como RNA ELM escolhida a rede referente à aplicação 27, por apresentar o menor valor de EMQ ao ser aplicada ao grupo de validação.

As estatísticas média e desvio padrão referentes ao EMQ calculados por meio das 50 aplicações das melhores topologias RNAs BKP e ELM, podem ser vistas na Tabela 6.

Tabela 6: Média do EMQ e desvio padrão das 50 aplicações de RNAs BKP e ELM realizadas para etapa TR1 - 80% das árvores

	<i>ELM</i>		<i>BKP</i>	
<i>EMQ</i>	<i>Validação</i>	<i>Teste</i>	<i>Validação</i>	<i>Teste</i>
<i>Média</i>	2,0160	1,9659	2,0489	1,9789
<i>Desvio Padrão</i>	0,0173	0,0215	0,0289	0,0274

Os treinamentos de RNAs por ELM e BKP apresentaram resultados de generalização muito semelhantes, tanto para a média, quanto para o desvio padrão. Este fato denota que as duas técnicas podem ser utilizadas para estimar a altura de árvores, possuindo um bom nível de precisão e adaptação ao problema, devido ao baixo valor do desvio padrão.

A relação entre os ajustes das RNAs treinadas por BKP, aplicadas aos grupos de validação e teste, pode ser vista na Figura 12, em que é possível verificar uma tendência similar entre o EMQ calculado para validação e teste.




Figura 12: Erro médio quadrático calculado para cada uma das 50 aplicações de RNA BKP aos grupos de validação e teste, referente à etapa TR1

Após se realizar as 50 aplicações da topologia escolhida para os treinamentos das RNAs por

ELM, foi possível verificar que a disposição dos EMQs calculados para os grupos de validação e teste obtiveram tendências similares aos dos treinamentos por BKP, permitindo a validação do modelo por esta técnica. Na Figura 15 são apresentados os EMQs referentes às 50 aplicações do treinamento ELM aos grupos de validação e teste.




Figura 13: Erro médio quadrático calculado para cada uma das 50 aplicações de RNA ELM aos grupos de validação e teste, referente à etapa TR1

Ao se comparar o tempo de ajuste e aplicação para a etapa TR1, pode-se observar um ganho de tempo muito grande com o uso do treinamento ELM, em relação ao algoritmo BKP. Na Tabela 7 é apresentado o cálculo do tempo para cada método utilizado.

Tabela 7: Tempo para ajuste e aplicação das metodologias estudadas

	TR1	TR2
ELM	00m:18s	00m:07s
BKP	7m:23s	03m:41s

Para se realizarem os ajustes e aplicar os modelos estatísticos ajustados, foi apenas necessário 0,65 segundos. Ou seja, o ME apresentou-se como método mais rápido, contando com a vantagem de não ser necessário, neste caso, o emprego de técnicas de validação, como no caso das RNAs.

O mesmo processo de validação, ou seja, a escolha da melhor RNA treinada da topologia escolhida, que foi aplicada ao grupo de teste, foi realizado da mesma forma para segunda etapa do estudo TR2, em que foram utilizadas apenas 3 árvores por parcela no treinamento das RNAs.

O resultado dos 50 treinamentos para cada método estudado, referente ao EMQ da melhor rede ajustada aplicada ao grupo de teste e validação para etapa TR2 deste estudo pode ser visto na Tabela 8.

Tabela 8: Média do EMQ e desvio padrão das 50 aplicações de RNAs BKP e ELM realizadas para etapa TR2 - 3 árvores por parcela

<i>Aplicação</i>	ELM		BKP	
	<i>Validação</i>	<i>Teste</i>	<i>Validação</i>	<i>Teste</i>
1	2.21631	2.16167	3.35833	2.98447
2	2.16548	2.14745	2.20373	2.12790
3	2.17546	2.11224	2.18905	2.07714
4	2.16727	2.15728	2.19228	2.16186
5	2.13450	2.14706	2.15783	2.09800
6	2.19119	2.13299	2.28812	2.07697
7	2.12723	2.09087	2.15175	2.09526
8	2.13666	2.15421	2.15520	2.09513
9	2.19960	2.08351	2.21602	2.08668
10	2.11712	2.12870	2.18134	2.06380
11	2.12144	2.13138	2.21543	2.06097
12	2.17078	2.12634	2.17907	2.07239
13	2.13675	2.07502	2.14619	2.03007
14	2.16444	2.12553	2.15144	2.13365
15	2.22559	2.12094	2.18154	2.09457
16	2.24853	2.19550	2.21595	2.09467
17	2.19432	2.10892	7.53378	6.62887
18	2.20020	2.13392	2.15976	2.13156
19	2.22950	2.11889	2.17978	2.05705
20	2.13421	2.14109	2.18810	2.05603
21	2.19980	2.09425	2.23782	2.24761
22	2.12128	2.16692	2.20652	2.16337
23	2.13653	2.14220	2.19930	2.11375
24	2.21557	2.08278	2.15940	2.10975
25	2.22387	2.10527	2.17002	2.11329
26	2.18698	2.15794	2.16630	2.07812
27	2.19294	2.15459	2.19258	2.09905
28	2.20214	2.17686	2.14734	2.08205
29	2.13598	2.04454	2.13991	2.14725
30	2.16203	2.19463	2.18409	2.08631
31	2.20331	2.10316	2.26865	2.19657
32	2.20567	2.10478	2.16858	2.07235
33	2.20551	2.09823	2.13565	2.02567
34	2.15116	2.10327	2.18182	2.04051
35	2.18318	2.05579	2.16517	2.08270
36	2.19731	2.15417	2.18359	2.09601
37	2.20339	2.08892	2.19015	2.17687
38	2.17121	2.12664	2.21239	2.05026
39	2.19679	2.15268	2.17599	2.06756
40	2.16755	2.11097	2.19018	2.05960
41	2.19125	2.13129	2.19170	2.09011
42	2.17493	2.12082	2.17319	2.09581
43	2.19962	2.18111	2.17405	2.11104
44	2.18695	2.16074	2.15335	2.03662
45	2.18165	2.13380	2.21062	2.12138
46	2.16998	2.13351	2.24486	2.09110
47	2.16463	2.10973	2.20246	2.13010
48	2.11605	2.05267	2.18636	2.08802
49	2.18571	2.08547	2.16660	2.07969
50	2.15096	2.17908	2.14269	2.08833

Foi percebido um aumento do EMQ para os dois métodos estudados, referentes à diminuição do grupo de treinamento, tornando a generalização mais difícil.

A seguir, na Tabela 9, são apresentadas as estatísticas média e desvio padrão referentes aos 50 treinamentos das melhores topologias RNAs BKP e ELM aplicadas na segunda etapa deste estudo (TR2).

Tabela 9: Média e Desvio Padrão dos 50 ajustes realizados para etapa TR2 - 3 árvores por parcela

	<i>ELM</i>		<i>BKP</i>	
<i>EMQ</i>	<i>Validação</i>	<i>Teste</i>	<i>Validação</i>	<i>Teste</i>
<i>Média</i>	2.1824	2.1277	2.1827	2.0928
<i>Desvio Padrão</i>	0.0322	0.0350	0.7640	0.6454

Ao se avaliar a média e o desvio padrão das 50 aplicações com um grupo reduzido de dados no treinamento, foi possível verificar que o treinamento ELM se mostrou com um resultado de EMQ médio pior que o BKP, na aplicação das RNAs treinadas ao grupo de teste. Mas o ELM obteve melhor consistência na aplicação TR2, com a base de dados reduzida, em relação ao BKP que apresentou um maior desvio padrão.

Tal inconsistência referente à aplicação do treinamento BKP para RNAs pode ser avaliado na Figura 14.




Figura 14: Erro médio quadrático calculado para os grupos de validação e teste para cada ajuste efetuado pelo treinamento BKP, referente a etapa TR2

Como pode ser visto na Figura 15, o treinamento de RNA utilizando-se ELM para um grupo

reduzido de árvores TR2, se apresentou com boa consistência. Cabe ressaltar que as linhas do EMQ, entre as aplicações nos grupos de validação e teste, começaram a se cruzar, o que aponta uma maior dificuldade relacionada ao problema, que está associada à menor base de dados para treinamento dificultando assim, a generalização das RNAs.

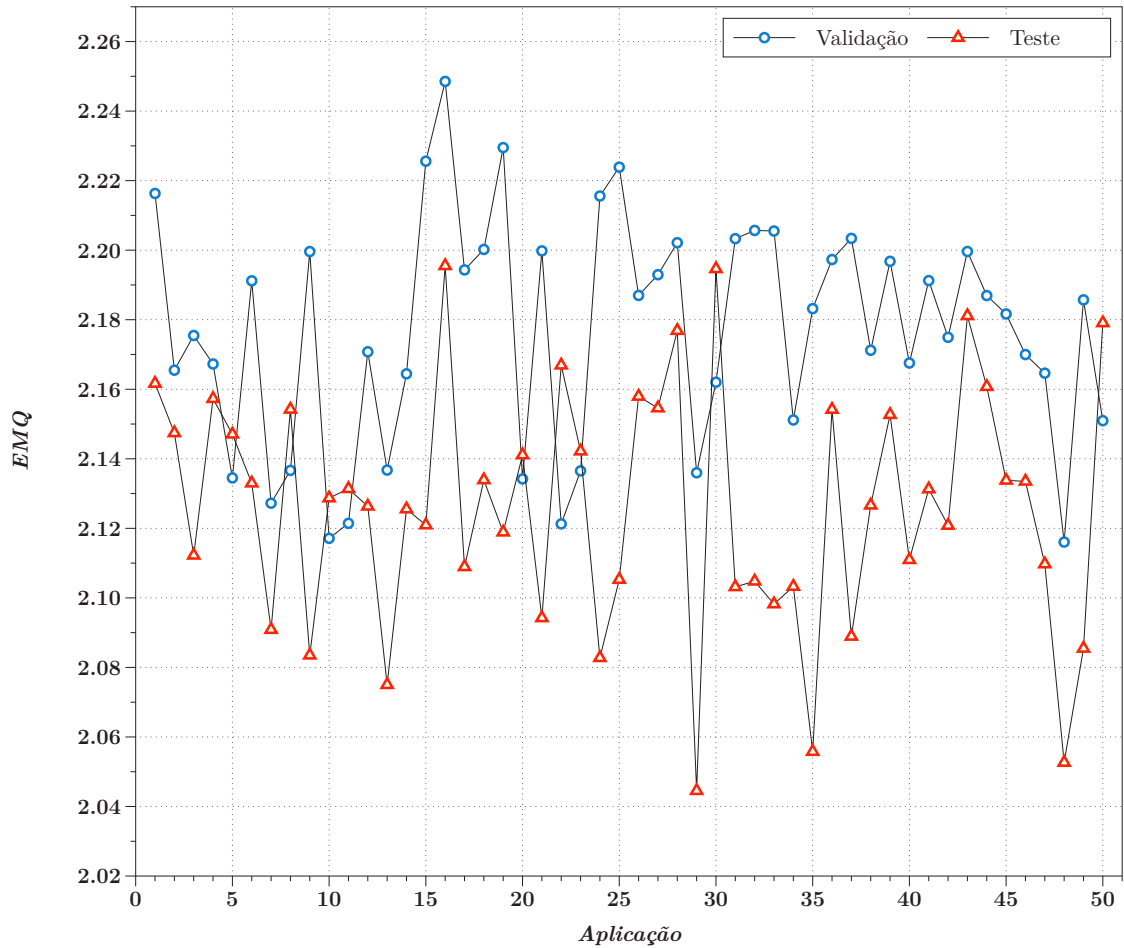


Figura 15: Relação entre o EMQ calculado para os grupos de validação e teste para cada ajuste efetuado pelo treinamento ELM, referente a etapa TR2

Os parâmetros estimados para o modelo hipsométrico (ME), para a primeira etapa do estudo (TR1), são apresentados na Tabela 10.

Tabela 10: Parâmetros ajustados do modelo estatístico proposto para cada estrato referente a base de dados com 80% das árvores por parcelas

Estrato	$\beta(0)$	$\beta(1)$	$\beta(2)$	R^2
1	0.6047	-4.4134	0.8485	0.6194
2	2.3723	-10.5581	0.3056	0.7495
3	0.7799	-9.7343	0.8575	0.9146
4	1.5668	-9.8475	0.5857	0.8121
5	1.3275	-8.4318	0.6339	0.6770
6	1.0081	-7.5307	0.7527	0.7106
7	1.0111	-7.5117	0.7491	0.5536
8	0.9647	-6.4567	0.7556	0.4961
9	0.9873	-7.1261	0.7489	0.7208
10	0.9778	-7.1691	0.7515	0.5642
11	0.7042	-4.7258	0.8231	0.6978
12	1.1803	-6.2847	0.6512	0.7367
13	1.7724	-6.5218	0.3650	0.6885
14	0.5994	-6.7419	0.8805	0.5704
15	0.7726	-7.4354	0.8314	0.7235
16	0.8820	-7.3253	0.7976	0.7598
17	0.9479	-8.9930	0.7998	0.6558
18	0.9984	-5.7657	0.7372	0.5591
19	3.8522	-6.0193	-0.2291	0.4716
20	0.7433	-8.6538	0.8601	0.7572
21	0.4255	-8.2981	0.9500	0.6306
22	0.6468	-6.6119	0.8600	0.9284
23	0.9395	-8.4738	0.8030	0.6846
24	1.0076	-5.6534	0.7135	0.5753
25	0.4458	-1.5240	0.8632	0.3440
26	1.0516	-10.8508	0.7788	0.7480
27	0.7374	-6.2738	0.8174	0.6901
28	0.9293	-6.6142	0.7693	0.7313
29	0.7672	-7.5827	0.8343	0.8088
30	0.7595	-9.0726	0.8384	0.7842
31	0.7955	-7.6928	0.8262	0.8517
32	0.8182	-7.5619	0.8211	0.8317
33	1.1613	-10.0868	0.7322	0.8521
34	-0.0011	-7.1325	1.0906	0.7702

Campos e Leite (2013) relatam que o modelo hipsométrico (ME), quando utilizado para estimar a altura de árvores, resultam em R^2 pouco acima que 0,5, ou seja, sendo este modelo um dos mais utilizados no setor florestal para este fim, pode-se dizer que os modelos hipsométricos apresentam certa dificuldade na estimativa da altura de árvores. Tal fato pode ser associado à fatores ambientais que afetam o crescimento das árvores.

Os erros em porcentagem, para cada estrato, ao se aplicarem os modelos estatísticos ajustados por estrato, podem ser visualizados na Figura 16.




Figura 16: Distribuição dos erros para aplicação do modelo de regressão referente a base de dados com 80% das árvores por parcela

Já os parâmetros estimados para o modelo hipsométrico (ME) para segunda a etapa do estudo (TR2), ou seja, utilizando-se três árvores por parcela dentro de cada estrato, são apresentados na Tabela 11.

Tabela 11: Parâmetros ajustados do modelo estatístico proposto para cada estrato com 3 árvores por parcela

Estrato	$\beta(0)$	$\beta(1)$	$\beta(2)$	R^2
1	0.3008	-4.1083	0.9491	0.7095
2	4.0040	-18.5210	-0.1338	0.8861
3	0.2168	-6.9954	1.0130	0.9188
4	1.6734	-15.0646	0.6255	0.9255
5	1.8644	-8.0727	0.4254	0.6421
6	1.0111	-7.6013	0.7523	0.6264
7	2.1764	-7.5597	0.3501	0.5229
8	1.6084	-8.1960	0.5624	0.5038
9	1.0141	-7.2396	0.7418	0.7258
10	1.6313	-8.6452	0.5516	0.5314
11	-0.6982	-2.0444	1.3406	0.8311
12	1.2415	-6.0160	0.6118	0.6598
13	1.9344	-6.1143	0.2605	0.6054
14	0.5016	-7.8431	0.9269	0.5675
15	0.5513	-6.9216	0.9034	0.7560
16	0.7691	-6.8050	0.8319	0.7529
17	0.4582	-8.1055	0.9436	0.7724
18	0.7328	-5.8598	0.8241	0.6825
19	2.3698	-6.4276	0.2880	0.8197
20	0.8307	-9.6431	0.8439	0.7239
21	0.1578	-7.9673	1.0346	0.4592
22	-0.1863	-3.8192	1.1025	0.9455
23	0.9599	-8.8756	0.8142	0.6660
24	0.1807	-5.2274	1.0382	0.7056
25	-0.2672	6.4789	1.0088	0.4631
26	1.7161	-9.6417	0.5672	0.5369
27	0.8233	-6.2314	0.7871	0.6185
28	0.6840	-7.1802	0.8598	0.7152
29	0.7670	-7.1031	0.8283	0.8373
30	0.5803	-7.7471	0.8774	0.7882
31	0.3231	-6.2378	0.9646	0.8864
32	0.6597	-7.5366	0.8754	0.8712
33	1.3602	-10.5846	0.6775	0.8795
34	-0.8240	-4.5211	1.3350	0.7295

Pode-se constatar uma diferença nos parâmetros estimados entre as etapas TR1 e TR2, que está relacionada com a diminuição do grupo de dados de entrada, sendo 6.145 árvores na etapa TR1 para 1.863 na etapa TR2. Ribeiro et al. (2010) estudaram o número ideal de árvores medidas por parcela para se estimar a altura das demais árvores de um povoamento, e obtiveram como melhor resultado um número mínimo de 5 árvores mais duas dominantes, para utilização de modelos hipsométricos. Foram utilizadas as medidas de altura de 3 árvores por parcela neste estudo, a fim de se verificar o potencial das RNAs em estimar a altura das árvores levando-se em conta a redução na base de dados; o modelo hipsométrico foi apenas utilizado como base para comparação.




Figura 17: Distribuição dos erros para aplicação do modelo de regressão referente à base de dados com 3 árvores por parcela.

Os resultados de EMQs calculados a partir da aplicação dos métodos estudados sobre o grupo de teste, para etapa TR1, são apresentados na Tabela abaixo.

Tabela 12: Resultados por metodologia com treinamento efetuado com 80% dos dados

Método	EMQ
BKP	1,95
ELM	1,96
ME	1,99

Foi possível verificar que as RNAs, utilizando-se os treinamentos BKP e ELM, apresentaram EMQ menor que o modelo hipsométrico estudado, o que aponta que as RNAs podem obter boas estimativas da altura de árvores. Em relação ao EMQ calculado, os métodos de treinamento de RNAs, ELM e BKP se mostraram semelhantes, sendo que a diferença do EMQ entre eles foi muito pequena, com uma diferença de 0,015.

Ao se analisar a dispersão dos erros para a primeira etapa do estudo TR1, na Figura 18, foi possível verificar que os métodos estudados se comportaram de maneira semelhante, ou seja, não é possível relatar diferenças visuais entre a aplicação destes métodos.




Figura 18: Distribuição dos erros para aplicação das metodologias estudadas, referente ao treinamento efetuado com 80% dos dados.

A análise do gráfico de frequência de erros, Figura 19, demonstrou a semelhança entre os resultados obtidos pela aplicação das metodologias estudadas na etapa TR1 deste estudo.

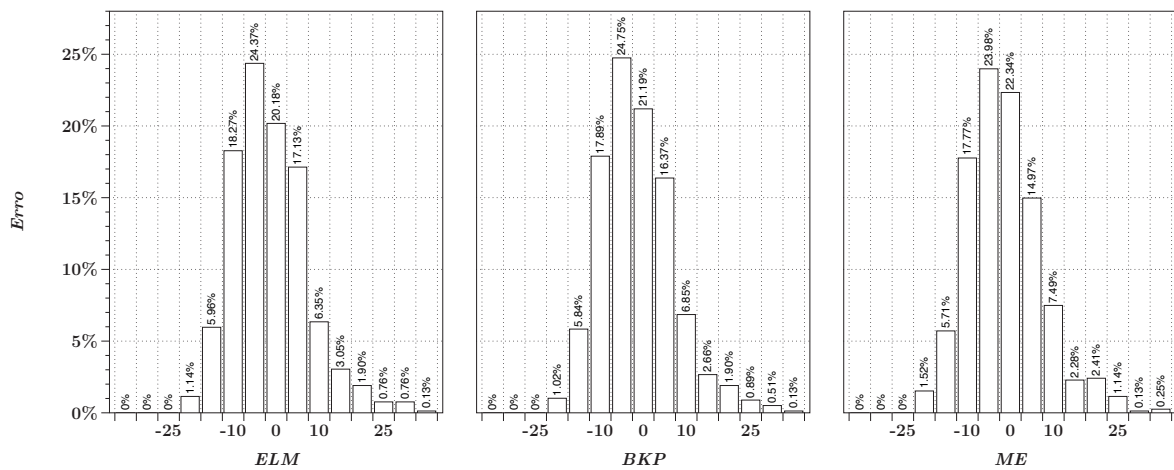


Figura 19: Frequência percentual dos erros percentuais referentes às aplicações dos métodos ELM, BKP e ME, respectivamente para etapa TR1.

Ao se utilizarem apenas 3 árvores por parcela dentro do grupo de treinamento, observou-se um aumento no EMQ para as três metodologias estudadas. Este resultado é apresentado na Tabela 13.

Tabela 13: Erro médio quadrático calculado por metodologia referente a treinamento efetuado para 3 árvores por parcela:

Método	EMQ
BKP	2,02
ELM	2,05
ME	2,13

A dispersão dos erros para a etapa TR2, Figura 20, apresentou pequenas variações nos erros da estimação da altura de árvores com DAP até 10 cm, em relação à etapa TR1, o que pode ter sido ocasionado por falha na amostragem ou composição do grupo de treinamento, devido ao número reduzido de árvores.




Figura 20: Distribuição dos erros para metodologia com treinamento efetuado com 3 árvores por parcela.

A análise do gráfico de frequência de erros para a etapa TR2 é apresentada na Figura 21. Neste caso também houve semelhança entre os resultados obtidos pela a aplicação das metodologias estudadas.




Figura 21: Frequência percentual dos erros percentuais referente às aplicações dos métodos ELM, BKP e ME, respectivamente, para etapa 2 deste estudo.

Os treinamentos de redes neurais artificiais (Métodos BKP e ELM) se mostraram com erro médio quadrático (EMQ) inferiores tanto para a aplicação com dez árvores por parcela (TR1), quanto para a aplicação com três árvores por parcela (TR2), em relação ao método estatístico estudado (ME).

Houve acréscimo no EMQ de TR1 para TR2, fato que pode estar relacionado com a diminuição da base de dados, pois se reduz o poder de generalização de uma RNA a ser treinada ao se limitar o grupo de treinamento a um número menor de amostras.

Binoti (2012) relatou que o uso das redes neurais artificiais para estimar a altura de povoa-mentos foi eficiente e permitiu reduzir o número de medições em altura, sem perda de precisão

e exatidão. Neste estudo foi possível verificar que houve um pequeno aumento no EMQ entre as aplicações efetuadas, no qual, foram mantidos os mesmos dados para treinamento e testes. Tal verificação foi relevante para o setor florestal, pois permite a redução da medição da altura de árvores por parcela.

Em relação ao tempo para aplicação das metodologias estudadas o treinamento via ELM foi mais rápido do que o BKP, o que já era esperado. O ME se apresentou como metodologia mais rápida.

Tabela 14: Resultados de EMQ referentes a cada metodologia estudada e aumento do EMQ em % referentes à variação no tamanho do grupo de treinamento

	TR1	TR2	Aumento
BKP	1,95	2,02	3,78%
ELM	1,96	2,05	4,37%
ME	1,99	2,13	6,94%

Gestores do setor florestal devem atentar para tais considerações a fim de avaliar a necessidade relacionada ao custo, no caso de se efetuar a medição de um número reduzido de árvores. Outro ponto a se considerar é que deve ser feito um planejamento da coleta dos dados, que leve em consideração o fato de que para se realizar a escolha dos melhores modelos RNAs são necessárias, além das três ou dez árvores por parcela, uma quantidade de árvores amostra, destinada ao grupo de validação das RNAs, caso for utilizar-se do método aplicado neste estudo.

6 Conclusões

As redes neurais artificiais treinadas pela máquina de aprendizagem extrema se mostraram eficazes na estimativa da altura de árvores de *Pinus*, e apresentaram resultados semelhantes às redes neurais artificiais treinadas pelo algoritmo *back-propagation*.

Houve uma maior precisão na estimativa da altura de árvores ao se utilizar as redes neurais artificiais, considerando-se a medição do número de 12 árvores por parcela, sendo 10 árvores para o grupo de treinamento e 2 árvores destinadas ao grupo de validação. A redução do grupo de treinamento para 3 árvores por parcela, mantendo o mesmo grupo de validação, afetou o poder de generalização das redes neurais artificiais aumentando o erro médio quadrático na ordem de 4%.

Parte III

TREINAMENTO DE REDES NEURAIIS ARTIFICIAIS UTILIZANDO A MÁQUINA DE APRENDIZAGEM EXTREMA PARA ESTIMAR VOLUME DE VEGETAÇÃO LENHOSA NO CERRADO *SENSU STRICTO*

Resumo

O setor florestal brasileiro possui um bom nível de desenvolvimento tecnológico. O uso de novas tecnologias, como ferramentas da inteligência computacional, pode tornar as empresas deste setor cada vez mais competitivas. Com o avanço e melhorias na acessibilidade aos computadores atuais, novas técnicas vêm sendo estudadas para solucionar problemas que envolvem um grande número de variáveis associadas à produção florestal e preservação do meio ambiente. A maioria das decisões tomadas no manejo florestal necessita do conhecimento, em alta escala de precisão, do volume de madeira contido no povoamento a ser manejado. Este estudo teve como objetivo a implementação de um técnica de treinamento de Redes Neurais Artificiais (RNA), chamada de máquina de aprendizagem extrema (*Extreme Learn Machine - ELM*), e aplicação das RNAs em problema de estimativa de volume dos componentes (fuste e galhos) de árvores do Cerrado. Os modelos de regressão atuais podem não estimar de forma precisa o volume de galhos, sendo que, o Cerrado apresenta alta diversidade de espécies, além de elevada variabilidade entre indivíduos da mesma espécie. Árvores de uma mesma espécie podem apresentar grande variação na forma do fuste e principalmente na forma dos galhos, o que dificulta a modelagem. Neste estudo foi possível verificar que as redes neurais artificiais podem estimar o volume dos componentes (fuste e galhos) de árvores do Cerrado. Verificou-se a importância de utilizar uma base de dados com informação suficiente para dividir os dados nos grupos de treinamento, validação e teste. Com a base de dados utilizada neste estudo, não possível identificar qual é o melhor método para se estimar o volume de fuste e de galhos de árvores do Cerrado de maneira consistente, tendo em vista que, as RNAs apresentaram resultados semelhantes aos modelos de regressão estudados.

Palavras-chave: *Inteligência Computacional, Regressão, Estimativa do volume de fuste, Estimativa do volume de galhos*

Abstract

The forest sector has a good level of technological development. The use of new technologies as tools of computational intelligence can make the companies in this sector ever more competitive. With the advancement and improvements in the accessibility of current computers, new techniques have been studied for solve problems that involve a large number of variables associated with forest production and preservation of the environment. Most of the decisions in forestry management requires knowledge, for high precision scale, the volume of wood contained in the population to be managed. This study aimed to implement a training technique Artificial Neural Networks (ANN) called extreme learning machine (ELM), and application of ANNs in estimation problem of volume components stem and twigs of trees of the Cerrado. The current regression models may not estimate accurately the volume of twigs, given that the Cerrado has a high diversity of species in addition to high variability between individuals of the same species. Trees of the same species may show large variation in stem form and mainly in the form of twigs, which complicates the modeling. In this study was verified that artificial neural networks can estimate the volume of components (stem and twigs) of trees of the Cerrado. The importance of using a database with enough data to divide in groups of training, validation and testing was observed. With the database used in this study can not be identified what is the best method to estimate the volume of stem

and twigs of trees of the Cerrado consistently, considering that the ANNs presented similar results to studied regression models.

Keywords: *Computational Intelligence, Regression, Estimation the volume of stem, Estimation the volume of twigs*

1 Introdução

O Cerrado é o segundo maior bioma brasileiro, com área inferior apenas à Amazônia. O Cerrado apresenta alta diversidade de espécies, compostas por grande variabilidade entre indivíduos de mesma espécie, podendo apresentar grande variação na forma do tronco e galhos destes indivíduos, o que acaba por dificultar a obtenção de estimativas precisas de sua produtividade (REZENDE et al., 2006).

A cada dia, o Cerrado vem sofrendo com a destruição dos ecossistemas que o constituem. Machado et al. (2004) observaram que 55% do Cerrado já foram desmatados ou transformados pela ação humana. O restante das áreas estão sendo utilizadas por pastagens(41%), agricultura (11%), florestas plantadas (0,1%), áreas urbanas (2%) e outros.

De acordo com Campos e Leite (2013), o manejo florestal trata do gerenciamento dos recursos florestais. A produtividade é indicador de grande importância neste setor, para auxiliar na extração madeireira para fins energéticos, nos produtos lenha e carvão vegetal, ou mesmo para fins de preservação e uso sustentável deste recurso.

Alguns autores como SCOLFORO e SILVA (1993), PAULA et al. (1998), OLIVEIRA et al. (1998), IMAÑA-ENCINAS e PAULA (2003), BATALHA M.A.; MARTINS (2004), Rezende et al. (2006), Corrêa e Costa (2011) trabalharam em estudos relacionados com a produtividade do Cerrado. O que se pôde verificar foi que a característica produtividade do Cerrado é pouco conhecida, principalmente ao se avaliarem as variáveis volume de fuste e galhos. Muitas vezes, o volume de galhos de árvores do Cerrado é desprezado no cálculo do volume total da árvore, o que pode acarretar erros elevados na estimativa da produtividade.

As dificuldades para modelagem de árvores do Cerrado são norteadas por questões relacionadas com a forma do fuste e dos galhos, legislação que muitas das vezes não permite a derrubada da árvore para se efetuar a cubagem, questões sociais e ambientais que impedem ou dificultam a obtenção de dados consistentes referentes ao bioma Cerrado.

Campos et al. (2001) definiram que um modelo adequado para estimar o volume de componentes de árvores, fuste e galhos, deve ser consistente, ou seja, ao se somar o volume de fuste e galhos estimados deve se obter um valor compatível com o volume real da árvore.

Os modelos de regressão são muito utilizados no setor florestal para se estimar o volume de árvores, uma alternativa à aplicação destes modelos é dada pelo emprego de redes neurais artificiais (DIAMANTOPOULOU, 2005; GÖRGENS, 2006; GÖRGENS et al., 2009; SILVA et al., 2009; ÖZÇELİK et al., 2010).

2 Objetivos

Este trabalho teve como objetivo estimar de forma precisa e consistente o volume de fuste e de galhos, de árvores do Cerrado, utilizando redes neurais artificiais, e comparar os resultados com modelos de regressão.

3 Material e Métodos

Os dados utilizados neste estudo foram provenientes de uma área de 63,54 *ha* de Cerrado *sensu stricto* destinada a projetos silviculturais. A área foi dividida em parcelas iguais, de 20x50 *m*, e em seguida foram selecionadas ao acaso 10 parcelas. Foram medidos de cada indivíduo o diâmetro na base do fuste (*Db*) e altura total (*Ht*) de todos os indivíduos lenhosos vivos com diâmetro com casca tomado a 0,3 *m* de altura com diâmetro igual ou superior a 5 *cm*. Os indivíduos coletados foram dispostos em classes de diâmetro com intervalos de 4 *cm*. (REZENDE et al., 2006).

Tabela 15: Análise descritiva dos dados

Variável	Mínimo	Máximo	Média	Desvio Padrão
Volume de Fuste (m^3ha^{-1})	0.0013	0.3091	0.0332	0.0452
Volume de Galho (m^3ha^{-1})	0.0010	0.4705	0.0514	0.0855
Diâmetro na base do fuste (<i>cm</i>)	5.0000	32.3000	12.6887	6.0495
Altura total (<i>m</i>)	1.1500	11.1000	4.3053	2.1556
Altura comercial (<i>m</i>)	0.3000	6.3900	2.0108	1.1441

Para o ajuste dos modelos de volume, foram selecionados casualmente 25% dos indivíduos vivos em cada classe diamétrica, mantendo pelo menos um indivíduo de cada espécie dentro de cada classe. Posteriormente, cada indivíduo selecionado de cada classe de diâmetro foi localizado no campo, cortado na base do fuste com o uso de motosserra e o diâmetro inicial (*D0*) tomado neste ponto. Em seguida, foi separado o tronco dos galhos e mediu-se a altura comercial de cada indivíduo. Considerou-se para ambos, galhos e tronco, um diâmetro mínimo comercial de 3 *cm*. Galhos e secções do tronco com *Db* menor que 3 *cm* foram eliminados. (REZENDE et al., 2006).

Para a obtenção do volume de cada indivíduo, foi realizada a cubagem do tronco e dos galhos por meio da aplicação sucessiva da expressão de Smalian (HUSCH et al., 1972), em secções de comprimentos variáveis ao longo do tronco, tendo em vista que as espécies arbóreas do Cerrado possuem tronco e galhos tortuosos. (REZENDE et al., 2006).

Foi efetuada a consistência dos dados na tentativa de evitar potenciais tendências relacionadas ao nível de amostragem reduzido de árvores com volume de galho inferior a 0,01 m^3 e com *Db* acima de 40 *cm*. Havia 189 árvores na base de dados inicial, após efetuar a consistência foram mantidas 155 árvores.

Após realizar a consistência foram visualizadas curvas de dispersão dos dados, relacionando volume de fuste e galhos com *Db*, altura e altura de fuste.

Pode-se perceber que tanto para o volume de fustes, quanto para os galhos existe uma relação com a variável Db , que pode ser observada na Figura 22.




Figura 22: Volume em m^3 de fuste e galho para cada árvore em função do Db

Ao se analisar o volume de fustes e galhos das árvores estudadas em relação a altura das mesmas, Figura 23, foi possível verificar que as alturas explicam o volume, mas de maneira um pouco menos expressiva do que o Db .




Figura 23: Volume em m^3 de fuste e galho para cada árvore em função da altura das árvores

A relação entre os volumes de fuste e de galho, e a altura comercial das árvores pode ser vista na Figura 24. O volume dos galhos se apresentou menos relacionado com a altura comercial do que o volume de fustes.




Figura 24: Volume em m^3 de fuste e galho para cada árvore em função da altura comercial

A metodologia deste estudo é descrita pela organização dos dados em 9 combinações distintas, obtidas por meio da aleatorização da base de dados completa. Tal diversificação dos dados em combinações foi proposta a fim de se verificar o comportamento da aplicação dos métodos estudados em situações distintas.

Os dados foram aleatorizados em nível de árvore, para que se evitassem treinamentos com maior incidência de informações de fuste ou galhos, podendo, assim, apresentar falhas nos resultados.

A organização dos dados para aplicação dos métodos foi feita de acordo com o esquema apresentado a seguir, em que a variável alvo é o volume do componente, fuste ou galho, que é definido pela variável binária Tx .

Alvo	Numérica	Numérica	Numérica	Binária
Volume de fustes	Db	Ht	Hf	$Tx = 0$
Volume de galhos	Db	Ht	Hf	$Tx = 1$

Sendo:

Db = Diâmetro em cm medido à $0,3 m$ do solo;

Ht = Altura da árvore;

Hf = Altura comercial da árvore;

Tx = Variável binária para diferenciação de dados de fuste $Tx = 0$ e $Tx = 1$ para dados de galhos

O volume total da árvore foi calculado por meio da equação:

$$Volume_{total} = Volume_{fuste} + Volume_{galhos} \quad (6)$$

A base de dados foi dividida em três grupos de dados dentro de cada combinação, de acordo com o esquema apresentado na Figura 25. A definição do tamanho dos grupos foi realizada de modo empírico, objetivado na determinação do número mínimo de árvores para se treinar adequadamente uma rede neural artificial a fim de se prever de forma compatível o volume das demais árvores.

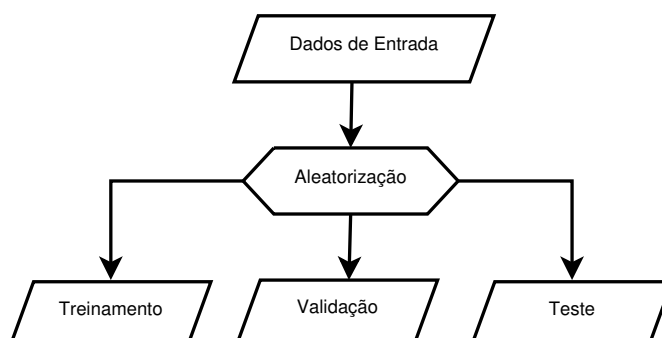


Figura 25: Fluxograma para descrição da divisão dos grupos de dados

O grupo de treinamento foi utilizado no ajuste dos modelos estatísticos e como base para o treinamento das RNAs BKP e ELM. O grupo de validação foi utilizado para escolha das melhores RNAs BKP e ELM, tal como a definição das topologias das redes. O grupo de teste foi determinado para se efetuar a comparação direta entre os métodos estudados, ou seja, para aplicação dos modelos estatísticos e RNAs treinadas.

Dados de cubagem de mata nativa possuem um alto grau de dificuldade para obtenção. Isto se deve a alguns fatores como: legislação, preservação de espécies, difícil acesso, diversidade, dentre outros. Este fator foi limitador para o estudo, que foi realizado com a utilização de 155 árvores de espécies variadas. Os três grupos de dados definidos para cada combinação foram dispostos com o seguinte nível de amostragem:

Tabela 16: Definição do tamanho dos grupos de dados

Grupo	%	Nº de árvores
Treinamento	75	116,25
Validação	10	15,50
Teste	15	23,25

Foi feito o arredondamento do número de árvores utilizando apenas a parte inteira, ou seja, o grupo de treinamento foi composto por 116 árvores, o de validação por 15 e o de testes por 23, perfazendo um total de 154 árvores em cada combinação.

Após a divisão dos grupos referentes a cada combinação foram obtidos os gráficos de dispersão, levando-se em conta o volume de fuste e galhos em relação ao Db , a Ht e Hf , para cada grupo de combinação de dados.

Como se pode observar na Figura 26, cada combinação apresentou pequenas diferenças nas tendências de curvas dos dados do grupo de treinamento, referentes à variação dos dados de

maneira aleatória, o que está de acordo com a pretensão de obter diferentes cenários para se realizar a comparação entre os métodos estudados.

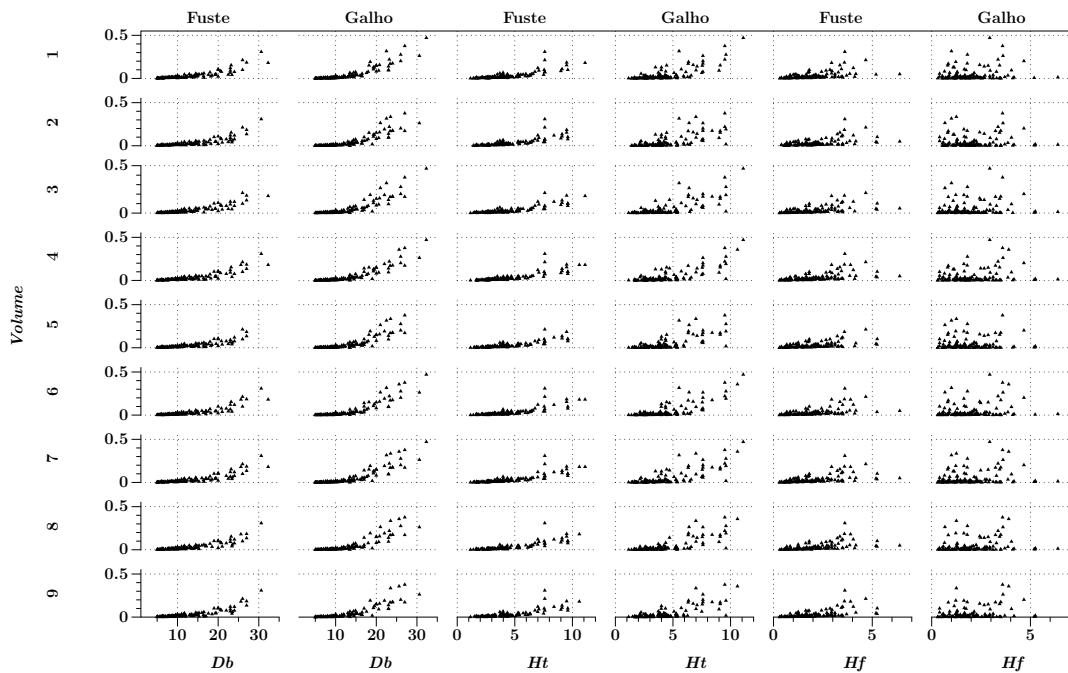


Figura 26: Dispersão dos dados de volume de fuste e galhos, em relação ao diâmetro de base (Db), altura total (Ht) e altura comercial (Hf), referente ao grupo de treinamento para cada combinação

De forma similar, as curvas de dispersão dos dados do grupo de validação podem ser vistos na Figura 27, com suas respectivas tendências para cada combinação definida.




Figura 27: Dispersão dos dados de volume de fuste e galhos, em relação ao diâmetro de base (Db), altura total (Ht) e altura comercial (Hf), referente ao grupo de validação para cada combinação

As curvas de dispersão dos dados do grupo de teste para cada combinação são apresentadas abaixo, na Figura 28:




Figura 28: Dispersão dos dados de volume de fuste e galhos, em relação ao diâmetro de base (Db), altura total (Ht) e altura comercial (Hf), referente ao grupo de teste para cada combinação

Foram utilizados quatro métodos para se estimar o volume de componentes de árvores do Cerrado, sendo dois tipos de treinamentos de RNAs e aplicação de dois modelos estatísticos. Para as RNAs foram utilizados o treinamento *extreme learn machine* (ELM) e o *back-propagation* (BKP). Os modelos estatísticos estudados foram a equação de volume Schumacher e Hall (1933) e modelo utilizado no ajuste do volume dos diferentes componentes da árvore e o proposto por Campos et al. (2001).

3.1 Modelos Estatísticos

Existem vários modelos para expressar o volume de madeira correlacionando o diâmetro e a altura das árvores.

O modelo proposto por Schumacher e Hall (1933) é o mais difundido na área florestal, devido às suas propriedades estatísticas (CAMPOS; LEITE, 2013). Foi definida a sigla (S&H) para referenciar este modelo neste estudo. O modelo proposto por Schumacher e Hall (1933) que é dado por:

$$V = \beta_0 Db^{\beta_1} Ht^{\beta_2} \times \varepsilon \quad (7)$$

Sendo:

V = volume por árvore;

Db = diâmetro da árvore medido a 0,3 m do solo;

Ht = altura da árvore;
 β_i = parâmetros de ajuste da equação;
 ε = erro associado ao ajuste.

Como a proposta deste estudo foi a estimativa do volume dos componentes fuste e galhos das árvores de Cerrado, a aplicação do modelo Schumacher e Hall (1933) se deu por meio de um sistema que pode ser visto na Figura 29.

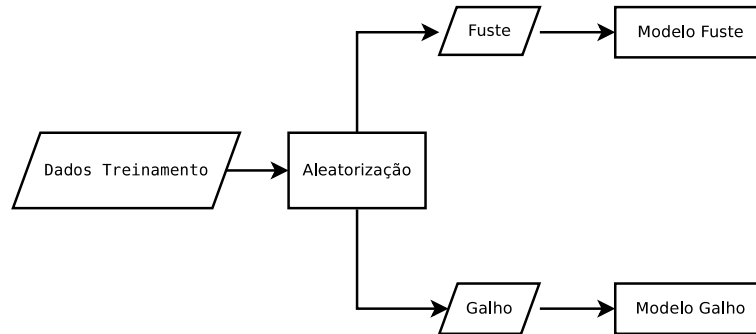


Figura 29: Definição de sistema para aplicação do modelo S&H para fuste e galho.

Campos et al. (2001) propuseram o Modelo 8 para estimar o volume dos diferentes componentes da árvore.

$$V = \beta_0 * DAP^{\beta_1} * Ht^{\beta_2} * \exp(-\beta_3 * \frac{Tx_1}{DAP}) * (1 - (\frac{Tx_2 * h}{DAP})^{\beta_4}) * \varepsilon \quad (8)$$

Sendo:

V = volume de cada componente da árvore;
 Ht = altura da árvore;
 h = altura comercial da árvore;
 DAP = diâmetro da árvore medido a 1,3m do solo;
 $Tx_1 = 0$ para volume com casca e $Tx_1 = 1$ para volume sem casca;
 $Tx_2 = 0$ para volume comercial e $Tx_2 = 1$ para volume de galhos;
 β_i = parâmetros de ajuste da equação;
 ε = erro associado ao ajuste.

Como não havia interesse neste estudo de contemplar a modelagem de dados de casca, o Modelo 8 foi reduzido à Equação 9. Foi proposta a sigla (REG) para referenciar este modelo neste estudo.

$$V = \beta_0 * Db^{\beta_1} * Ht^{\beta_2} * (1 - (\frac{Tx * h}{Db})^{\beta_3}) * \varepsilon \quad (9)$$

Assim sendo, a variável binária Tx é responsável por representar o volume de fuste quando $Tx = 0$, e volume de galhos quando $Tx = 1$. Outra alteração que foi feita para se adequar a equação foi a utilização do diâmetro da base (Db) ao invés do DAP.

3.2 Redes Neurais Artificiais (RNAs)

Foram utilizados dois procedimentos de treinamento das RNAs: o *extreme learn machine* e o *back-propagation*.

Para a aplicação das RNAs ELM e BKP os dados foram normalizados com desvio padrão 1 e média 0, no intuito de defini-los em uma mesma escala, visando à melhoria da capacidade de estimativa das RNAs (WRAY et al., 1994). Apenas a variável alvo não foi normalizada.

Na definição das topologias das RNAs ELM e BKP, foi utilizada a técnica de validação cruzada *K-Fold-cross validation* (KOHAVI, 1995; BOUCKAERT, 2003). Foi definido $k = 10$. Foram feitas variações no número de neurônios na camada escondida e avaliadas a média e o desvio padrão do erro médio quadrático dos resultados da validação cruzada para definição do número de neurônios na camada escondida, que melhor se adequou ao problema.

Para definir a topologia de RNA utilizando-se o treinamento BKP, foram variados os números de neurônios na camada oculta de 1 até 20. Para a definição da topologia da RNA, utilizando-se o treinamento ELM, o número de neurônios na camada oculta foi variado de 10 até 50, sendo que a ELM requer um número maior de neurônios nesta camada quando comparada ao BKP, e o número de neurônios da camada oculta deve ser inferior ou igual ao número de amostras contidas no grupo de treinamento (HUANG et al., 2004).

A configuração das RNAs utilizando-se BKP foi dada por taxa de aprendizagem com valor 0,001; Foram definidos como critérios de parada dos treinamentos os valores de EMQ abaixo de 0,00001, e o número máximo de 100 iterações do algoritmo *back-propagation* para cada treinamento. Tais parâmetros foram definidos por meio de testes preliminares, com base em realizar o máximo de iterações do algoritmo BKP tentando aproximar ao máximo das melhores estimativas.

A função de ativação utilizada na configuração das RNAs utilizada nos treinamentos BKP e ELM foi a sigmoideal.

Após definição dos parâmetros de configuração e topologia definida, foi feito o treinamento das RNAs, sendo definido o melhor treinamento pelo cálculo do EMQ da rede treinada aplicada ao grupo de validação. A melhor RNA treinada foi aplicada ao grupo de teste, a fim de ser comparada com os outros métodos.

Para se definir a melhor rede treinada por ELM, foram realizados 1000 treinamentos para cada combinação. Já para a definição da RNA BKP adequada foram realizados 50 treinamentos para cada combinação.

3.3 Avaliação dos métodos estudados

Após cada aplicação de modelos estatísticos e das RNAs, foram calculadas as médias e os desvios padrão, referente às 9 combinações propostas, para cada método estudado.

Para se efetuar a comparação entre os métodos estudados, foram utilizadas análises de gráficos de dispersão dos erros, frequência de erros, assim como a estatística erro médio quadrático

(EMQ):

$$EMQ = \frac{1}{n} \sum_{i=0}^n (y_{est} - y_{obs})^2 \quad (10)$$

O cálculo da dispersão dos erros foi feita utilizando a Equação 11

$$E\% = \frac{(y_{est} - y_{obs})}{y_{obs}} \times 100 \quad (11)$$

O processamento de cálculos, estatísticas e análises gráficas foram realizados em ambiente MATLAB 2012. (MATHWORKS, 2013)

4 Resultados e Discussão

Os parâmetros ajustados referente ao modelo S&H para volume de fuste, para cada combinação, podem ser vistos na Tabela 17.

Tabela 17: Parâmetros ajustados para modelo estatístico S&H proposto para dados de fuste para cada combinação:

<i>Combinação</i>	$\beta(0)$	$\beta(1)$	$\beta(2)$	R^2
1	0.000048	2.223555	0.349783	0.8060
2	0.000007	2.689102	0.629259	0.8405
3	0.000176	1.467070	0.820832	0.8394
4	0.000054	2.167365	0.383233	0.8249
5	0.000112	1.531759	0.949411	0.8080
6	0.000033	2.363806	0.320733	0.8172
7	0.000049	2.130844	0.475737	0.8158
8	0.000023	2.412372	0.439838	0.8394
9	0.000008	2.777775	0.410956	0.8685

Pode-se perceber uma mudança no sinal do parâmetro $\beta(2)$ para aplicação em dados de galhos, demonstrando a necessidade de ajustes separados para volume de fuste e galhos. Os parâmetros ajustados para modelo S&H para volume de galhos são apresentados na Tabela 18.

Tabela 18: Parâmetros ajustados para modelo estatístico S&H proposto para dados de galho para cada combinação:

Combinação	$\beta(0)$	$\beta(1)$	$\beta(2)$	R^2
1	0.000016	3.022477	-0.217735	0.8786
2	0.000010	3.199530	-0.359593	0.8304
3	0.000009	3.230504	-0.308843	0.8811
4	0.000016	2.992340	-0.117816	0.8778
5	0.000005	3.422096	-0.326781	0.8383
6	0.000016	3.037927	-0.225389	0.8720
7	0.000016	3.029663	-0.242937	0.8488
8	0.000017	3.011262	-0.264270	0.8254
9	0.000016	3.011712	-0.218555	0.8167

Os parâmetros ajustados para o modelo proposto por Campos et al. (2001), na forma reduzida referente a Equação 8, para cada combinação, podem ser visualizados na Tabela 19:

Tabela 19: Parâmetros referentes ao ajuste de modelo de regressão REG para cada combinação

Combinação	$\beta(0)$	$\beta(1)$	$\beta(2)$	$\beta(3)$	R^2
1	0.00004	2.34838	0.39424	3.50389 ^{n.s.}	0.7801
2	0.000022	2.55855	0.35010	2.62978 ^{n.s.}	0.7328
3	0.000034 ^{n.s.}	2.51938*	0.192634 ^{n.s.}	3.11654 ^{n.s.}	0.7289
4	0.000035	2.33491	0.47106	3.37891 ^{n.s.}	0.8023
5	0.000027	2.50512	0.34559	2.88004 ^{n.s.}	0.6791
6	0.00004	2.29169	0.49566	3.78669 ^{n.s.}	0.7741
7	0.000041	2.32021	0.42246	3.25001 ^{n.s.}	0.7504
8	0.000027	2.35179	0.57767	3.09632 ^{n.s.}	0.7587
9	0.000022	2.42469	0.57976	3.20319 ^{n.s.}	0.7883

Alguns parâmetros se mostraram não-significativos nos ajustes do modelo REG. Em todas as combinações o parâmetro associado à variável Tx , que define o volume de fuste ou galho, apresentou-se como não-significativo. Devido a este fato, as estimativas dos volumes de fuste e galho computados por este método apresentaram-se com valores aproximados.

As topologias das RNAs BKP e ELM foram definidas com 10 e 13 neurônios na camada oculta.

Os resultados da validação cruzada, que definem a topologia mais adequada para aplicação das RNAs treinadas por BKP ao problema de estimativa do volume de componentes de árvores são apresentados na Figura 30.




Figura 30: Definição da topologia de rede para treinamento BKP

Foi definida a topologia de 10 neurônios na camada oculta para a RNA, usando-se o BKP. Essa topologia se apresentou com menor EMQ médio e melhor consistência entre os treinamentos, mantendo um desvio padrão baixo.

De acordo com a validação cruzada, a topologia de rede escolhida foi a de 13 neurônios na camada escondida, conforme apresentado na Figura 31.




Figura 31: Definição da topologia de rede para treinamento ELM

Foi possível verificar um aumento do EMQ nos treinamentos das RNAs, utilizando-se ELM, quando a rede foi treinada com um número de neurônios na camada oculta maior que 33.

Ao se avaliar o EMQ calculado apenas para fuste, referente a cada combinação, o método ELM se mostrou com melhores resultados, tanto em média quanto em desvio padrão, seguido pelo BKP, S&H e REG. Tais resultados são apresentados na Tabela 20.

Tabela 20: Resultados de erro médio quadrático referente à estimativa do volume de fuste de árvores do Cerrado, para cada combinação dos métodos estudados

<i>Combinação</i>	<i>REG</i>	<i>ELM</i>	<i>RNA</i>	<i>S&H</i>
<i>1</i>	0.000787	0.000201	0.000215	0.000192
<i>2</i>	0.003010	0.000115	0.000880	0.001490
<i>3</i>	0.000538	0.000985	0.000250	0.001379
<i>4</i>	0.000454	0.000087	0.000055	0.000147
<i>5</i>	0.000135	0.000981	0.000101	0.001224
<i>6</i>	0.000739	0.000066	0.000199	0.000305
<i>7</i>	0.000344	0.000082	0.000038	0.000159
<i>8</i>	0.000179	0.000033	0.000566	0.000295
<i>9</i>	0.003237	0.000071	0.001324	0.001451
<i>Média</i>	0.001047	0.000291	0.000403	0.000738
<i>Desvio Padrão</i>	0.001130	0.000372	0.000415	0.000586

O método ELM se adequou bem à estimativa de volume fuste de espécies do Cerrado, perfazendo uma média muito menor, dentre as combinações de dados, do que os modelos estatísticos estudados. Isto denota que este método é adequado à utilização para este fim.

A Figura 32 é apresentada para facilitar a visualização das aplicações dos métodos estudados apenas para o fuste.




Figura 32: Histograma dos resultados de erro médio quadrático referente à estimativa do volume de fuste para cada combinação de dados

O método ELM obteve os melhores resultados e o método REG apresentou os piores resultados na estimativa do volume de fuste.

Em quase todas as combinações de dados, o método ELM apresentou menor EMQ do que os demais métodos estudados, na estimativa do volume de fuste de árvores do Cerrado, exceto nas combinações 3 e 5.

Ao se avaliarem os resultados de EMQ referentes aos métodos aplicados na estimativa do volume de galhos, é possível verificar que o EMQ aumentou em relação a estimativa do volume de fuste. Campos e Leite (2013) relatam que o processo de modelagem deste problema não é muito fácil, pois as formas dos galhos não se assemelham a formas geométricas conhecidas.

O EMQ calculado para galhos demonstrou um destaque para o método RNA BKP, que apresentou EMQ médio mais baixo e desvio padrão menor do que o dos outros métodos estudados. Como os volumes dos galhos não seguem uma distribuição estatística conhecida, as RNAs utilizando-se o treinamento BKP acabaram por obter melhores resultados do que a ELM, devido ao alto potencial de generalização associado ao algoritmo BKP.

Tabela 21: Resultados de erro médio quadrático referente à estimativa do volume de galhos de árvores do Cerrado, para cada combinação dos dados

<i>Combinação</i>	<i>REG</i>	<i>ELM</i>	<i>RNA</i>	<i>S&H</i>
<i>1</i>	0.002028	0.002913	0.000713	0.001734
<i>2</i>	0.002052	0.001607	0.000755	0.005759
<i>3</i>	0.002295	0.001457	0.001725	0.002678
<i>4</i>	0.001889	0.000603	0.000880	0.001743
<i>5</i>	0.000644	0.000617	0.000716	0.000609
<i>6</i>	0.002609	0.001197	0.000950	0.002519
<i>7</i>	0.001336	0.000316	0.000093	0.001274
<i>8</i>	0.000610	0.000459	0.000767	0.000369
<i>9</i>	0.001990	0.001549	0.000753	0.003155
<i>Média</i>	0.001717	0.001191	0.000817	0.002204
<i>Desvio Padrão</i>	0.000664	0.000768	0.000395	0.001530

Pode-se visualizar na Figura 33 que as RNAs obtiveram melhores resultados do que os métodos estatísticos na estimativa do volume de galhos. A equação S&H apresentou os piores resultados, dentre os métodos estudados, na estimativa do volume de galhos.




Figura 33: Histograma dos resultados de erro médio quadrático referente a estimativa do volume de galhos para cada combinação dos dados

Os resultados de EMQ referentes à consistência, volume total (composto por fuste e galhos), dos métodos é apresentado na Tabela 22. O método que apresentou maior consistência em média foi o RNA utilizando-se BKP, mantendo um desvio menor do que os outros métodos. O método REG se mostrou com resultados muito aproximados ao método RNA BKP, sendo que em alguns casos, como nos resultados referentes às combinações 3, 4, 5 e 8 apresentou melhores resultados.

Tabela 22: Resultados de erro médio quadrático referente à consistência na estimativa do volume total de árvores do Cerrado, para cada combinação dos dados

<i>Combinação</i>	<i>REG</i>	<i>ELM</i>	<i>BKP</i>	<i>S&H</i>
<i>1</i>	0.002405	0.003683	0.001221	0.001357
<i>2</i>	0.002235	0.002015	0.001650	0.003624
<i>3</i>	0.000978	0.002051	0.001415	0.002877
<i>4</i>	0.000934	0.000822	0.001104	0.001087
<i>5</i>	0.000681	0.001522	0.000794	0.001214
<i>6</i>	0.001296	0.001542	0.001241	0.001962
<i>7</i>	0.000657	0.000562	0.000190	0.000726
<i>8</i>	0.000379	0.000538	0.000511	0.000563
<i>9</i>	0.002106	0.001559	0.002187	0.001684
<i>Média</i>	0.001297	0.001588	0.001146	0.001677
<i>Desvio Padrão</i>	0.000717	0.000915	0.000564	0.000950

Como o método ELM não obteve bons resultados na estimativa do volume de galhos, isto acabou por denotar uma baixa consistência em relação a RNA BKP.

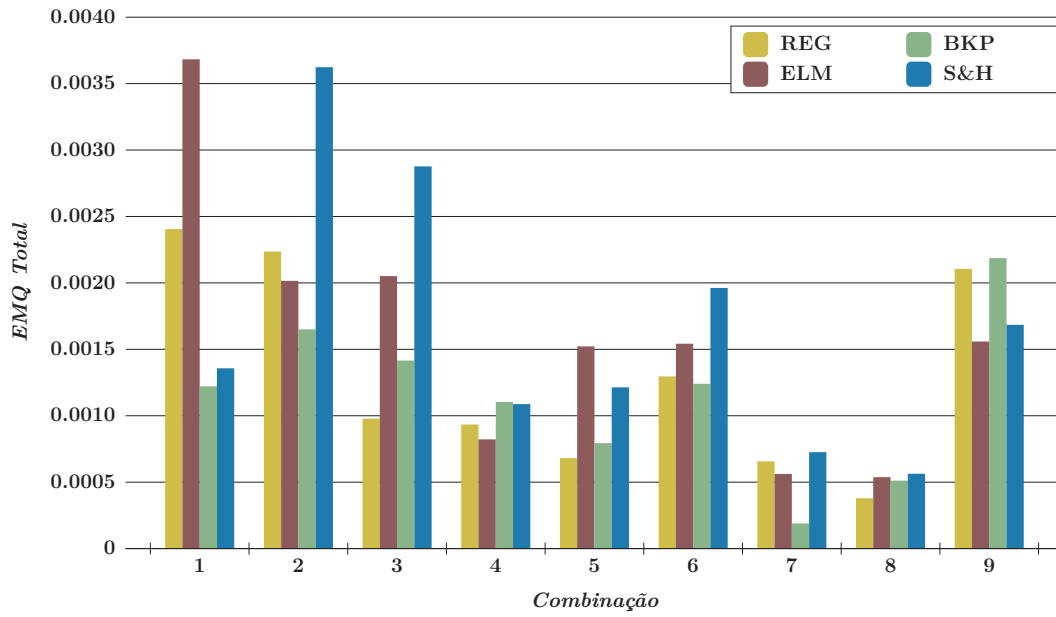


Figura 34: Histograma dos resultados de erro médio quadrático referente à estimativa do volume total de forma consistente para cada combinação dos dados

Os gráficos de dispersão dos erros referentes a cada combinação são apresentados na Figura 35, com a divisão de fuste, galhos e volume total das árvores.

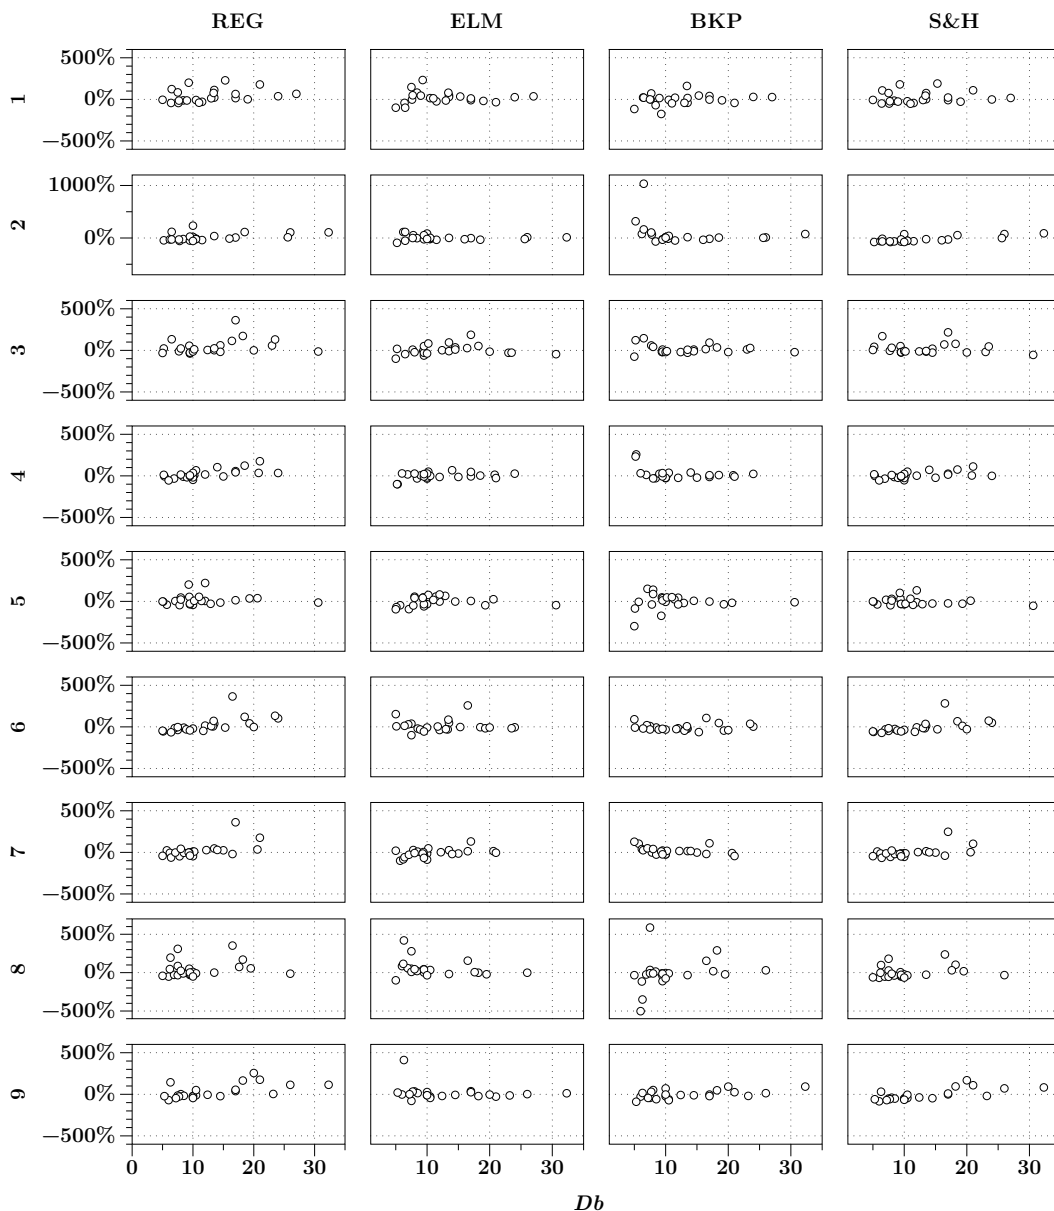


Figura 35: Dispersão de erros percentuais referentes à estimativa do volume de fuste para cada combinação dos métodos estudados

No resultado referente à combinação de dados 2, o método RNA BKP apresentou alto erro em uma única amostra, que pode estar relacionado com ausência de árvores semelhantes no grupo de treinamento.

No resultado referente à combinação de dados 8 todos os métodos apresentaram dificuldades para estimar o volume de fuste. Mesmo que os métodos tenham apresentado EMQ baixos, a análise de resíduos demonstra que os métodos, em alguns casos, apresentaram erros superiores a 500%.

As RNAs treinadas com ELM apresentaram bons resultados para fuste em quase todos os resultados, e as RNAs BKP já se mostraram mais inconsistentes, com erros apresentados na forma positiva e negativa.

Os modelos estatísticos se comportaram de forma muito similar entre si, em relação à análise de resíduos. Conforme a relação com outros estudos (DIAMANTOPOULOU, 2006; GÖRGENS, 2006; SILVA et al., 2009; ÖZÇELİK et al., 2010), foi possível verificar a possibilidade da estimativa do volume de fuste utilizando-se as RNAs BKP, e então, o treinamento ELM pode ser considerado apto para estimar o volume de fuste, pois apresentou resultados melhores do que o BKP, sendo mais eficiente na sua aplicação.

Para facilitar a visualização da dispersão dos erros, foram utilizados os gráficos de frequência percentual dos erros percentuais, como pode ser visto na Figura 36.

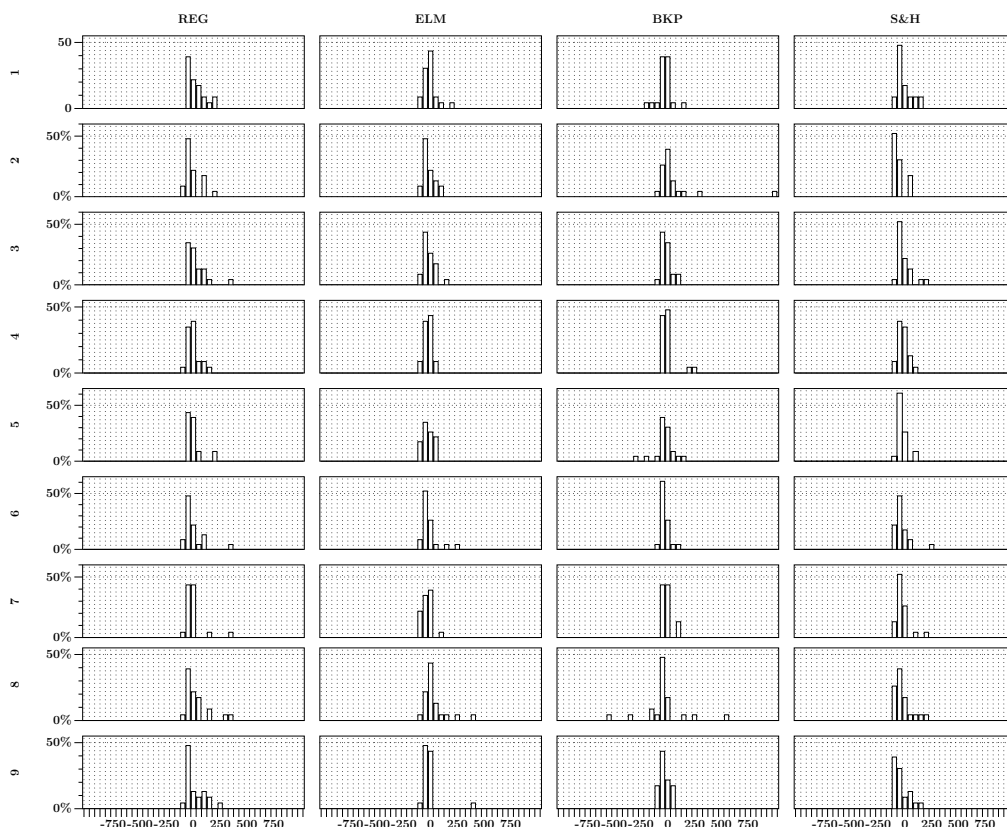


Figura 36: Frequência percentual dos erros percentuais referente ao uso dos métodos REG, ELM, BKP e S&H, respectivamente, para cada combinação, na estimativa do volume de fuste das árvores do Cerrado

Podem ser verificados, após análise das frequências percentuais dos erros de fuste, alguns desvios elevados em relação à média, que podem ser explicados pela falta de correlação entre os grupos de treinamento e validação, devido à amostragem reduzida. Cabe aos gestores do setor florestal verificar tais correlações para que os erros sejam minimizados. A escolha da melhor RNA treinada foi feita pelo grupo de validação. Se o grupo de validação não for representativo do grupo de treinamento, a escolha do modelo de RNA não será feita de forma adequada.

Com a análise da dispersão dos erros referentes à estimativa do volume do componente galho foi possível verificar elevada dispersão dos resultados em relação a média, o que já era esperado pelo grau de complexidade relacionado ao problema. Os erros médios quadráticos referentes à aplicação dos métodos na estimativa dos volumes de galhos se mostraram muito superiores aos

relacionados com o volume de fuste.

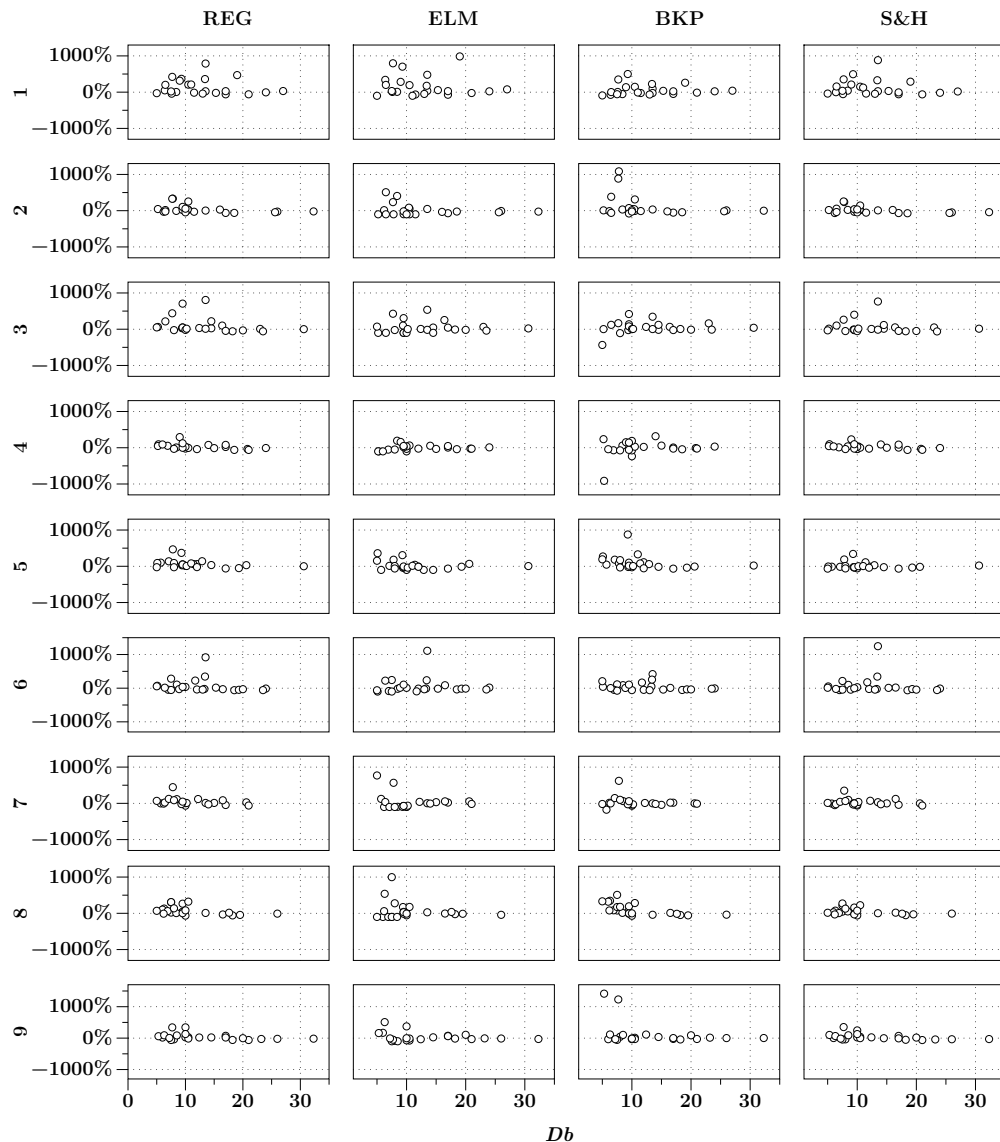


Figura 37: Dispersão de erros percentuais referentes à estimativa do volume de galhos para cada aplicação dos métodos estudados

Alguns trabalhos (GÖRGENS et al., 2009; SOARES et al., 2011; BINOTI, 2010, 2012), denotam que uma boa alternativa para se aumentar a precisão dos ajustes para os métodos de RNAs é utilizar mais informação agregada ao treinamento, com a entrada de outras variáveis disponíveis, sem aumentar a complexidade do modelo para uso. Algumas características que podem ser facilmente adicionadas ao treinamento das RNAs são: *Espécie*, *Local*, *Idade*, dentre outras. Isto pode vir a ser inviável para modelos de regressão, na maioria dos casos, pois, para cada característica inserida, ou é necessária uma readequação estatística no modelo, ou então se faz necessário o aumento do número de equações a serem ajustadas, sendo uma nova equação para cada variação da característica inserida. Tais adequações podem dificultar ou até impossibilitar a aplicação dos modelos estatísticos nesses casos, dependendo do nível de inserção de novas variáveis.

Por se tratar de dados de mata nativa, a complexidade deste problema é elevada, pois existe uma ampla variação de formas de fuste e galhos, tal fato pode denotar que árvores com formas de fuste e galhos diferentes podem apresentar volume de madeira semelhante. Assim sendo, apenas os dados de Db e altura, em muitos casos, não são suficientes para se estimar o volume dos galhos. Em alguns casos, as RNAs treinadas por BKP e por ELM apresentaram resultados da estimativa do volume de galhos negativos, o que não ocorre na prática.

Para se minimizarem os problemas de valores negativos de volume obtidos, tais ocorrências foram consideradas como zero.

Na Figura 38 são apresentadas as frequências percentuais dos EMQ referentes à aplicação dos métodos estudados na estimativa do volume de galhos.



Figura 38: Frequência percentual dos erros percentuais referentes ao uso dos métodos REG, ELM, BKP e S&H, respectivamente, para cada combinação, na estimativa do volume de galhos das árvores do Cerrado.

Foi possível verificar o erro elevado nas estimativas de volume de galhos por todos os métodos estudados. Isto é devido à grande variabilidade natural de espécies e variação de formas dos galhos das árvores do Cerrado. Rezende et al. (2006) relataram que existe uma grande variabilidade natural, tanto na estrutura da vegetação, quanto nas formas das árvores do Cerrado, o que afetou o erro médio absoluto obtido por meio da aplicação de modelos estatísticos na estimativa do volume de árvores.

Foi realizada uma tentativa de se melhorarem os ajustes das RNAs, com a aplicação no treinamento da variável categórica “espécie”. Esses testes não resultaram em melhorias como o esperado. Tal fato pode ser explicado pela distribuição das variadas espécies e seus indivíduos nas florestas de mata nativa numa forma de “J-Invertido”, que de acordo com Barbour et al. (1987), na mata nativa, muitos indivíduos se apresentam nas menores classes de diâmetro que, individualmente, representam uma pequena parte do total da biomassa da população e poucos indivíduos nas classes superiores, que individualmente representam uma grande parte da biomassa total da população. Assim sendo, para se utilizar a variável “espécie” na aplicação das RNAs, é de bom senso realizar uma amostragem representativa da floresta, considerando uma maior amostragem dos indivíduos mais raros.

Tal implicação denota que podem acontecer casos em que uma árvore de determinada espécie não apareça no grupo de treinamento, mas se apresenta em um grupo de teste. Assim sendo, a RNA não consegue generalizar a partir de um conhecimento que não foi “aprendido” previamente.

Os gráficos de dispersão dos erros referente à estimativa do volume de forma consistente para com cada combinação são apresentados na Figura 39.

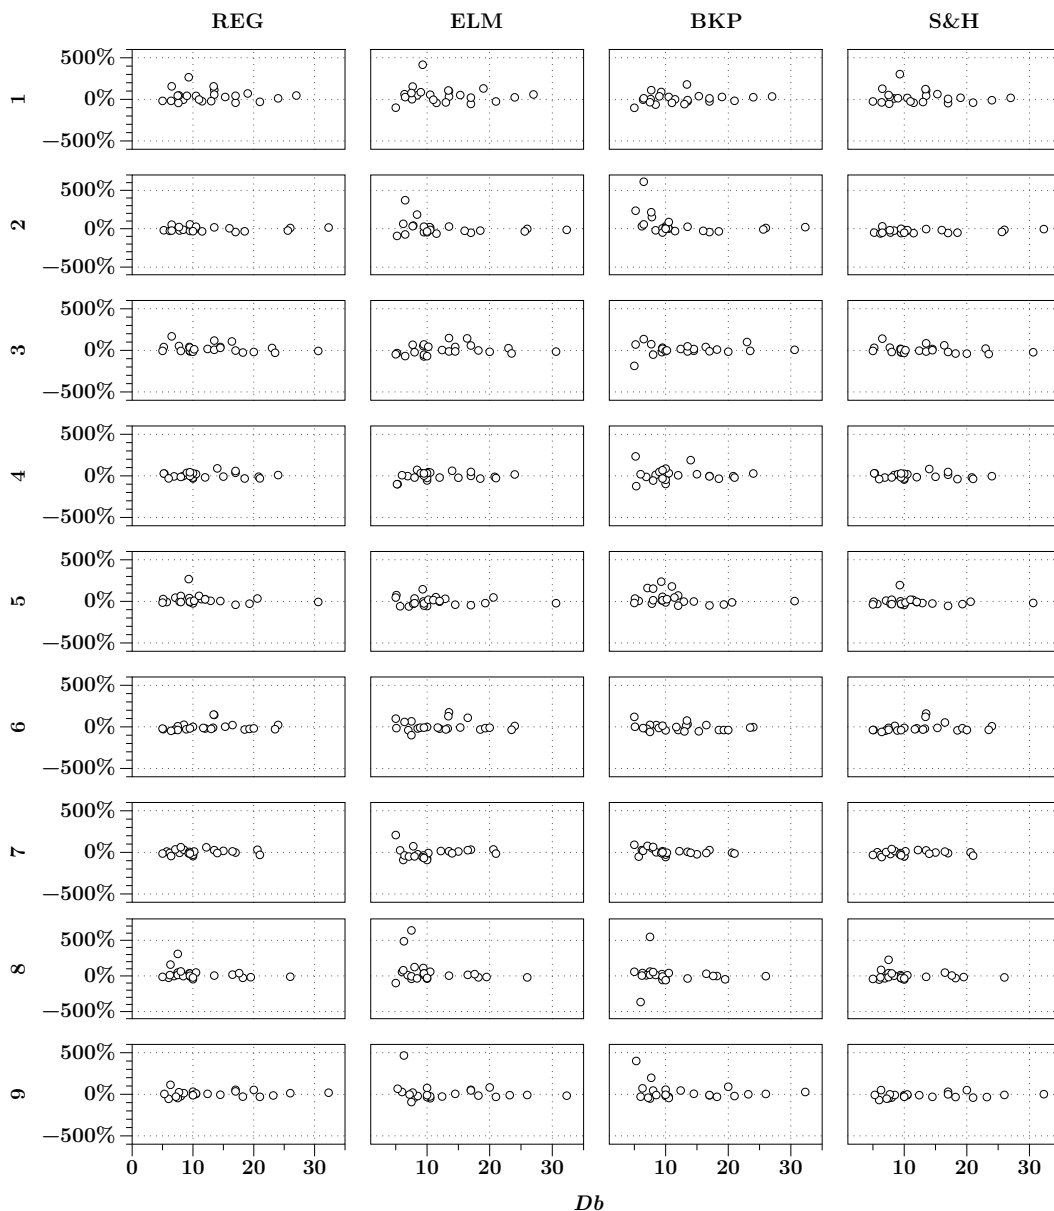


Figura 39: Dispersão de erros percentuais referentes à estimativa do volume de forma consistente para, com cada combinação dos métodos estudados

Na primeira combinação as RNAs, utilizando o treinamento BKP, obtiveram o melhor resultado, dentre os métodos estudados, a partir da análise visual do gráfico de dispersão. Mas, nos resultados referentes às combinações 2, 5, 8 e 9 as RNAs BKP não apresentaram bons resultados, com erros de amostras pontuais com deslocamento elevado em relação à média.

As RNAs, treinadas pelo método ELM, apresentaram bons resultados referentes à estimativa do volume de árvores do Cerrado de forma consistente com os resultados referentes às combinações de dados 3, 4 5 e 6. Já para as combinações 1, 2 8 e 9 este método já não respondeu bem. Tais erros são justificados pela má estimativa dos galhos utilizando-se este método, que pode ser associado à sub-amostragem ter dificultado a obtenção de uma melhor generalização.

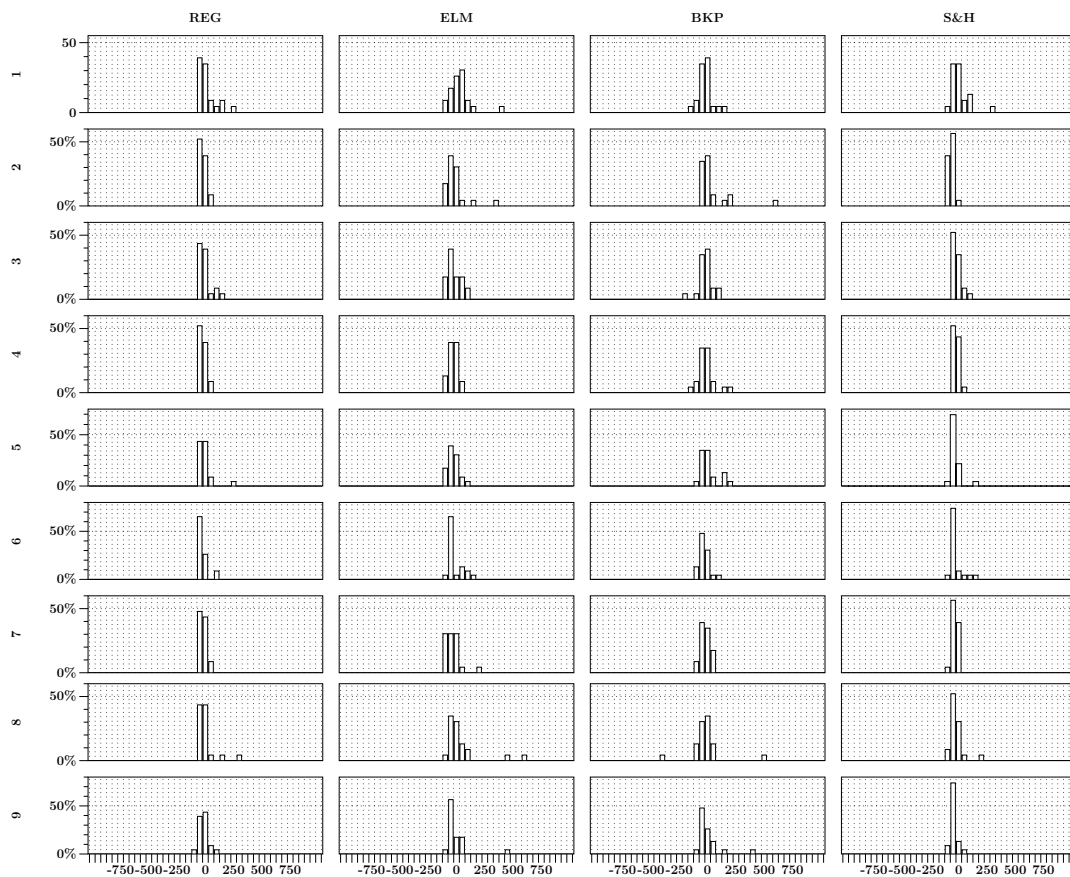


Figura 40: Frequência percentual dos erros percentuais referentes ao uso dos métodos REG, ELM, BKP e S&H, respectivamente, para cada combinação, do volume total das árvores do Cerrado

As Redes Neurais Artificiais treinadas por BKP obtiveram menor EMQ na estimativa do volume de forma consistente, mas ao se analisarem os gráficos de dispersão dos resultados referentes às 9 combinações de dados, os modelos estatísticos concentraram os erros mais próximos da média, mesmo que os erros das RNAs tenham sido pontuais.

5 Conclusões

As redes neurais artificiais podem ser utilizadas para estimar de forma consistente o volume de fuste e de galhos de árvores do Cerrado.

As estimativas geradas pelos modelos de regressão e pelas redes neurais artificiais, treinadas pelo algoritmo *back-propagation* e pela máquina de aprendizagem extrema se apresentaram semelhantes. No entanto, o algoritmo *back-propagation* apresentou resultados mais precisos na estimativa do volume de galhos em relação à máquina de aprendizagem extrema.

Verificou-se a importância de utilizar uma base de dados contendo informação suficiente para se dividir os dados nos grupos de treinamento, validação e teste. Com a base de dados utilizada neste estudo, não foi possível identificar qual é o melhor método para se estimar o volume de fuste e de galhos de árvores do Cerrado de forma consistente.

Parte IV

CONSIDERAÇÕES FINAIS

A máquina de aprendizagem extrema apresentou resultados semelhantes ao treinamento pelo método *back-propagation*, tanto pelo erro médio quadrático, quanto pela análise gráfica de resíduos, mas com tempo de treinamento e aplicação muito menor.

A facilidade de uso do método da máquina de aprendizagem extrema foi avaliada de forma positiva, pois alguns parâmetros como taxa de aprendizagem, desempenho da rede, número de iterações, não precisaram ser ajustados. Além de não haver a preocupação com parada em mínimos locais, o que pode ocorrer na aplicação do método *back-propagation*.

Outro ponto positivo na aplicação da máquina de aprendizagem extrema, está relacionado com a definição da arquitetura ou topologia da rede neural artificial, pois existe uma relação bem definida entre o número de neurônios na camada oculta e a resposta de erro médio quadrático, o que facilita a escolha da topologia.

No artigo 1, em que foi realizada a implementação e aplicação da técnica máquina de aprendizagem extrema na estimativa de altura de árvores de *Pinus*, o método se mostrou eficaz para estimar a altura das árvores, sendo que apresentou resultados semelhantes ao treinamento pelo algoritmo *back-propagation*, mas com menor custo computacional.

No artigo 2, em que, foi feita aplicação de redes neurais artificiais, para estimar de forma precisa e consistente os componentes, fuste e galhos, de árvores do Cerrado, não foi possível identificar, dentre os métodos estudados, qual é o mais indicado para se estimar o volume de fuste e de galhos de árvores do Cerrado de forma consistente, sendo que, as estimativas geradas pelas redes neurais artificiais e pelos modelos de regressão apresentaram resultados semelhantes. No entanto, as redes neurais artificiais podem ser utilizadas para estimar de forma consistente o volume de fuste e de galhos de árvores do Cerrado. Cabe ressaltar que, o algoritmo *back-propagation* apresentou resultados mais precisos na estimativa do volume de galhos em relação à máquina de aprendizagem extrema.

Referências Bibliográficas

- BARBOUR, M. G.; BURK, J. H.; PITTS, W. D. *Terrestrial Plant Ecology*. 2. ed. Menlo Park: The Benjamin/Cummings, 1987.
- BATALHA M.A.; MARTINS, F. Floristic, frequency, and vegetation life-form spectra of a cerrado site. *Brazilian Journal of Biology*, v. 64, n. 2, p. 201–209, 2004.
- BINOTI, M. L. M. da S. *Redes Neurais Artificiais para prognose da produção de povoamentos não desbastados de Eucalito*. Dissertação (Mestrado) — UFV, 2010.
- BINOTI, M. L. M. da S. *Emprego de redes neurais artificiais em mensuração e manejo florestal*. Tese (Doutorado) — UFV, 2012.
- BOUCKAERT, R. R. Choosing between two learning algorithms based on calibrated tests. In: *20th International Conference on Machine Learning*. [S.l.: s.n.], 2003. p. 51–58.
- BRAGA, A. P.; CARVALHO, A. C. P. L. F.; LUDERMIR, T. B. *Redes Neurais Artificiais, Teoria e Aplicações*. 2a. ed. [S.l.]: Livros Técnicos e Científicos (LTC), 2007.
- CAMPOS, J. C. C.; LEITE, H. G. *Mensuração florestal: perguntas e respostas*. 4. ed. [S.l.]: Viçosa: UFV, 2013. 605 p.
- CAMPOS, J. C. C. et al. Estimação de volumes do tronco e da copa de árvores de povoamentos mistos. *Revista Árvore*, v. 25, n. 4, p. 471–480, 2001.
- CORRÊA, C.; COSTA, D. A. *Estimativa de volume, biomassa e carbono da vegetação lenhosa de floresta estacional no estado de Goiás*. Dissertação (Mestrado) — Universidade de Brasília - UNB, 2011.
- CYBENKO, G. Approximation by superpositions of a sigmoid function. *Mathematics of Control, Signals and Systems*, v. 2, p. 303–314, 1989.
- DIAMANTOPOULOU, M. J. Artificial neural networks as an alternative tool in pine bark volume estimation. *Computers and Electronics in Agriculture*, v. 48, n. 3, p. 235–244, 2005.
- DIAMANTOPOULOU, M. J. Tree-bole volume estimation on standing pine trees using cascade correlation artificial neural network models. *Agricultural Engineering International: The CIGR Ejournal*, v. 8, 2006.
- DIAMANTOPOULOU, M. J.; MILIOS, E. Modelling total volume of dominant pine trees in reforestations via multivariate analysis and artificial neural network models. *Biosystems Engineering*, v. 105, n. 3, p. 306–315, 2010.
- FENG, G. et al. Error minimized extreme learning machine with growth of hidden nodes and incremental learning. *IEEE Transactions on Neural Networks*, v. 20, n. 8, august 2009.
- GÖRGENS, E. B. *Estimação do volume de árvores utilizando redes neurais artificiais*. 84 p. Dissertação (Mestrado) — UFV, 2006.
- GÖRGENS, E. B. et al. Estimação do volume de árvores utilizando redes neurais artificiais. *Revista Árvore*, v. 33, n. 6, p. 1141–1147, 2009.
- HAYKIN, S. *Redes Neurais, princípios e práticas*. 2a. ed. [S.l.]: Bookman, 2001.
- HUANG, G.-B.; CHEN, L.; SIEW, C.-K. Universal approximation using incremental constructive feedforward networks with random hidden nodes. *IEEE Transactions on Neural Networks*, v. 17, n. 4, 2006.

- HUANG, G.-B.; ZHU, Q.-Y.; SIEW, C.-K. Extreme learning machine: a new learning scheme of feedforward neural networks. *International Joint Conference on Neural Networks (IJCNN2004)*, Budapest, Hungary, v. 2, p. 25–29, 2004.
- HUANG, G.-B.; ZHU, Q.-Y.; SIEW, C.-K. Extreme learning machine: Theory and applications. *Neurocomputing*, v. 70, p. 489–501, 2006.
- HUSCH, B.; MILLER, C.; BEERS, T. *Forest mensuration*. 2a. ed. New York: The Ronald Press Co, 1972. 410 p.
- IMAÑA-ENCINAS, J.; PAULA, J. E. Análise da vegetação de cerrado no município de santa quitéria – maranhão. *Brasil Florestal*, Brasília, n. 78, p. 33–42, 2003.
- KOHAVI, R. A study of cross-validation and bootstrap for accuracy estimation and model selection. In: *International Joint Conference on AI*. [S.l.: s.n.], 1995. p. 1137–1145.
- MACHADO, R. B. et al. Estimativas de perda da área do cerrado brasileiro. *Conservation International do Brasil, Brasília.*, 2004.
- MATHWORKS. 2013. Disponível em: <<http://www.mathworks.com/>>.
- MENDONÇA, A. R.; CALEGARIO, N.; SILVA, G. F. Modelos hiposométricos e de crescimento em altura das árvores dominantes e codominantes para pinus caribaea var . hondurensis. *Scientia Forestalis*, p. 151–160, 2011.
- NETO, J. M. *Instituto de Engenharia Biomédica/UFSC*. Julho 2013. Disponível em: <http://www.ieb.ufsc.br/?page_id=139>.
- OLIVEIRA, A. D. et al. Avaliação econômica da vegetação de cerrado submetida a diferentes regimes de manejo e de povoamentos de eucaliptos plantado em monocultivo. *Cerne*, Lavras, v. 4, n. 1, p. 34–56, 1998.
- ÖZÇELİK, R. et al. Estimating tree bole volume using artificial neural network models for four species in turkey. *Journal of Environmental Management*, v. 91, n. 3, p. 742–753, 2010.
- PAULA, J. E.; IMAÑA-ENCINAS, J.; SUGIMOTO, N. Levantamento quantitativo em três hectares de vegetação de cerrado. *Pesquisa Agropecuária Brasileira*, Brasília, v. 33, n. 5, p. 613–620, 1998.
- RAO, C. R.; MITRA, S. K. *Generalized Inverse of Matrices and its Applications*. New York: Wiley, 1971.
- REZENDE, A. V. et al. Comparação de modelos matemáticos para estimativa do volume, biomassa e estoque de carbono da vegetação lenhosa de um cerrado *sensu stricto* em Brasília, DF. *Scientia Forestalis*, n. 71, p. 65–76, 2006.
- RIBEIRO, A. et al. Estratégias e metodologias de ajuste de modelos hipsométricos em plantios de *eucalyptus sp*. *Cerne*, v. 16, n. 1, p. 22–31, jan./mar. 2010.
- RUMELHART, D. E.; MCCLELLAND, J. L. A general framework for parallel distributed processing. in: Parallel distributed processing: explorations. In: *Learning internal representations by error propagation*. D. E. Rumelhart and J. L. McClelland (eds.). [S.l.]: MIT Press, 1986. p. 318–362.
- RUSSELL, S.; NORVIG, P. *Artificial Intelligence: A Modern Approach*. 2nd edition. ed. [S.l.]: Prentice-Hall, Englewood Cliffs, NJ, 2003.

- SCHUMACHER, F. X.; HALL, F. S. Logarithmic expression of timber-tree volume. *Journal of Agricultural Research*, v. 47, n. 9, p. 719–734, 1933.
- SCOLFORO, J.; SILVA, S. O conceito de “floresta balanceada de meyer” como opção para intervenção em cerrado sensu stricto. In: SBS (Ed.). *CONGRESSO FLORESTAL BRASILEIRO*. Curitiba: [s.n.], 1993. v. 1, p. 378–381.
- SILVA, I. N. da; SPATTI, D. H.; FLAUZINO, R. A. *Redes neurais artificiais: para engenharia e ciências aplicadas*. São Paulo: Artliber, 2010.
- SILVA, M. L. M. da et al. Ajuste do modelo de schumacher e hall e aplicação de redes neurais artificiais para estimar o volume de árvores de eucalipto. *Revista Árvore*, Viçosa: UFV, 2009.
- SOARES, F. A. A. et al. Recursive diameter prediction and volume calculation of eucalyptus trees using multilayer perceptron networks. *Computers and Electronics in Agriculture*, v. 78, n. 19-27, 2011.
- SOARES, F. A. A. et al. Recursive diameter prediction for calculating merchantable volume of eucalyptus clones without previous knowledge of total tree height using artificial neural networks. *Applied Soft Computing*, v. 12, p. 2030–2039, 2012.
- SOARES, F. A. A. M. N. et al. Multilayer perceptron na predição recursiva de diâmetros de clone de eucalipto. In: *Simpósio Brasileiro de Automação Inteligente*. São João Del Rei: [s.n.], 2011.
- WRAY, B.; BEJOU, D.; PALMER, A. Using neural network analysis to evaluate buyer-seller relationships. *European Journal of Marketing*, Bradford, v. 28, n. 10, p. 32–48, 1994.
- XIAO, R.; CARANDE, R.; GHIGLIA, D. A neural network approach for tree height estimation using ifsar data. *IEEE Transactions on Geoscience and Remote Sensing*, v. 36, n. 5, p. 345–348, 1998.