

UNIVERSIDADE FEDERAL DO PARANÁ

FRANCISCO DE ARAGÃO JUNIOR

Comparação entre uso das Redes Neurais Artificiais e o Uso de Técnicas
Estatísticas Tradicionais na Mensuração Florestal

CURITIBA
2017

FRANCISCO DE ARAGÃO JUNIOR

Comparação entre uso das Redes Neurais Artificiais e o Uso de Técnicas
Estatísticas Tradicionais na Mensuração Florestal

Trabalho de conclusão de curso
apresentado ao Curso de Pós Graduação
em Manejo Florestal de Precisão, do
Programa de Educação Continuada de
Ciências Agrárias, da Universidade
Federal do Paraná, como pré-requisito
para obtenção do título de especialista.

Orientador: Prof. Dr. Razer Anthom Nizer
Rojas Montaña.

CURITIBA
2017

Agradecimentos

Agradeço primeiramente a Deus e a Nossa Senhora por estarem sempre ao meu lado em todos os momentos, iluminando-me em minhas jornadas.

Aos meus espelhos, Francisco e Maria Jossileide, por me ensinarem os verdadeiros valores da vida. A meu irmão Isaac e meu sobrinho Henrico, pelo apoio, carinho e perseverança em todas as etapas dessa caminhada. A minha irmã Mayara, que além do apoio e carinho, mostrou-se fundamental no incentivo em momentos difíceis.

A minha namorada, Jheillanny Pereira de Macedo, pelo enorme apoio no desenvolvimento deste trabalho, mas principalmente pelo grande amor, carinho, perseverança, incentivo e paciência.

Ao meu orientador, Razer Anthom Nizer Rojas Montaña, pelo apoio e ensinamentos.

À professora Anabel Aparecida de Mello, pelos ensinamentos e pela perseverança, estando sempre disponível em me receber e a me ajudar.

A André Dias, Mônica Antunes, José, Maria, e todos da empresa, pela disponibilização e por permitirem que o trabalho pudesse se desenvolver da melhor forma.

A todos os professores do curso, por compartilharem seus conhecimentos no decorrer do curso.

RESUMO

Este trabalho teve como objetivo comparar os resultados obtidos na cubagem rigorosa de clones de eucalipto (base genética *Eucalyptus urophylla* X *Eucalyptus grandis*) com a utilização de redes neurais artificiais com os resultados obtidos através de modelos alométricos para estimativa de coeficientes de regressão, no Oeste da Bahia. Os dados são provenientes de um talhão de 42,52 hectares de povoamento clonal de Eucalipto (base genética *Eucalyptus urophylla* X *Eucalyptus grandis*) com 3 anos de idade, e, espaçamento 3,6 X 3,1 m, no Oeste da Bahia. Foram cubadas 50 árvores com classes diamétrica distintas, utilizando o método de Smalian, nas seguintes posições do fuste: 0,1; 0,5; 0,9; 1,3; 2,0; 4,0; 6,0 metros e assim até a altura comercial, com diâmetro mínimo de 4 cm. Para estimativa da altura total foram utilizados os modelos alométricos de Stoffels, Curtis e Prodan II, e para estimativa do volume foram utilizados os modelos alométricos de Spurr, Schumacher-Hall e Stoate. As configurações de RNA para estimativa de altura total e volume utilizadas foram do tipo *Multi Layer Perceptrons* (MLP). O processamento de dados, tanto para os modelos hipsométricos e volumétricos tanto para a Rede Neural Artificial, foi realizado em duas etapas, sendo a primeira etapa de Treinamento e a segunda etapa de Validação. A RNA 1 mostrou-se superior aos modelos hipsométricos avaliados, tanto na fase de treino quanto na fase de validação. O melhor modelo volumétrico avaliado no estudo mostrou-se ligeiramente superior, em seus parâmetros estatísticos, quando comparado ao uso de RNA na estimativa do volume dos indivíduos avaliados.

Palavras-chave: Cubagem Rigorosa. Rede Neural Artificial. Mensuração Florestal.

ABSTRACT

The objective of this work was to compare the results obtained in the rigorous counting of eucalyptus clones (*Eucalyptus urophylla* x *Eucalyptus grandis*) with the use of artificial neural networks with the results obtained using allometric models to estimate regression coefficients in Western Bahia. The data come from a plot of 42.52 hectares of clonal settlement of Eucalyptus (*Eucalyptus urophylla* x *Eucalyptus grandis*) at 3 years of age, and spacing 3.6 X 3.1 m in the west of Bahia. Fifty trees with distinct diametric classes were cubed, using the Smalian method, in the following positions of the stem: 0.1; 0.5; 0.9; 1.3; 2.0; 4.0; 6.0 meters and thus to commercial height, with a minimum diameter of 4 cm. The allometric models of Stoffels, Curtis and Prodan II were used to estimate the total height, and the allometric models of Spurr, Schumacher-Hall and Stoate were used for volume estimation. The RNA settings for total height and volume estimation were *Multi Layer Perceptrons* (MLP). The data processing, both for the hypsometric and volumetric models for both the Artificial Neural Network, was performed in two stages, being the first stage of Training and the second stage of Validation. RNA 1 was superior to the hypsometric models evaluated, both in the training stage and in the validation stage. The best volumetric model evaluated in the study was slightly superior, in its statistical parameters, when compared to the use of RNA in the estimated volume of the individuals evaluated.

Key words: Rigorous Counting. Artificial Neural Network. Forest Measurement.

LISTA DE TABELAS

TABELA 1 - MODELOS HIPSOMÉTRICOS COM SEUS COEFICIENTES E EQUAÇÕES AJUSTADAS.....	30
TABELA 2 - RESULTADO DO AJUSTE DOS MODELOS HIPSOMÉTRICOS NAS FASES DE TREINO, COM 80% DOS DADOS, E VALIDAÇÃO, COM 20% DOS DADOS, NA CUBAGEM DE 50 ÁRVORES DE EUCALIPTO COM IDADE DE TRÊS ANOS DE BASE GENÉTICA <i>EUCALYPTUS GRANDIS</i> E <i>EUCALYPTUS UROPHYLLA</i> , NO OESTE BAIANO.....	29
TABELA 3 - RESULTADO DAS REDES NEURAIS ARTIFICIAIS PARA ESTIMAÇÃO DA ALTURA TOTAL, NA FASE DE TREINO, COM 80% DOS DADOS, E VALIDAÇÃO, COM 20% DOS DADOS, NA CUBAGEM DE 50 ÁRVORES DE EUCALIPTO COM IDADE DE TRÊS ANOS DE BASE GENÉTICA <i>EUCALYPTUS GRANDIS</i> E <i>EUCALYPTUS UROPHYLLA</i> , NO OESTE BAIANO.....	35
TABELA 4 - COMPARAÇÃO DO MELHOR MODELO HIPSOMÉTRICO E DA MELHOR RNA PARA ESTIMAÇÃO DA ALTURA TOTAL, NA FASE DE TREINO, COM 80% DOS DADOS, E VALIDAÇÃO, COM 20% DOS DADOS, NA CUBAGEM DE 50 ÁRVORES DE EUCALIPTO COM IDADE DE TRÊS ANOS DE BASE GENÉTICA <i>EUCALYPTUS GRANDIS</i> E <i>EUCALYPTUS UROPHYLLA</i> , NO OESTE BAIANO.....	39
TABELA 5 - MODELOS VOLUMÉTRICOS COM SEUS COEFICIENTES E EQUAÇÕES AJUSTADAS.....	40

TABELA 6 - RESULTADO DO AJUSTE DOS MODELOS VOLUMÉTRICOS NA FASE DE TREINO, COM 80% DOS DADOS, E VALIDAÇÃO, COM 20% DOS DADOS, NA CUBAGEM DE 50 ÁRVORES DE EUCALIPTO COM IDADE DE TRÊS ANOS DE BASE GENÉTICA *EUCALYPTUS GRANDIS* E *EUCALYPTUS UROPHYLLA*, NO OESTE BAIANO.....40

TABELA 7 - RESULTADO DAS REDES NEURAIS ARTIFICIAIS PARA ESTIMATIVA DO VOLUME, NA FASE DE TREINO, COM 80% DOS DADOS, E VALIDAÇÃO, COM 20% DOS DADOS, NA CUBAGEM DE 50 ÁRVORES DE EUCALIPTO COM IDADE DE TRÊS ANOS DE BASE GENÉTICA *EUCALYPTUS GRANDIS* E *EUCALYPTUS UROPHYLLA*, NO OESTE BAIANO.....47

TABELA 8 - COMPARAÇÃO DO MELHOR MODELO VOLUMÉTRICO E DA MELHOR RNA PARA ESTIMAÇÃO DO VOLUME, NA FASE DE TREINO, COM 80% DOS DADOS, E VALIDAÇÃO, COM 20% DOS DADOS, NA CUBAGEM DE 50 ÁRVORES DE EUCALIPTO COM IDADE DE TRÊS ANOS DE BASE GENÉTICA *EUCALYPTUS GRANDIS* E *EUCALYPTUS UROPHYLLA*, NO OESTE BAIANO.....51

LISTA DE FIGURAS

FIGURA 1 - EXEMPLO DE ESTRUTURA DE UMA REDE NEURAL ARTIFICIAL.....	19
FIGURA 2 - DISTRIBUIÇÃO DOS RESÍDUOS EM PERCENTAGEM PARA O AJUSTE DO MODELO HIPSOMÉTRICO DE STOFFELS NA FASE DE TREINO.....	31
FIGURA 3 - DISTRIBUIÇÃO DOS RESÍDUOS EM PERCENTAGEM PARA O AJUSTE DO MODELO HIPSOMÉTRICO DE CURTIS NA FASE DE TREINO.....	31
FIGURA 4 - DISTRIBUIÇÃO DOS RESÍDUOS EM PERCENTAGEM PARA O AJUSTE DO MODELO HIPSOMÉTRICO DE PRODAN II NA FASE DE TREINO.....	31
FIGURA 5 - DISTRIBUIÇÃO DOS RESÍDUOS EM PERCENTAGEM PARA O AJUSTE DO MODELO HIPSOMÉTRICO DE STOFELLS NA FASE DE VALIDAÇÃO.....	32
FIGURA 6 - DISTRIBUIÇÃO DOS RESÍDUOS EM PERCENTAGEM PARA O AJUSTE DO MODELO HIPSOMÉTRICO DE CURTIS NA FASE DE VALIDAÇÃO.....	32
FIGURA 7 - DISTRIBUIÇÃO DOS RESÍDUOS EM PERCENTAGEM PARA O AJUSTE DO MODELO HIPSOMÉTRICO DE PRODAN II NA FASE DE VALIDAÇÃO.....	33
FIGURA 8 - ARQUITETURA DA RNA 1 PARA ALTURA TOTAL.....	33
FIGURA 9 - ARQUITETURA DA RNA 2 PARA ALTURA TOTAL.....	34
FIGURA 10 - ARQUITETURA DA RNA 3 PARA ALTURA TOTAL.....	34
FIGURA 11 - DISTRIBUIÇÃO DOS RESÍDUOS EM PERCENTAGEM PARA ESTIMATIVA DA ALTURA TOTAL DA RNA 1 NA FASE DE TREINO.....	36

FIGURA 12 - DISTRIBUIÇÃO DOS RESÍDUOS EM PERCENTAGEM PARA ESTIMATIVA DA ALTURA TOTAL DA RNA 2 NA FASE DE TREINO.....	36
FIGURA 13 - DISTRIBUIÇÃO DOS RESÍDUOS EM PERCENTAGEM PARA ESTIMATIVA DA ALTURA TOTAL DA RNA 3 NA FASE DE TREINO.....	37
FIGURA 14 - DISTRIBUIÇÃO DOS RESÍDUOS EM PERCENTAGEM PARA ESTIMATIVA DA ALTURA TOTAL DA RNA 1 NA FASE DE VALIDAÇÃO.....	37
FIGURA 15 - DISTRIBUIÇÃO DOS RESÍDUOS EM PERCENTAGEM PARA ESTIMATIVA DA ALTURA TOTAL DA RNA 2 NA FASE DE VALIDAÇÃO.....	38
FIGURA 16 - DISTRIBUIÇÃO DOS RESÍDUOS EM PERCENTAGEM PARA ESTIMATIVA DA ALTURA TOTAL DA RNA 3 NA FASE DE VALIDAÇÃO.....	38
FIGURA 17 - DISTRIBUIÇÃO DOS RESÍDUOS EM PERCENTAGEM PARA O AJUSTE DO MODELO VOLUMÉTRICO DE SPURR NA FASE DE TREINO.....	42
FIGURA 18 - DISTRIBUIÇÃO DOS RESÍDUOS EM PERCENTAGEM PARA O AJUSTE DO MODELO VOLUMÉTRICO DE SCHUMACHER-HALL NA FASE DE TREINO.....	42
FIGURA 19 - DISTRIBUIÇÃO DOS RESÍDUOS EM PERCENTAGEM PARA O AJUSTE DO MODELO VOLUMÉTRICO DE STOATE NA FASE DE TREINO.....	43
FIGURA 20 - DISTRIBUIÇÃO DOS RESÍDUOS EM PERCENTAGEM PARA O AJUSTE DO MODELO VOLUMÉTRICO DE SPURR NA FASE DE VALIDAÇÃO.....	44

FIGURA 21 - DISTRIBUIÇÃO DOS RESÍDUOS EM PERCENTAGEM PARA O AJUSTE DO MODELO VOLUMÉTRICO DE SCHUMACHER-HALL NA FASE DE VALIDAÇÃO.....	44
FIGURA 22 - DISTRIBUIÇÃO DOS RESÍDUOS EM PERCENTAGEM PARA O AJUSTE DO MODELO VOLUMÉTRICO DE STOATE NA FASE DE VALIDAÇÃO.....	45
FIGURA 23 - ARQUITETURA DA RNA 1 – VOLUME.....	46
FIGURA 24 - ARQUITETURA DA RNA 2 – VOLUME.....	46
FIGURA 25 - ARQUITETURA DA RNA 3 – VOLUME.....	46
FIGURA 26 - DISTRIBUIÇÃO DOS RESÍDUOS EM PERCENTAGEM DA ESTIMATIVA DE VOLUME DA RNA 1 NA FASE DE TREINO.....	48
FIGURA 27 - DISTRIBUIÇÃO DOS RESÍDUOS EM PERCENTAGEM DA ESTIMATIVA DE VOLUME DA RNA 2 NA FASE DE TREINO.....	48
FIGURA 28 - DISTRIBUIÇÃO DOS RESÍDUOS EM PERCENTAGEM DA ESTIMATIVA DE VOLUME DA RNA 3 NA FASE DE TREINO.....	49
FIGURA 29 - DISTRIBUIÇÃO DOS RESÍDUOS EM PERCENTAGEM DA ESTIMATIVA DE VOLUME DA RNA 1 NA FASE DE VALIDAÇÃO.....	50
FIGURA 30 - DISTRIBUIÇÃO DOS RESÍDUOS EM PERCENTAGEM DA ESTIMATIVA DE VOLUME DA RNA 2 NA FASE DE VALIDAÇÃO.....	50
FIGURA 31 - DISTRIBUIÇÃO DOS RESÍDUOS EM PERCENTAGEM DA ESTIMATIVA DE VOLUME DA RNA 3 NA FASE DE VALIDAÇÃO.....	50

LISTA DE EQUAÇÕES

EQUAÇÃO 1 – EQUAÇÃO DE SMALIAN.....	23
EQUAÇÃO 2 – MODELO HIPSONÉTICO DE STOFELLS.....	24
EQUAÇÃO 3 – MODELO HIPSONÉTICO DE CURTIS.....	24
EQUAÇÃO 4 – MODELO HIPSONÉTICO DE PRODAN II.....	24
EQUAÇÃO 5 – MODELO VOLUMÉTICO DE SPURR.....	25
EQUAÇÃO 6 – MODELO VOLUMÉTICO DE SCHUMACHER-HALL.....	25
EQUAÇÃO 7 – MODELO VOLUMÉTICO DE STOATE.....	25
EQUAÇÃO 8 - CORRELAÇÃO ENTRE A VARIÁVEL OBSERVADA E A VARIÁVEL ESTIMADA.....	26
EQUAÇÃO 9 – RAIZ QUADRADA DO ERRO MÉDIO.....	26
EQUAÇÃO 10 – RAIZ QUADRADA DO ERRO MÉDIO EM PORCENTAGEM.....	26

SUMÁRIO

1. INTRODUÇÃO.....	16
1.1. Mensuração Florestal.....	16
1.2. Redes Neurais Artificiais.....	18
1.3. Redes Neurais Artificiais na Mensuração Florestal.....	20
1.4. Objetivo.....	21
1.5. Justificativa.....	22
2. MATERIAL E MÉTODOS.....	23
2.1 Caracterização da Área de Estudo.....	23
2.2 Cubagem Rigorosa.....	23
2.3 Processamento dos Dados.....	24
2.3.1 Modelos Hipsométricos.....	24
2.3.2 Modelos Volumétricos.....	25
2.3.3 Rede Neural Artificial.....	26
2.4 Critérios de avaliação dos modelos hipsométricos e volumétricos e RNA.....	26
3. RESULTADOS E DISCUSSÃO.....	28

3.1 Relação Hipsométrica.....	28
3.1.1 Modelos Hipsométricos.....	28
3.1.2 RNA Altura.....	33
3.1.3 Modelo Hipsométrico X RNA.....	38
3.2 Relação Volumétrica.....	40
3.2.1 Modelos Volumétricos.....	40
3.2.2 RNA Volume.....	46
3.2.3 Modelo Volumétrico X RNA.....	51
3.3 Considerações.....	52
4. CONCLUSÕES.....	54
5. REFERÊNCIAS.....	56

1. INTRODUÇÃO

1.1 Mensuração Florestal

A avaliação do estoque dos produtos florestais é uma etapa fundamental dentro do manejo florestal. Como ferramenta utiliza-se o inventário florestal para estimar os produtos florestais existentes, como por exemplo, volume e biomassa. Nos levantamentos realizados em povoamentos florestais equiâneos, uma das variáveis de maior interesse é o volume (VENDRUSCOLO, et al., 2015). As principais variáveis coletadas são Diâmetro à Altura do Peito (DAP), idade (I) das árvores e a altura (H), sendo que essa última pode ser estimada por meio de relação hipsométrica.

O processo do inventário florestal se dá por meio de amostragens, coletando as variáveis de uma porção representativa da população, tendo como consequência a extrapolação do resultado da amostragem para a população, ou seja, estimando-se os valores das variáveis desejáveis da população.

Para as estimativas de volume empregam-se comumente os modelos volumétricos. Assim sendo, é necessário utilizar algum método de cubagem para determinar o volume das árvores amostra e, em geral, essa opção exige o abate das árvores previamente selecionadas e a medição de vários diâmetros ao longo do fuste (LEAL et al., 2015). A cubagem gera dados reais de volume das árvores amostra e esses dados são utilizados para ajustar os modelos volumétricos por meio de análise de regressão. Segundo Leite (2008), a cubagem implica na divisão do fuste das árvores em n seções, o que leva à medição de diâmetros sucessivos ao longo do tronco, consequentemente a soma dos volumes dessas seções resulta no volume da árvore. Os métodos de Newton, Huber e Smalian são os três principais métodos utilizados para cubagem rigorosa de árvores. Apesar de Smalian apresentar menor precisão, em relação aos demais, não há diferença significativa entre os resultados dos volumes, sendo mais viável utilizar a de Smalian, por conta da sua praticidade em campo quando comparada às outras duas metodologias (FRANCEZ et al., 2010).

Em estudo para ajustar e validar modelos volumétricos para a estimativa do volume de árvores de *Eucalyptus urophylla*, com vistas à redução do número de árvores a serem cubadas, Leal et al. (2015) utilizou os modelos volumétricos de Schumacher e Hall linearizado; Spurr; e, Kopecky-Gehhardt, afirmando que a equação ajustada de Schumacher e Hall estimou com precisão o volume das árvores em todos os cenários avaliados e apresentou estatísticas de ajuste e precisão, por meio do coeficiente de correlação entre a variável observada e estimada (r) e da percentagem do erro padrão da estimativa ($Sy\%$), bastante aceitáveis.

A relação hipsométrica é um instrumento essencial na prática tradicional do inventário florestal, pois esta técnica resulta numa sensível redução do custo de inventário, dado o elevado custo relativo da mensuração da altura comparada à do diâmetro (COSTA et al., 2006). A mensuração da altura demanda um maior tempo e acurácia de quem a realiza, comparada à mensuração do diâmetro, e como os custos dessa atividade geralmente decorrem em horas (R\$/hora), logo a mensuração da altura torna-se mais custosa do que a mensuração do diâmetro, por isso, adota-se a medição da altura de parte das árvores das parcelas, estimando a altura das outras árvores através de relação hipsométrica. Segundo Sbravati et al. (2014), durante a coleta de dados a determinação da altura das árvores em pé por meio de instrumentos é uma operação onerosa e sujeita a erros.

Diante da problemática envolvendo a medição da altura das árvores no inventário florestal, opta-se por medição do DAP de todos os indivíduos da parcela e apenas uma pequena parte desses indivíduos tem a sua altura medida em campo, sendo assim, utilizam-se modelos hipsométricos para estimar a altura das árvores não mensuradas em campo. Mendonça et al. (2015) afirmam que os modelos baseados em relações hipsométricas são ferramentas que ajudam na economia de tempo e capital nos inventários florestais.

Sousa et al. (2013) ajustaram e selecionaram modelos estatísticos adequados para estimar a variável altura total em dois povoamentos de *Eucalyptus urophylla*, manejados sob regime de alto fuste e de talhadia, no Sudoeste da Bahia. Ao todo foram avaliados oito modelos hipsométricos, entre

eles os modelos de Prodan, Curtis e Stoffels. Os autores afirmam que a maioria dos modelos ajustados para o regime de alto fuste apresentaram valores de coeficientes de determinação ajustados inferiores a 50%, com exceção do modelo de Prodan, que obteve 81,85%. Quanto mais próximo o valor do coeficiente de determinação ajustado for de 100% melhor será o ajuste do modelo.

Em trabalho realizado no Estado do Pará, com o intuito de avaliar a relação direta entre o Diâmetro à Altura do Peito (DAP) e a altura total de indivíduos jovens de Teca, Sanquetta et al. (2015) testaram seis modelos hipsométricos, utilizando como variável dependente a altura total e como variável independente o DAP. Além disso, os autores aplicaram a técnica da regressão linear simples e múltipla aos seis modelos testados. Segundo os autores, levando-se em conta os critérios gerais de ajuste, pode-se verificar que os modelos tiveram comportamentos semelhantes e, a princípio, com indicadores satisfatórios em termos de ajuste.

1.2 Redes Neurais Artificiais

As redes neurais artificiais (RNA) tentam simular o processamento de informações que ocorrem em nosso sistema nervoso por meio dos neurônios e suas sinapses. Na sua forma mais geral, uma rede neural é uma máquina que é projetada para modelar a maneira como o cérebro realiza uma tarefa particular ou função de interesse; a rede é normalmente implementada utilizando-se componentes eletrônicos ou é simulada por programação em um computador digital (HAYKIN, 2001).

RNA são sistemas paralelos distribuídos compostos por unidades de processamento simples (nodos) que calculam determinadas funções matemáticas (normalmente não lineares) (BRAGA et al., 2000). Essas unidades arranjam-se em uma ou mais camadas e interligam-se por meio de suas conexões, quase sempre em uma única direção (Figura 1). Essas conexões geralmente são associadas a pesos que armazenam o conhecimento representado pela rede e ponderam a entrada recebida por cada neurônio da rede (BRAGA et al., 2000).




Figura 1. Exemplo de estrutura de uma rede neural artificial.
Fonte: Binoti (2010).

Em uma RNA, a solução de problema inicia-se com a aprendizagem (ou treinamento), onde um conjunto de exemplos, geralmente denominado de conjunto de treinamento, é apresentado para a rede que extrai as características necessárias para representar a informação contida nos dados e gerar a resposta para o problema (BINOTI, 2010). Esse processo de treinamento é chamado de algoritmo de aprendizagem e tem por objetivo ajustar os pesos sinápticos da rede de forma ordenada para que se tenham os resultados esperados. Após a fase de aprendizagem a rede está pronta para aplicações posteriores, caso tenha a capacidade de generalizar, ou seja, gerar respostas coerentes para dados não conhecidos (BRAGA et al., 2000).

As redes neurais *MultiLayer Perceptron* (MLP), ou *Perceptron* de Múltiplas Camadas são redes que apresentam uma ou mais camadas intermediárias, comumente chamadas de camada oculta ou escondida (SILVA, 2009).

Em uma rede MLP, o processamento realizado por cada nodo é definido pela combinação dos processamentos realizados pelos nodos da camada anterior que estão conectados a ele (BRAGA et al., 2000). Segundo Silva (2009), cada camada da MLP possui uma função específica, sendo que a camada de entrada é composta por unidades sensoriais, as quais são responsáveis pela recepção e propagação das informações de entrada para a camada seguinte, sem modificá-las. Essa camada seguinte é denominada de camada intermediária, que é composta por unidades computacionais que

transmitem as informações por meio das conexões entre as unidades de entrada e saída. Essas camadas intermediárias guardam os pesos que serão multiplicados pelas entradas, garantindo o conhecimento da rede. Quando se segue da primeira camada intermediária em direção à camada de saída, as funções implementadas se tornam cada vez mais complexas, com isso, estas funções definem como é realizada a divisão do espaço de decisão (BRAGA et al., 2000). Por fim, a camada de saída recebe os dados da camada intermediária fornecendo a resposta à rede (SILVA, 2009).

A RNA do tipo *MultiLayer Perceptron* foi utilizada para estimação da altura e do volume de árvores de eucalipto, com resultados satisfatórios, por Binoti et al. (2013b); Vendruscolo et al. (2015); Leite et al. (2016).

1.3 Redes Neurais Artificiais na Mensuração Florestal

Ainda é recente o uso de RNA na pesquisa florestal, entretanto se apresenta como uma nova ferramenta apresentando resultados interessantes e sendo importante na tomada de decisões (SOUZA, 2015).

O uso de redes neurais está ganhando força a medida que surgem novos trabalhos comprovando a sua eficácia e praticidade, tanto em termos estatísticos quanto na redução de custos. Os principais parâmetros estatísticos utilizados para avaliar a qualidade das estimativas são o coeficiente de correlação entre as variáveis observadas e estimadas (r) e a raiz quadrada do erro médio (RQEM). Quanto maior for o valor de r e menor for o valor de RQEM melhor será a qualidade das estimativas. Segundo Silva (2016), a utilização das redes neurais artificiais para estimar o volume comercial e total de Eucalipto apresentou um alto valor r e uma baixa RQEM%. O uso das RNA para estimar a altura de povoamentos é eficiente e permite reduzir o número de medições em altura sem perda de precisão. É possível a redução no custo do inventário por meio da aplicação da RNA na estimação das alturas das árvores (BINOTI, 2013).

Diamantopoulou (2005) evidenciou que as RNA foram superiores em relação aos algoritmos de regressão não linear para estudar o volume de casca em *Pinus*, concluindo que as RNA têm grande potencial nas aplicações em modelagem florestal, sendo útil como alternativa às tradicionais. Binoti et al. (2014) relataram em seus estudos com *Eucalyptus spp.* que há ligeira

superioridade nas estimativas volumétricas com o uso das RNA sobre o modelo de Schumacher e Hall, contudo destaca a vantagem das RNA sobre o modelo alométrico pela inclusão de variáveis categóricas.

Em trabalho realizado nos estados da Bahia, Minas Gerais, São Paulo e Mato Grosso, com dados de cubagem de *Eucalyptus spp* e *Tectona grandis* L.f., Görgens (2006), afirma que a modelagem por redes neurais é perfeitamente viável, uma vez que no experimento a rede foi capaz de realizar a predição de volume de árvores para cinco locais e duas espécies.

As redes neurais artificiais (RNA) são capazes de ajustar dados com relações não lineares sem especificar previamente um modelo, diferindo da abordagem por regressão, além disso, a modelagem através de RNA permite a inclusão de variáveis qualitativas com facilidade (MARTINS et al., 2016). Variáveis como idade, material genético, índice de local, solo, interferem no desenvolvimento em altura e apresentam na maioria das vezes relações complexas e tendências muitas vezes não lineares, fazendo com que a inclusão dessas variáveis dificulte o ajuste de modelos hipsométricos. As RNA apresentam-se como uma ferramenta apropriada para serem utilizadas nessas situações, onde a inclusão de variáveis categóricas não é factível (BINOTI et al. 2012; BINOTI et al., 2009). Com essa vantagem e facilidade da inclusão de variáveis categóricas, com ganho de qualidade nas estimativas e facilidade de uso agregada, as empresas florestais podem optar por utilizar as RNA, ao invés dos modelos estatísticos tradicionais, para solucionar problemas que envolvem tomada de decisão (PELLI et al., 2014). Segundo Görgens (2006), os principais problemas ao conduzir inventários florestais é a definição de equações volumétricas apropriadas para cada estrato da floresta e a necessidade de atualizações anuais dessas equações, dando como possível solução o uso de RNA junto ao banco de dados de cubagem ao longo dos anos, com o objetivo de estimar o volume das árvores.

1.4 Objetivo

O objetivo do trabalho é realizar o ajuste de modelos alométricos para estimativa de coeficientes de regressão de altura total e volume e comparar com os ajustes para a estimação da altura total e do volume obtidos por meio de redes

neurais artificiais na cubagem rigorosa de clones de eucalipto (base genética *Eucalyptus urophylla* X *Eucalyptus grandis*).

1.5 Justificativa

Com os avanços tecnológicos na área florestal surge a necessidade de aperfeiçoamento em todos os setores da área, tais aperfeiçoamentos requerem uma maior produtividade com custos reduzidos. Dentro dessa tendência, as redes neurais artificiais apresentam-se como alternativa aos métodos tradicionais de estimativas por meio de análise de regressão, uma vez que a redução dos custos pode vir com o menor número de indivíduos amostrados, sem perdas na precisão das estimativas (ARAÚJO, 2015; SILVA et al., 2009; GÖRGENS, 2006).

Em alguns trabalhos foram observados melhora nas estimativas de altura total e volume por meio do uso das redes neurais artificiais e até mesmo a redução no custo do inventário florestal por meio dessa ferramenta (BINOTI et al., 2014; BINOTI et al., 2013a).

Com isso, a comprovação da eficiência e eficácia do uso das redes neurais artificiais, em comparação às técnicas tradicionais, deve ser ratificada para que o seu uso possa ser empregado de forma segura e confiável.

2. MATERIAL E MÉTODOS

2.1 Caracterização da Área de Estudo

Os dados utilizados no presente estudo foram provenientes de um talhão de 42,52 hectares de povoamento clonal de Eucalipto (base genética *Eucalyptus urophylla* X *Eucalyptus grandis*) com 3 anos de idade, e, espaçamento 3,6 X 3,1 m. O talhão pertence a uma empresa de base florestal, localizada no Oeste da Bahia, no município de São Desidério, com coordenadas 12° 50' 9,185" S 44° 52' 21,543" W, e altitude de 763 metros.

O clima, segundo a classificação de Köppen é do tipo Aw - Clima tropical, com inverno seco. Apresentando uma estação chuvosa no verão, de novembro a abril, e nítida estação seca no inverno, de maio a outubro (julho é o mês mais seco). A precipitação média anual é de 1.300 mm, sendo que os meses mais chuvosos são Novembro e Dezembro. O mês mais quente do ano é Setembro com temperatura média de 26,4°C, em contrapartida o mês mais frio é o de Junho, com média de temperatura de 23.0°C.

2.2 Cubagem Rigorosa

Dentro da área do talhão de 42,52 ha, foram cubadas 50 árvores com classes diamétricas distintas. O abate das árvores foi realizado por motosserra, e as medições de altura e diâmetro foram realizadas com trena e suta, respectivamente. As posições das medições de comprimento e diâmetro se deram nas seguintes posições do fuste: 0,1; 0,5; 0,9; 1,3; 2,0; 4,0; 6,0 metros e assim até a altura comercial, com diâmetro mínimo de 4 cm.

O método de cubagem rigorosa utilizado foi o de Smalian (Equação 1).

$$V_i = \frac{(S_1 + S_2)}{2} L \quad \text{Equação 1}$$

Onde:

V_i = Volume da seção (m³);

S_1 = Área seccional da extremidade inferior da seção (m²), onde:

$$S1 = \frac{\pi d1^2}{40000};$$

S2 = Área seccional da extremidade superior da seção (m²), onde:

$$S2 = \frac{\pi d2^2}{40000};$$

L = Comprimento da seção (m).

2.3 Processamento dos Dados

O processamento de dados, tanto para os modelos hipsométricos e volumétricos tanto para a Rede Neural Artificial, foi realizado em duas etapas, sendo a primeira etapa de Treinamento, com utilização de 80% dos dados coletados, e a segunda etapa de Validação, com 20% dos dados coletados.

Para o processamento dos dados foram utilizados os *softwares* Excel e Weka.

2.3.1 Modelos Hipsométricos

Os modelos hipsométricos ajustados foram: Modelo de Stoffels (Equação 2); Modelo de Curtis (Equação 3); e, Modelo de Prodan II (Equação 4). Esses modelos foram utilizados para ajuste de relação hipsométrica em *Eucalyptus "urograndis"* e mais três clones de eucalipto, no Nordeste do Pará e no estado de Mineiros, em Goiás (SANTOS et al., 2014; SILVA et al., 2013). O fator de Meyer (ε) foi aplicado aos modelos matemáticos estatísticos, a fim de corrigir o erro de discrepância logarítmica. De acordo com Silva, Corte e Sanquetta (2011), nas operações matemáticas logarítmicas existe um erro chamado de discrepância logarítmica, e para corrigir tal erro, aplica-se o fator de correção de Meyer, para modelos que utilizam logaritmo na base 10 e o logaritmo natural.

$$\ln ht = \beta_0 + \beta_1 \ln DAP + \varepsilon \quad \text{Equação 2}$$

$$\ln ht = \beta_0 + \beta_1 \frac{1}{DAP} + \varepsilon \quad \text{Equação 3}$$

$$ht = \frac{DAP^2}{\beta_0 + \beta_1 DAP + \beta_2 DAP^2} + 1,3 \quad \text{Equação 4}$$

Onde:

ln = logaritmo neperiano;

ht = altura total;

DAP = diâmetro à altura do peito (1,3 m);

ε = fator de Meyer;

$\beta_0, \beta_1, \beta_2$ = coeficientes da equação.

2.3.2 Modelos Volumétricos

Os modelos volumétricos ajustados foram: Modelo de Spurr (Equação 5); Modelo Linearizado de Schumacher-Hall (Equação 6); e, Modelo de Stoaate (Equação 7). Os modelos de Schumacher-Hall linearizado, Spurr e Stoaate foram ajustados para estimar o volume total de *Eucalyptus grandis* e *Eucalyptus urophylla* no Sudoeste Goiano (LEAL et al., 2015; MIGUEL, et al., 2010). Da mesma forma como utilizado nos modelos logarítmicos hipsométricos, o fator de Meyer também foi utilizado no modelo logarítmico volumétrico, para correção da discrepância logarítmica.

$$V = \beta_0 + \beta_1 DAP^2 ht$$

Equação 5

$$lnV = \beta_0 + \beta_1 lnDAP + \beta_2 lnht \times \varepsilon$$

Equação 6

$$V = \beta_0 + \beta_1 DAP^2 ht + \beta_2 DAP^2 + \beta_3 ht$$

Equação 7

Onde:

V = volume;

DAP = diâmetro à altura do peito (1,3 m);

ht = altura total;

ε = fator de Meyer;

ln = logaritmo neperiano;

$\beta_0, \beta_1, \beta_2, \beta_3$ = coeficientes da equação.

2.3.3 Rede Neural Artificial

A RNA utilizada em treinamento (80%) e validação (20%) dos dados foi do tipo *perceptrons* de múltiplas camadas (MLP), com processamento de dados na camada intermediária e na camada de saída, sendo a camada de entrada apenas para o recebimento dos dados e direcionamento destes para a camada intermediária. Para a classificação das instâncias foi utilizada a função *backpropagation*. O software Weka 3.8 foi utilizado para obtenção das RNA. A RNA do tipo MLP foi utilizada para estimativa de altura e volume em três clones de eucalipto e cinco tipos de solo na Bahia (BINOTI, 2012).

Foram selecionadas as três melhores configurações de RNA, tendo como primeira análise o número de neurônios na camada oculta que variou entre 1 a 100, com saltos de 1. Após a seleção das três melhores configurações de RNA em relação ao número de neurônios nas camadas ocultas, foram testadas as taxas de aprendizado e o *momentum*, que variaram entre 0,1 a 1,0, com saltos de 0,1.

2.4 Critérios de avaliação dos modelos hipsométricos e volumétricos e RNA

Os modelos hipsométricos e volumétricos e a RNA foram avaliados com base na correlação entre as variáveis observadas e estimadas (r), percentagem da raiz quadrada do erro médio (RQEM%) e dispersão dos resíduos percentuais.

$$r = \frac{\text{cov}(Y, \hat{Y})}{\sqrt{s^2(Y)s^2(\hat{Y})}} \quad \text{Equação 8}$$

$$\text{RQEM} = \sqrt{\frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n}} \quad \text{Equação 9}$$

$$\text{RQEM\%} = \frac{100}{\bar{Y}} \sqrt{\frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n}} \quad \text{Equação 10}$$

Onde:

r = correlação entre a variável observada e a variável estimada;

RQEM = raiz quadrada do erro médio;

RQEM% = raiz quadrada do erro médio em percentagem;

cov = covariância;

s^2 = variância;

Y = variável observada;

$\hat{Y}$ = variável estimada;

$\bar{Y}$ = média da variável observada;

n = número de amostras.

3. RESULTADOS E DISCUSSÃO

3.1 Relação Hipsométrica

3.1.1 Modelos Hipsométricos

As equações hipsométricas de Stoffels, Curtis e Prodan II foram ajustadas por meio de análise de regressão, para determinação dos coeficientes de suas equações. Utilizando os coeficientes das equações ajustados na análise de regressão e os dados das variáveis independentes (coletadas em campo) estimou-se a altura total de cada árvore. Ressalta-se que, para a realização da análise regressão foram utilizados os dados de 80% do total de árvores cubadas (fase de treino). Na fase de validação utilizou-se os 20% restantes dos dados das variáveis independentes nas equações já ajustadas através da análise de regressão que utilizou 80% dos dados. Na Tabela 1 estão dispostos os coeficientes e equações ajustadas de cada modelo hipsométrico.

Tabela 1. Modelos hipsométricos com seus coeficientes e equações ajustadas na cubagem de 50 árvores de eucalipto com idade de três anos e base genética *Eucalyptus grandis* e *Eucalyptus urophylla*, no Oeste Baiano.

Modelo Hipsométrico	Coeficientes			Equação Ajustada
	β_0	β_1	β_2	
Stoffels	1,2633	0,6139		$lnht = (1,2633 + 0,6139 \times lnDAP) \times 1,0006$
Curtis	3,2841	-6,0361		$lnht = \left(3,2841 + -6,0361 \times \frac{1}{DAP} \right) \times 1,0005$
Prodan II	6,4376	-0,8092	0,0912	$ht - 1,3 = \frac{DAP^2}{6,4376 - 0,8092 \times DAP + 0,0912 \times DAP^2}$

Onde: $\beta_0, \beta_1, \beta_2$ = coeficientes da equação; ln = logaritmo neperiano; ht = altura total; e, DAP = diâmetro à altura do peito.

Com os dados de altura total observada (coletadas em campo) e os dados de altura total estimada obteve-se o coeficiente de correlação (r) para cada equação hipsométrica ajustada, nas fases de treino e validação, com a utilização da Equação 8. Além disso, aplicando os dados da altura total observada e estimada na Equação 10, obteve-se o valor da raiz quadrada do erro médio (RQEM%) para cada equação hipsométrica ajustada, nas fases de treino e

validação. A obtenção dos resíduos das variáveis observadas e estimadas permitiu a construção dos Gráficos de Dispersão de Resíduos para cada equação hipsométrica ajustada, nas fases de treino e validação.

Dos três modelos hipsométricos avaliados, o modelo de Prodan II destacou-se pelo resultado obtido no r nas fases de treino e validação, com 0,8967 e 0,9277, respectivamente, sendo o modelo com o maior r em ambas as fases. Além disso, tal modelo obteve os melhores resultados para a RQEM% quando comparado aos modelos hipsométricos de Stoffels e Curtis, tanto na fase de treino quanto na fase de validação.

Tabela 2. Resultado do ajuste dos modelos hipsométricos nas fases de treino, com 80% dos dados, e validação, com 20% dos dados, na cubagem de 50 árvores de eucalipto com idade de três anos e base genética *Eucalyptus grandis* e *Eucalyptus urophylla*, no Oeste Baiano.

Modelo	Treino		Validação	
	r	RQEM(%)	r	RQEM(%)
Stoffels	0,8814	3,41	0,8978	2,91
Curtis	0,8895	3,28	0,9114	2,77
Prodan II	0,8967	3,18	0,9277	2,63

Onde: r = coeficiente de correlação; RQEM (%) = raiz quadrada do erro médio em percentagem.

Os modelos de Stoffels, Curtis e Prodan II, obtiveram valores satisfatórios de correlação na fase de treino, 0,8814, 0,8895 e 0,8967, respectivamente. Na fase de validação todos os modelos tiveram os valores de correlação aumentados, sendo o modelo de Prodan II o maior, com valor de r (coeficiente de correlação) igual a 0,9277. Oliveira (2014) ajustou os modelos hipsométricos de Curtis, Stoffels, Prodan II, Linha Reta e Parabólico, em uma cubagem de 40 árvores de *Tectona grandis* L. f (Teca) no Estado do Mato Grosso, e os resultados mostraram que o modelo de Prodan obteve o melhor valor do coeficiente de determinação ajustado (R^2_{ajus}). Os modelos de Stoffels e Curtis obtiveram valores de correlação na fase de validação de 0,8978 e 0,9114, respectivamente. Em estudo realizado para ajustar e selecionar modelos hipsométricos para estimação de altura total em povoamento clonal de *Eucalyptus urophylla* X *Eucalyptus grandis* no Distrito Federal, Jesus et al. (2015) encontrou resultados

superiores (em todos os parâmetros estatísticos utilizados no estudo) com o modelo de Curtis quando comparado ao modelo de Stoffels.

Embora os três modelos obtivessem valores de correlação satisfatórios, na fase de treino e validação, o modelo de Prodan II apresentou maior precisão na percentagem da Raiz Quadrada do Erro Médio (RQEM%), com valor de 3,18% na fase de treino, e 2,63% na fase de validação. Cabacinha (2003) em cubagem de 1819 clones de eucalipto (híbrido de *Eucalyptus grandis* x *Eucalyptus urophylla*) verificou que, independentemente da parcela, o modelo de Prodan em geral propiciou resultados ligeiramente superiores aos apresentados pelo modelo de Curtis, com pequenos erros padrões de resíduos. Os modelos de Curtis e Stoffels apresentaram valores satisfatórios de RQEM%, tanto na fase de treino quanto na fase de validação, sendo que o modelo de Curtis obteve o menor valor, com 3,28% na fase de treino, e 2,77% na fase de validação, sendo apenas menos preciso que o modelo de Prodan II.

Os gráficos de distribuição de resíduos para a altura estimada na fase de treino (Figura 2, Figura 3 e Figura 4) evidenciam que todos os modelos apresentaram comportamentos semelhantes, sendo que o modelo hipsométrico de Prodan II apresentou valores estimados levemente mais próximos à zero por cento. No estudo de Jesus et. al (2015), os gráficos de dispersão dos resíduos mostraram comportamentos semelhantes dos modelos de Stoffels, Curtis e Prodan II, por essa razão o erro padrão da estimativa passou a ser a estatística decisiva para selecionar o modelo mais indicado para a estimativa da altura, a qual indica uma ligeira superioridade no modelo de Prodan.




Figura 2. Distribuição dos resíduos em percentagem para o ajuste do modelo hipsométrico de Stoffels na fase de treino.




Figura 3. Distribuição dos resíduos em percentagem para o ajuste do modelo hipsométrico de Curtis na fase de treino.




Figura 4. Distribuição dos resíduos em percentagem para o ajuste do modelo hipsométrico de Prodan II na fase de treino.

Na fase de validação, os gráficos de resíduos da altura estimada dos modelos de Stofells, Curtis e Prodan II comportaram-se de maneira semelhante, sendo que o modelo de Prodan II obteve maior precisão no conjunto de dados avaliados, em comparação aos modelos hipsométricos de Stoffels e Curtis (Figura 5, Figura 6 e Figura 7).




Figura 5. Distribuição dos resíduos em percentagem para o ajuste do modelo hipsométrico de Stöffels na fase de validação.




Figura 6. Distribuição dos resíduos em percentagem para o ajuste do modelo hipsométrico de Curtis na fase de validação.




Figura 7. Distribuição dos resíduos em percentagem para o ajuste do modelo hipsométrico de Prodan II na fase de validação.

3.1.2 RNA Altura

Foram utilizadas três configurações de Rede Neural Artificial (RNA) para treino e validação dos dados da cubagem de 50 árvores de eucalipto no Oeste Baiano, com 1 neurônio na camada oculta na RNA 1, 2 neurônios na camada oculta na RNA 2, e 3 neurônios na RNA 3. As três RNA possuem apenas uma camada de entrada (Diâmetro à Altura do Peito – DAP) e saída (Altura) (Figura 2, Figura 3 e Figura 4). De acordo com Bullinaria (2015), para evitar sobreajuste no processamento da RNA é recomendável que se restrinja o número de parâmetros ajustáveis da rede, para isso é necessário a redução do número de unidades ocultas, ou seja, um número baixo de camadas intermediárias.




Figura 8. Arquitetura da RNA 1 para altura total, na cubagem de 50 árvores de eucalipto com idade de três anos e base genética *Eucalyptus grandis* e *Eucalyptus urophylla*, no Oeste Baiano. Fonte: WEKA.




Figura 9. Arquitetura da RNA 2 para altura total, na cubagem de 50 árvores de eucalipto com idade de três anos e base genética *Eucalyptus grandis* e *Eucalyptus urophylla*, no Oeste Baiano.
Fonte: WEKA.




Figura 10. Arquitetura da RNA 3 para altura total, na cubagem de 50 árvores de eucalipto com idade de três anos e base genética *Eucalyptus grandis* e *Eucalyptus urophylla*, no Oeste Baiano.
Fonte: WEKA.

Observou-se que na fase de treino o maior valor de r foi alcançado pela RNA 3, e os menores valores da Raiz Quadrada do Erro Médio em percentagem (RQEM%), na fase de treino, foram alcançados pelas RNA 2 e 3. Já na fase de validação a RNA 1 apresentou o maior resultado para r e o menor valor para RQEM%, com valores de 0,9373 e 2,44, respectivamente. Leite et al (2016), em estudo realizado em povoamentos de clones de *Eucalyptus urophylla* X *Eucalyptus grandis* no Sul da Bahia, obteve resultados satisfatórios nas estimativas da altura dominante utilizando RNA, com valores de r variando de 0,9235 a 0,9312, e valores de RQEM% variando entre 8,24 a 8,67. Vendruscolo et al (2015) avaliaram quatro configurações de RNA para estimar a altura total de indivíduos de eucalipto no município de Itiquira, MT, encontrando valores de r variando de 0,894 a 0,895 na fase de treino, além da RQEM% variando entre 9,34 e 9,38, para a mesma fase. Ainda de acordo com os autores, na fase de validação

os valores de r foram de 0,889 para todas as configurações de RNA utilizadas, e para a RQEM% os valores compreenderam-se entre 9,47 e 9,51.

Como na fase de validação existiu a inserção de novos dados à configuração ajustada da RNA, a configuração com apenas 1 neurônio na camada oculta (RNA 1) mostrou-se mais precisa, quando comparada às outras RNA, pois nesta fase a RNA 1 obteve os melhores resultados de r e da RQEM%. Os valores obtidos pelas três RNA, na fase de treino e validação, estão dispostos na Tabela 2.

Tabela 3. Resultado das Redes Neurais Artificiais para estimação da altura total, na fase de treino, com 80% dos dados, e validação, com 20% dos dados, na cubagem de 50 árvores de eucalipto com idade de três anos e base genética *Eucalyptus grandis* e *Eucalyptus urophylla*, no Oeste Baiano.

RNA	Arquitetura	Treino		Validação	
		R	RQEM(%)	R	RQEM(%)
RNA 1	1-1-1	0,9366	2,51	0,9373	2,44
RNA 2	1-2-1	0,9377	2,49	0,9367	2,46
RNA 3	1-3-1	0,9378	2,49	0,9367	2,47

Onde: RNA = rede neural artificial, r = coeficiente de correlação, e, RQEM% = raiz quadrada do erro médio em percentagem.

A distribuição dos resíduos das três RNA na fase de treino apresentaram-se de maneira semelhante, com exceção da RNA 1, a qual comportou-se de maneira diferente com os resíduos das estimativas próximas e acima a 15,5 metros, quando comparada ao comportamento das RNA 2 e 3. Mesmo assim, esse comportamento diferenciado da RNA 1 não ocasionou perda da qualidade na distribuição dos resíduos. Leite et al (2016), afirmou que a dispersão dos resíduos das RNA apresentaram comportamento semelhantes com leve tendência dos pontos de se aproximarem do eixo central, em relação aos modelos hipsométricos avaliados.

As RNA 2 e 3 apresentaram a melhor distribuição dos resíduos na fase de treino, com valores ligeiramente mais próximos ao zero por cento de resíduos, quando comparada à RNA 1.

Os resultados da distribuição dos resíduos para estimativa da altura total na fase de treino através das três RNA estão dispostos nas Figuras 11, 12 e 13.




Figura 11. Distribuição dos resíduos em percentagem para estimativa da altura total da RNA 1 na fase de treino, na cubagem de 50 árvores de eucalipto com idade de três anos e base genética *Eucalyptus grandis* e *Eucalyptus urophylla*, no Oeste Baiano.




Figura 12. Distribuição dos resíduos em percentagem para estimativa da altura total da RNA 2 na fase de treino, na cubagem de 50 árvores de eucalipto com idade de três anos e base genética *Eucalyptus grandis* e *Eucalyptus urophylla*, no Oeste Baiano.




Figura 13. Distribuição dos resíduos em percentagem para estimativa da altura total da RNA 3 na fase de treino, na cubagem de 50 árvores de eucalipto com idade de três anos e base genética *Eucalyptus grandis* e *Eucalyptus urophylla*, no Oeste Baiano.

Para a fase de validação, a RNA 1 apresentou resultado ligeiramente superior na distribuição dos resíduos da altura total estimada, quando comparada ao conjunto de dados das RNA 2 e 3 (Figura 14, Figura 15 e Figura 16). Avaliando os gráficos de dispersão de duas RNA distintas de Martins et al (2016), percebe-se que a rede treinada com poucos neurônios teve um bom desempenho na fase de validação, entretanto a rede treinada com mais neurônios apresentou bom desempenho na fase de treino, mas apresentou menor precisão na fase de validação.




Figura 14. Distribuição dos resíduos em percentagem para estimativa da altura total da RNA 1 na fase de validação, na cubagem de 50 árvores de eucalipto com idade de três anos e base genética *Eucalyptus grandis* e *Eucalyptus urophylla*, no Oeste Baiano.




Figura 15. Distribuição dos resíduos em percentagem para estimativa da altura total da RNA 2 na fase de validação, na cubagem de 50 árvores de eucalipto com idade de três anos e base genética *Eucalyptus grandis* e *Eucalyptus urophylla*, no Oeste Baiano.




Figura 16. Distribuição dos resíduos em percentagem para estimativa da altura total da RNA 3 na fase de validação, na cubagem de 50 árvores de eucalipto com idade de três anos e base genética *Eucalyptus grandis* e *Eucalyptus urophylla*, no Oeste Baiano.

Ressalta-se que as três configurações de RNA utilizadas neste trabalho obtiveram resultados satisfatórios, com eficácia nas estimativas da altura total.

3.1.3 Modelo Hipsométrico X RNA

O modelo hipsométrico de Prodan II, o qual apresentou melhor desempenho para estimar a altura total através do DAP, em um talhão de um povoamento clonal de eucalipto (base genética *Eucalyptus grandis* e *Eucalyptus*

urophylla) no Oeste da Bahia, foi comparado à RNA com melhor desempenho para a mesma finalidade. Os resultados dessa comparação estão apresentados na Tabela 3.

Tabela 4. Comparação do melhor modelo hipsométrico e da melhor RNA para estimação da altura total, na fase de treino, com 80% dos dados, e validação, com 20% dos dados, na cubagem de 50 árvores de eucalipto com idade de três anos e base genética *Eucalyptus grandis* e *Eucalyptus urophylla*, no Oeste Baiano.

Tipo	Treino		Validação	
	r	RQEM(%)	r	RQEM(%)
Prodan II	0,8967	3,18	0,9277	2,63
RNA 1	0,9366	2,51	0,9373	2,44

Onde: RNA = rede neural artificial, r = coeficiente de correlação, e, RQEM% = raiz quadrada do erro médio em percentagem.

A RNA 1 mostrou-se superior ao modelo hipsométrico de Prodan II, tanto na fase de treino quanto na fase de validação. Na fase de validação os valores de r e RQEM% da RNA 1 foram ligeiramente superiores aos valores do modelo de Prodan II, embora na fase de treino essa diferença mostrou-se mais elevada. Campos et al (2016) utilizaram os modelos hipsométricos de Campos et al. (1984), Curtis e Prodan II para estimar a altura total em um povoamento de *Pinus ssp.* e *Eucalyptus ssp.* na região do Triângulo Mineiro, em Minas Gerais, e ao compararem os resultados do melhor modelo hipsométrico ao resultado obtido pela RNA, observaram uma leve superioridade na acurácia das estimativas obtidas pela RNA em comparação às estimativas obtidas pela equação de regressão.

Mesmo a RNA 1 mostrando-se mais precisa na estimação da altura total quando comparada ao modelo de Prodan II, ambos apresentaram resultados satisfatórios nos parâmetros estatísticos coeficiente de correlação (r) e raiz quadrada do erro médio em percentagem (RQEM%) para estimar a altura total por meio do DAP na área de estudo.

3.2 Relações Volumétricas

3.2.1 Modelos Volumétricos

Na Tabela 5 estão apresentados os coeficientes e equações ajustadas para cada modelo volumétrico avaliado nesse estudo.

Tabela 5. Modelos volumétricos com seus coeficientes e equações ajustadas na cubagem de 50 árvores de eucalipto com idade de três anos e base genética *Eucalyptus grandis* e *Eucalyptus urophylla*, no Oeste Baiano.

Modelo Volumétrico	Coeficientes				Equação Ajustada
	β_0	β_1	β_2	β_3	
Spurr	0,0031	0,0003			$V = 0,0031 + 0,0003 \times DAP^2 ht$
Schumacher-Hall	-10,5932	1,5676	1,5079		$\ln V = (-10,5932 + 1,5676 \times \ln DAP + 1,5079 \times \ln ht) \times 1,0009$
Stoate	-0,0333	0,0002	0,0004	0,0032	$V = -0,0333 + 0,0002 \times DAP^2 ht + 0,0004 \times DAP^2 + 0,0032 \times ht$

Onde: $\beta_0, \beta_1, \beta_2, \beta_3$ = coeficientes da equação; v = volume; $\ln$ = logaritmo neperiano; ht = altura total; e, DAP = diâmetro à altura do peito.

Nas fases de treino e validação os modelos volumétricos de Spurr, Schumacher-Hall linearizado e Stoate apresentaram coeficiente de correlação acima de 0,9800, e valores abaixo de 5% para a raiz quadrada do erro médio em percentagem (RQEM%) (Tabela 4).

Tabela 6. Resultado do ajuste dos modelos volumétricos na fase de treino, com 80% dos dados, e validação, com 20% dos dados, na cubagem de 50 árvores de eucalipto com idade de três anos e base genética *Eucalyptus grandis* e *Eucalyptus urophylla*, no Oeste Baiano.

Modelo	Treino		Validação	
	r	RQEM(%)	R	RQEM(%)
Spurr	0,9809	4,90	0,9920	3,26
Schumacher-Hall	0,9855	4,28	0,9856	4,16
Stoate	0,9855	4,27	0,9845	4,32

Onde: r = coeficiente de correlação; RQEM (%) = raiz quadrada do erro médio em percentagem.

O modelo de Stoate obteve os melhores resultados na fase de treino, com valor de r igual a 0,9855 e RQEM% igual a 4,27. O modelo de linearizado de Schumacher-Hall apresentou, na fase de treino, o mesmo valor de r do modelo volumétrico de Stoate, sendo que o valor da RQEM% ficou muito próximo ao obtido pelo modelo de Stoate, com valor de 4,28.

Miranda, Junior e Gouveia (2015), ajustaram oito modelos volumétricos para estimar o volume total e comercial com casca de 20 árvores de *Eucalyptus urograndis*, e constataram que os valores do coeficiente de determinação ajustado (R^2 ajust) foram estatisticamente iguais para os modelos volumétricos de Spurr, Schumacher-Hall e Stoate, para a estimativa do volume total com casca, sendo que o modelo de Spurr apresentou o menor valor de R^2 ajust, com valor de 0,983, contra 0,984 dos modelos de Schumacher-Hall e Stoate. Ainda segundo os autores, para a estimativa de volume total com casca, não houve diferenciação nos valores do erro padrão da estimativa para os modelos volumétricos citados.

Na fase de validação (com inserção de dados novos ao modelo já ajustado) o modelo de melhor desempenho foi o de Spurr, com valor de r igual a 0,9920 e RQEM% igual a 3,26. Nesta fase, os modelos de Schumacher-Hall e Stoate apresentaram valores de r iguais a 0,9856 e 0,9845, respectivamente, assim como valores para a RQEM% de 4,16 e 4,32, respectivamente. O modelo volumétrico de Spurr mostrou-se ligeiramente superior ao modelo volumétrico de Schumacher-Hall no estudo de Loureiro et al (2012), em uma cubagem com 97 árvores de *Eucalyptus grandis* provenientes de um povoamento florestal no município de Balneário Pinhal, no Rio Grande do Sul.

As Figuras 17, 18 e 19 mostram o desempenho dos resíduos da estimativa do volume dos três modelos volumétricos avaliados na fase de treino. Os modelos de Schumacher-Hall e de Stoate apresentaram comportamento semelhante quanto aos resíduos da estimativa de volume das 40 árvores avaliadas na fase de treino, havendo uma leve superioridade do modelo de Stoate para o conjunto de dados avaliados nesta fase. Já modelo de Spurr apresentou comportamento levemente diferenciado e com maiores percentuais de resíduos para os volumes estimados, quando comparado aos modelos de Schumacher-Hall e Stoate.




Figura 17. Distribuição dos resíduos em percentagem para o ajuste do modelo volumétrico de Spurr na fase de treino, na cubagem de 50 árvores de eucalipto com idade de três anos e base genética *Eucalyptus grandis* e *Eucalyptus urophylla*, no Oeste Baiano.




Figura 18. Distribuição dos resíduos em percentagem para o ajuste do modelo volumétrico de Schumacher-Hall na fase de treino, na cubagem de 50 árvores de eucalipto com idade de três anos e base genética *Eucalyptus grandis* e *Eucalyptus urophylla*, no Oeste Baiano.




Figura 19. Distribuição dos resíduos em percentagem para o ajuste do modelo volumétrico de Stoate na fase de treino, na cubagem de 50 árvores de eucalipto com idade de três anos e base genética *Eucalyptus grandis* e *Eucalyptus urophylla*, no Oeste Baiano.

Melo et al (2013), em estudo para selecionar e avaliar a eficiência de três métodos para estimativa de volume de madeira para *Pinus caribaea* em Vitória da Conquista, Bahia, verificaram proximidade entre os volumes com casca total e comercial observados e os volumes estimados pelos modelos de Spurr e Stoate, com uma leve superioridade do modelo de Stoate em relação ao modelo de Spurr. No mesmo estudo, Melo et al (2013) afirmaram, através da análise de dispersão dos resíduos, que o modelo volumétrico de Stoate apresentou melhor desempenho para estimar o volume total sem casca, quando comparado ao modelo de Schumacher-Hall.

Em estudo realizado por Miguel et al (2010), para ajustar, comparar e escolher o melhor modelo volumétrico de simples e dupla entrada para obtenção do volume total em um povoamento de *Eucalyptus grandis*, no município de Rio Verde, Goiás, o modelo de Schumacher-Hall mostrou-se mais preciso aos modelos de Spurr e Stoate na estimativa de volume, apresentando boa distribuição no gráfico de resíduos.

As distribuições dos resíduos para estimação do volume na fase de validação mostram que os três modelos volumétricos avaliados na área de estudo comportaram-se de maneira semelhante, alternando-se entre os melhores valores percentuais de resíduos para cada volume estimado, não havendo assim, um modelo superior de maneira unânime (Figura 20, Figura 21 e Figura 22). Ao avaliarem a distribuição dos resíduos da estimativa de volume, Loureiro et al

(2012) observaram que o desempenho dos modelos de Spurr e Schumacher-Hall parece ser igual, tanto com a utilização de parâmetros obtidos conjuntamente quanto para os obtidos por classe de diâmetro.




Figura 20. Distribuição dos resíduos em percentagem para o ajuste do modelo volumétrico de Spurr na fase de validação, na cubagem de 50 árvores de eucalipto com idade de três anos e base genética *Eucalyptus grandis* e *Eucalyptus urophylla*, no Oeste Baiano.




Figura 21. Distribuição dos resíduos em percentagem para o ajuste do modelo volumétrico de Schumacher na fase de validação, na cubagem de 50 árvores de eucalipto com idade de três anos e base genética *Eucalyptus grandis* e *Eucalyptus urophylla*, no Oeste Baiano.




Figura 22. Distribuição dos resíduos em percentagem para o ajuste do modelo volumétrico de Stochastic na fase de validação, na cubagem de 50 árvores de eucalipto com idade de três anos e base genética *Eucalyptus grandis* e *Eucalyptus urophylla*, no Oeste Baiano.

Como houve similaridade entre os modelos na distribuição de resíduos na fase de validação, e uma pequena superioridade dos modelos volumétricos de Schumacher-Hall e Stochastic sobre o modelo de Spurr na fase de treino, o melhor modelo para estimar o volume total na área de estudo foi selecionado com base nos parâmetros de correlação entre a variável observada e estimada (r) e na raiz quadrada do erro médio em percentagem (RQEM%).

Como a fase de validação utiliza dados novos de DAP e altura total para a estimativa do volume, simulando assim, o uso do modelo ajustado no inventário florestal, o modelo volumétrico de Spurr, avaliado nesse estudo, foi o de melhor desempenho comparado aos outros modelos volumétricos avaliados. Tal situação assemelha-se ao estudo realizado por Miguel et al (2010), os quais, para uma maior confiabilidade na escolha do melhor modelo volumétrico, analisaram as estatísticas apresentadas pelo coeficiente de determinação ajustado ($R^2_{ajust.}$) e pelo erro padrão da estimativa ($Sy_x\%$) de cada modelo, uma vez que, os modelos avaliados pelos autores apresentaram desempenhos semelhantes na distribuição dos resíduos.

Embora o modelo de Spurr tenha sido o de melhor desempenho, os modelos volumétricos de Schumacher-Hall e Stochastic obtiveram resultados satisfatórios, validando, também, o seu uso para a estimativa do volume para a área de estudo.

3.2.2 RNA Volume

Foram utilizadas três configurações de Rede Neural Artificial (RNA) para treino e validação dos dados da cubagem de 50 árvores de eucalipto no Oeste Baiano, com 1 neurônio na camada oculta na RNA 1, 2 neurônios na camada oculta na RNA 2, e, 3 neurônios na RNA 3. As três RNA possuem duas camadas de entrada (DAP e Altura Total) e uma camada de saída (Volume) (Figura 5, Figura 6 e Figura 7).




Figura 23. Arquitetura da RNA 1 – Volume, na cubagem de 50 árvores de eucalipto com idade de três anos e base genética *Eucalyptus grandis* e *Eucalyptus urophylla*, no Oeste Baiano.
Fonte: WEKA.




Figura 24. Arquitetura da RNA 2 – Volume, na cubagem de 50 árvores de eucalipto com idade de três anos e base genética *Eucalyptus grandis* e *Eucalyptus urophylla*, no Oeste Baiano.
Fonte: WEKA.




Figura 25. Arquitetura da RNA 3 – Volume, na cubagem de 50 árvores de eucalipto com idade de três anos e base genética *Eucalyptus grandis* e *Eucalyptus urophylla*, no Oeste Baiano.
Fonte: WEKA.

Os valores obtidos pelas três RNA, na fase de treino e validação, estão dispostos na Tabela 5. Na fase de treino as três configurações de RNA apresentaram valores próximos para r e para a RQEM%, sendo que o melhor valor de r para essa fase foi obtido pela RNA 3, com 0,9860. Já o melhor valor da RQEM%, para a mesma fase, foi obtido pela RNA 2, com 4,32. Para a fase de validação, o melhor desempenho foi apresentado pela RNA 1, com valor de r igual a 0,9886 e valor da RQEM% igual a 3,67.

Através de dados provenientes de cubagens de 2700 árvores de povoamentos de clone de eucalipto, Binoti (2012) obteve valor de 0,9979 para o coeficiente de correlação entre as variáveis observadas e estimadas (r), e 4,18 para a raiz quadrada do erro médio em percentagem (RQEM%) na melhor configuração avaliada, utilizando 25 variáveis de entrada, dentre elas DAP, Altura Total e diâmetros com e sem casca ao longo do fuste, além de variáveis categóricas, 2 variáveis na camada oculta, com apenas uma variável na camada de saída, correspondente ao volume.

Diante dos resultados, a RNA 1, com apenas um neurônio na camada oculta, mostrou-se mais eficiente na estimativa do volume total na área de estudo, uma vez que, na fase de validação obteve os melhores resultados para r e para a RQEM%.

Binoti, Binoti e Leite (2014), na cubagem de 2307 árvores de um povoamento de eucalipto (*Eucalyptus grandis* x *Eucalyptus urophylla*), obtiveram resultados satisfatórios na estimativa de volume com configurações de apenas um neurônio na camada oculta, mostrando que redes de estruturas complexas não são necessárias para a estimação do volume de árvores.

Tabela 7. Resultado das Redes Neurais Artificiais para estimativa do volume, na fase de treino, com 80% dos dados, e validação, com 20% dos dados, na cubagem de 50 árvores de eucalipto com idade de três anos e base genética *Eucalyptus grandis* e *Eucalyptus urophylla*, no Oeste Baiano.

RNA	Arquitetura	Treino		Validação	
		r	RQEM(%)	r	RQEM(%)
RNA 1	2-1-1	0,9843	4,47	0,9886	3,67
RNA 2	2-2-1	0,9858	4,32	0,9864	4,07
RNA 3	2-3-1	0,9860	4,38	0,9865	4,17

Onde: RNA = rede neural artificial, r = coeficiente de correlação, e, RQEM% = raiz quadrada do erro médio em percentagem.

Os resultados da distribuição dos resíduos para estimativa do volume na fase de treino através das três configurações de RNA estão dispostos nas Figuras 26, 27 e 28. Para estimativa de volume abaixo de 0,04 m³ houve uma leve diferenciação no comportamento dos resíduos das três RNA avaliadas, sendo que as RNA 2 e 3 apresentaram uma pequena superioridade nas estimativas de volume nessa faixa de volume estimado. Já para volumes estimados acima de 0,04 m³, o comportamento dos resíduos das três RNA se apresentou de forma semelhante, não havendo unanimidade de apenas uma RNA.




Figura 26. Distribuição dos resíduos em percentagem da estimativa de volume da RNA 1 na fase de treino, na cubagem de 50 árvores de eucalipto com idade de três anos e base genética *Eucalyptus grandis* e *Eucalyptus urophylla*, no Oeste Baiano.




Figura 27. Distribuição dos resíduos em percentagem da estimativa de volume da RNA 2 na fase de treino, na cubagem de 50 árvores de eucalipto com idade de três anos e base genética *Eucalyptus grandis* e *Eucalyptus urophylla*, no Oeste Baiano.




Figura 28. Distribuição dos resíduos em percentagem da estimativa de volume da RNA 3 na fase de treino, na cubagem de 50 árvores de eucalipto com idade de três anos e base genética *Eucalyptus grandis* e *Eucalyptus urophylla*, no Oeste Baiano.

Araújo et al (2016), ao avaliarem cinco configurações diferentes de RNA para estimativa de volume de um híbrido clonal de *Eucalyptus grandis* x *Eucalyptus urophylla*, observaram que, na fase de treino, as estimativas para volumes mais baixos apresentaram comportamentos diferenciados nas cinco configurações na distribuição dos resíduos, entretanto, para valores maiores de volume os resíduos das estimativas comportaram-se de maneira semelhante para as cinco RNA avaliadas.

Para a fase de validação, as três configurações obtiveram o mesmo comportamento, no entanto, a RNA 1 mostrou-se levemente superior na distribuição dos resíduos da estimação do volume de 10 árvores cubadas nesta fase, em relação as RNA 2 e 3 (Figura 29, Figura 30 e Figura 31). OS gráficos de dispersão dos resíduos das quatro configurações de RNA utilizadas por Binoti (2012) na estimativa de volume de árvores de eucalipto mostraram baixa dispersão dos valores estimados em relação ao eixo das abcissas, além disso, apresentaram comportamentos semelhantes entre si.




Figura 29. Distribuição dos resíduos em percentagem da estimativa de volume da RNA 1 na fase de validação, na cubagem de 50 árvores de eucalipto com idade de três anos e base genética *Eucalyptus grandis* e *Eucalyptus urophylla*, no Oeste Baiano.




Figura 30. Distribuição dos resíduos em percentagem da estimativa de volume da RNA 2 na fase de validação, na cubagem de 50 árvores de eucalipto com idade de três anos e base genética *Eucalyptus grandis* e *Eucalyptus urophylla*, no Oeste Baiano.




Figura 31. Distribuição dos resíduos em percentagem da estimativa de volume da RNA 3 na fase de validação, na cubagem de 50 árvores de eucalipto com idade de três anos e base genética *Eucalyptus grandis* e *Eucalyptus urophylla*, no Oeste Baiano.

Embora a RNA 1 tenha sido a de melhor desempenho, as outras configurações de RNA obtiveram resultados satisfatórios, validando, também, o seu uso para a estimativa do volume para a área de estudo.

3.2.3 Modelo Volumétrico X RNA

O modelo volumétrico de Spurr, o qual apresentou melhor desempenho para estimativa do volume através do DAP e da altura total, em um talhão de um povoamento clonal de eucalipto (base genética *Eucalyptus grandis* e *Eucalyptus urophylla*) no Oeste da Bahia, foi comparado à RNA com melhor desempenho para a mesma finalidade. Os resultados dessa comparação estão apresentados na Tabela 6.

Tabela 8. Comparação do melhor modelo volumétrico e da melhor RNA para estimação do volume, na fase de treino, com 80% dos dados, e validação, com 20% dos dados, na cubagem de 50 árvores de eucalipto com idade de três anos e base genética *Eucalyptus grandis* e *Eucalyptus urophylla*, no Oeste Baiano.

Tipo	Treino		Validação	
	r	RQEM(%)	R	RQEM(%)
Spurr	0,9809	4,90	0,9920	3,26
RNA 1	0,9843	4,47	0,9886	3,67

Onde: RNA = rede neural artificial, r = coeficiente de correlação, e, RQEM% = raiz quadrada do erro médio em percentagem.

Na fase de treino, a RNA 1 mostrou-se mais eficiente quando comparada ao modelo volumétrico de Spurr, com valores de r e RQEM% superiores ao do modelo volumétrico. Entretanto, ao inserir novos dados de DAP e altura total (fase de validação), o modelo volumétrico de Spurr apresentou-se de maneira superior a RNA 1, com valor de r igual a 0,9920 contra 0,9886 da RNA 1, e, valor de RQEM% de 3,26 para o modelo de Spurr e 3,67 para a RNA 1.

Araújo et al (2016) ao comparar os resultados obtidos por modelo volumétrico com os resultados obtidos por RNA, obtiveram valores próximos para a RQEM%, com 4,92 para a RNA e 5,06 para o modelo volumétrico avaliado, já

para o coeficiente de correlação (r) os valores foram iguais (0,9978) para o modelo e para a RNA avaliados. Já Souza (2015), encontrou superioridade da RNA sobre o modelo volumétrico avaliado para estimativa de volume total de *Eucalyptus spp.*

O modelo de Spurr mostrou maior eficiência na estimativa do volume, utilizando o DAP e a altura total, em comparação a RNA 1, devido a sua leve superioridade na fase de validação. Entretanto, a RNA 1 obteve valores satisfatórios para a estimação do volume total na área de estudo através do DAP e da altura total, podendo ser utilizada para tal estimativa. Esse fato pode ter ocorrido devido a maior homogeneidade dos dados coletados, onde o modelo de Spurr conseguiu estimar de maneira precisa o volume dos indivíduos.

3.3 Considerações

Para a fase de processamento dos dados de campo por meio de modelos alométricos foi preciso obter os valores das variáveis específicas de cada modelo, tais variáveis específicas são geradas através das variáveis independentes da equação. Além disso, é preciso obter os coeficientes da equação através de uma análise de regressão.

O processamento dos dados de campo utilizando as RNA necessita apenas da geração do arquivo de entrada exigido pelo software, que detém a função RNA, contendo os valores das variáveis coletadas em campo, não sendo necessária a obtenção de outras variáveis a partir destas. Após a geração do arquivo de entrada é necessário realizar as configurações da RNA para que se chegue a um resultado satisfatório, sendo indicado testar configurações diferentes a fim de extrair o melhor resultado possível.

A RNA apresentou maior velocidade no processamento dos dados, quando compara ao uso de modelos alométricos tradicionais. Entretanto, o conhecimento e a prática de quem processa e avalia as diferentes configurações das RNA se torna um fator decisivo para obter a melhor configuração em menor tempo. Montañó (2016) afirma que as RNA possuem baixo tempo de treinamento e maior facilidade em seu entendimento e manuseio, em seu estudo que evidenciou, também, que os resultados obtidos através das RNA e Máquinas de Vetores de Suporte (SVM) foram superiores aos resultados obtidos por modelos

alométricos, nos experimentos com Acácia Negra, para avaliação de biomassa e relação hipsométrica; Pinus, para estimativa de volumes e relação hipsométrica; e, árvores de florestas tropicais de várias regiões do mundo, para estimativa de biomassa.

A qualidade das estatísticas de ambos os métodos avaliados através dos parâmetros estatísticos coeficiente de correlação e raiz quadrada do erro médio em percentagem apresentaram resultados precisos.

Constatou-se que, através dos parâmetros estatísticos utilizados, a RNA foi superior ao modelo tradicional na estimação da altura total dos indivíduos. Entretanto, para a estimação do volume o modelo alométrico tradicional mostrou maior precisão em tais parâmetros.

A inserção de novos dados de classes de diâmetro, material genético, de idades diferentes, ou até mesmo de diferentes locais, pode oferecer as Redes Neurais um maior poder de extração dos dados, podendo aumentar a sua precisão nos dados de volumes estimados. Loureiro et al. (2012), utilizando modelos alométricos para estimativa do volume, evidenciou que a separação das árvores por classes diamétricas para a obtenção de volume não apresentou vantagem em relação a obtenção de forma conjunta. Sendo assim, a inserção de dados das classes diamétricas poderá oferecer às RNA um maior poder de extração e conseqüentemente uma maior precisão na estimativa do volume, comparadas aos modelos alométricos. Estudos posteriores na área de estudo poderão comprovar tais suposições.

4. CONCLUSÕES

O melhor modelo hipsométrico avaliado foi o de Prodan II, o qual obteve os valores mais precisos de coeficiente de correlação (r) e raiz quadrada do erro médio em percentagem (RQEM%) na fase de validação.

Embora as configurações de rede neural do tipo *MultiLayer Perceptrons* (MLP) com dois e três neurônios na camada oculta obtivessem os valores de r e RQEM% mais precisos na fase de treinamento, a que mostrou-se mais precisa foi a configuração com apenas um neurônio na camada oculta, a qual apresentou maior valor de r e menor valor de RQEM% na fase de validação.

As Redes Neurais Artificiais apresentaram leve superioridade na precisão da estimativa da altura total na área de estudo em comparação ao melhor modelo hipsométrico avaliado.

O modelo volumétrico de Spurr mostrou-se mais preciso quando comparado aos modelos de Schumacher-Hall linearizado e Stoate, uma vez que apresentou maior precisão nas estimativas de volume na fase de validação, através dos parâmetros estatísticos coeficiente de correlação e raiz quadrada do erro médio em percentagem, mesmo embora, os modelos volumétricos de Schumacher-Hall linearizado e de Stoate apresentassem maior precisão nos parâmetros na fase de treino.

Assim como ocorreu na estimação da altura total através das RNA do tipo MLP, a configuração com apenas um neurônio na camada oculta mostrou-se mais precisa na estimação do volume na fase de validação, mesmo que na fase de treino as RNA com dois e três neurônios apresentassem valores mais precisos de r e RQEM%. Sendo assim, a configuração com apenas um neurônio na camada oculta apresentou-se mais precisa na estimação do volume dos indivíduos avaliados na área de estudo.

O melhor modelo volumétrico avaliado no estudo mostrou-se ligeiramente superior, em seus parâmetros estatísticos, quando comparado ao uso de RNA na estimativa do volume dos indivíduos avaliados.

A análise dos gráficos de dispersão corrobora com os resultados obtidos através dos parâmetros estatísticos r e RQEM% na estimação da altura total, tanto para os modelos alométricos tanto para as RNA, e na estimação do volume,

com uso dos modelos alométricos e com uso de RNA, nas fases de treino e validação.

O processamento dos dados se deu de maneira mais rápida com a utilização das RNA, em relação ao uso de modelos alométricos tradicionais, apresentando maior simplicidade e praticidade em tal processamento.

Através dos parâmetros estatísticos r e $RQEM\%$, além da análise dos gráficos de resíduos, verificou-se que o uso das RNA na estimação da altura total foi ligeiramente superior aos modelos alométricos tradicionais, que utilizam a regressão para determinação dos coeficientes da equação. Entretanto, na estimação do volume, o melhor modelo volumétrico mostrou uma leve superioridade na precisão dos parâmetros estatísticos quando comparado à melhor configuração de RNA.

Portanto, devido a maior velocidade e praticidade no processamento dos dados e, estatisticamente, igual ou maior precisão na estimação das variáveis altura total e volume, quando comparado ao uso de técnicas tradicionais de estimação da altura total e volume, o uso das RNA mostram qualidade, confiança e segurança na estimação de tais variáveis.

5. REFERÊNCIAS

ARAÚJO, B. H. P. **Modelagem da altura, volume e afilamento do fuste de *Calycophyllum spruceanum* Benth. empregando regressão e redes neurais artificiais.** Dissertação (Mestrado). Instituto de Pesquisas da Amazônia, 2015. Acesso em: 27/08/2016. Disponível em: <<http://bdtd.inpa.gov.br/handle/tede/1885>>.

ARAÚJO, T. A.; MOTA, F. C. M.; PEREIRA, R. S.; MIGUEL, E. P.; LUSTOSA JÚNIOR, I. M. **Técnicas de modelagem florestal empregadas na estimativa volumétrica de eucalipto.** Enciclopédia Biosfera, Centro Científico Conhecer - Goiânia, v.13 n.24; p. 1011 – 1026, 2016.

BATISTA, J. L. F.; COUTO, H. T. Z.; MARQUESINI, M. **Desempenho de modelos de relações hipsométricas: estudo em três tipos de floresta.** SCIENTIA FORESTALIS n. 60, p. 149-163, 2001.

BINOTI, D. H. B.; BINOTI, M. L. M. S.; LEITE, H. G.; GARCIA, S. L. R.; FERREIRA, M. Z.; RODE, R.; SILVA, A. A. L. **Configurações de redes neurais artificiais para estimação do volume de árvores.** Revista Árvore, Viçosa-MG, v.38, n.2, p.283-288, 2014. Acesso em: 27/08/2016. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S010067622014000200008>.

BINOTI, D. H. B.; BINOTI, M. L. M. S.; LEITE, H. G. **Configuração de redes neurais artificiais para estimação do volume de árvores.** Ciência da Madeira (Braz. J. Wood Sci.), Pelotas, v. 05, n. 01, p. 58-67, 2014.

BINOTI, D. H. B., BINOTI, M. L. M. da S.; LEITE, H. G.; SILVA, A. **Redução dos custos em inventário de povoamentos equiâneos.** Revista Brasileira de Ciências Agrárias, Recife, v.8, n.1, p.125-129, 2013a. Acesso em : 25/08/2016. Disponível em: <http://www.agraria.pro.br/sistema/index.php?journal=agraria&page=article&op=viewArticle&path%5B%5D=agraria_v8i1a2209>

BINOTI, M. L. M. da S.; BINOTI, D. H. B.; LEITE, H. G. **Aplicação de redes neurais artificiais para estimação da altura de povoamentos equiâneos de eucalipto**. Revista Árvore, Viçosa-MG, v.37, n.4, p.639-645, 2013b. Acesso em: 25/08/2016. Disponível em:<<http://www.redalyc.org/articulo.oa?id=48828747007>>.

BINOTI, M. L. M. da S. **Emprego de redes neurais artificiais em mensuração e manejo florestal**. Tese (*Doctor Scientiae*) - Universidade Federal de Viçosa. Viçosa-MG, 2012. Acesso em: 25/08/2016. Disponível em:<<http://www.bibliotecaflorestal.ufv.br/handle/123456789/9927>>.

BINOTI, M. L. M. da S. **Redes neurais artificiais para prognose da produção de povoamentos não desbastados de eucalipto**. Dissertação (mestrado) - Universidade Federal de Viçosa. Viçosa-MG, 2010. Acesso em: 25/08/2016. Disponível em:<<http://www.locus.ufv.br/handle/123456789/3030>>.

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

BRAGA, A. de P.; CARVALHO, A. P. de L. F. de; LUDEMIR, T. B. **Redes Neurais Artificiais: Teorias e Aplicações**. 1 ed. Rio de Janeiro LTC, 2000.

BULLINARIA, J. A. **Bias and variance, under-fitting and over-fitting: notas de aula**. 2015. Acesso em: 18/01/2017. Disponível em: <<http://www.cs.bham.ac.uk/~jxb/INC/I9.pdf>>.

CABACINHA, C. D. **Um método para a realização do inventário florestal suprimindo a cubagem rigorosa**. Dissertação (Mestrado) – Universidade Federal de Lavras. Lavras-MG, 2003.

CAMPOS, B. P. F.; SILVA, G. F.; BINOTI, D. H. B.; MENDONÇA, A. R.; LEITE, H. G. **Predição da altura total de árvores em plantios de diferentes espécies por**

meio de redes neurais artificiais. Pesquisa Florestal Brasileira, Colombo, v. 36, n. 88, p. 375-385, 2016. Acesso em: 18/01/2017. Disponível em: <<http://pfb.cnpf.embrapa.br/pfb/>>.

CAMPOS, J. C. C. et al. **Inventário florestal nacional: reflorestamento: Minas Gerais.** Brasília, DF: IBDF, 1984.

CESARO, A.; ENGEL, O. A.; FINGER, C. A. G.; SCHNEIDER, P. R. **Comparação dos métodos de amostragem de área fixa, relascopia, e de seis árvores, quanto a eficiência, no inventário florestal de um povoamento de Pinus sp.** Ci. Flor., Santa Maria, v.4, n.1, p. 97-108, 1994.

CEYLAN, I. 2008. **Determination of drying characteristics of timber by using artificial neural networks and mathematical models.** *Drying Technology* vol. 26, ISS 12, p. 1469-1476, 2008.

Costa, M.P.; Souza, C.A.M.; Almeida, A.Q.; Nappo, M.E. Estudo da relação hipsométrica para a espécie *Joannesia princeps* Vell. estabelecida em plantio misto. In: Encontro Latino Americano de Iniciação Científica, 6, 2006, São José dos Campos. **Anais...** São José dos Campos, 2006. p. 1038-1042. Acesso em: 14/09/2016. Disponível em: <http://www.inicepg.univap.br/cd/INIC_2006/inic/inic/01/INIC0000345%20ok.pdf>.

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. Acesso em: 28/08/2016. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0168169905000839>>.

EMBRAPA. **Comparação de modelos de crescimento em altura de duas espécies de eucalipto em sistemas agrossilvipastoris.** 1. ed. Planaltina, DF: Boletim de Pesquisa e Desenvolvimento, 2014. Acesso em: 14/09/2016. Disponível em: <www.cpac.embrapa.br/download/2534/t>.

FRANCEZ, L. M. B.; SOUZA, D. V., TAKEHANA, C. L. I., BARROS, P. L. C. **Manual para análise de inventário florestal e equação de volume em projetos de manejo florestal sustentável - PMFS.** Secretaria de Estado de Meio Ambiente. Belém, 2010.

GIL, A. C. **Métodos e técnicas de pesquisa social.** 6ª ed. São Paulo: Atlas, 2008.

GÖRGENS, E. B. **Estimação do volume de árvores utilizando redes neurais artificiais.** Dissertação (*Magister Scientiae*) - Universidade Federal de Viçosa, 2006. Acesso em 27/08/2016. Disponível em: <<http://www.locus.ufv.br/handle/123456789/3068>>.

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

LEAL, F. A.; CABACINHA, C. D.; CASTRO, R. V. O.; MATRICARDI, E. A. T. **AMOSTRAGEM DE ÁRVORES DE EUCALYPTUS NA CUBAGEM RIGOROSA PARA ESTIMATIVA DE MODELOS VOLUMÉTRICOS.** Rev. Bras. Biom., São Paulo, v.33, n.1, p.91-103, 2015. Acesso em: 23/11/2016. Disponível em: <http://jaguar.fcav.unesp.br/RME/fasciculos/v33/v33_n1/A8_Fabricio.pdf>.

JESUS, C. M.; MIGUEL, E. P.; AZEVEDO, G. B.; AZEVEDO, G. T. O. S.; PEREIRA, R. S. **Modelagem hipsométrica em povoamento clonal de *Eucalyptus urophylla* x *Eucalyptus grandis* no Distrito Federal.** Enciclopédia Biosfera, Centro Científico Conhecer - Goiânia, v.11 n.21; p. 1298-1308, 2015 . Acesso em: 17/01/2017. Disponível em: <<http://www.conhecer.org.br/enciclop/2015b/agrarias/modelagem%20hipsometrica.pdf>>.

LEITE, F. S. **Estimativa do volume de madeira a partir do diâmetro da cepa em uma área explorada de floresta amazônica de terra firme.** Dissertação (Mestrado). Universidade de Brasília, 2008. Acesso em: 24/11/2016. Disponível em: <

http://repositorio.unb.br/bitstream/10482/1173/1/DISSERTACAO_2008_FlaviaSaltiniLeite.pdf>.

LEITE, M. V. S.; SILVA, J. P. M.; CABACINHA, C. D.; ASSIS, A. L. Redes neurais artificiais para estimativa de altura dominantes em povoamentos de eucalipto. In: Semana de Engenharia Florestal da Bahia, 4, 2016, Vitória da Conquista. **Anais...** Vitória da Conquista, 2016. Acesso em 12/09/2016. Disponível em

<<http://www.uesb.br/eventos/seeflor/publicacoes/2016/REDES%20NEURAIIS%20ARTIFICIAIS%20PARA%20ESTIMATIVA%20DE%20ALTURA%20DOMINANTES%20EM%20POVOAMENTOS%20DE%20EUCALIPTO.pdf>>

LOUREIRO, G. H.; CURTO, R. A.; ROSOT, N. C.; MARANGON, G. P.; VARGAS, J. F. Ajuste de modelos volumétricos por classe diamétrica e para todas as classes em *Eucalyptus grandis* Hill ex Maiden. In: Congresso Florestal Paranaense, 4, 2012, Curitiba. **Anais...** Curitiba, 2012. Acesso em: 19/01/2017. Disponível em: < http://malinovski.com.br/CongressoFlorestal/Arquivos_HTML/4-Trabalhos-04.htm>.

MARTINS, E. R.; BINOTI, M. L. M. S.; LEITE, H. G.; BINOTI, D. H. B.; DUTRA, G. C. **Configuração de redes neurais artificiais para estimação do afilamento do fuste de árvores de eucalipto.** Agrária, Recife, v.11, n.1, p.33-38, 2016. Acesso em: 25/11/2016. Disponível em: < http://www.agraria.pro.br/ojs2.4.6/index.php?journal=agraria&page=article&op=view&path%5B%5D=agraria_v11i1a5354&path%5B%5D=4884>.

MELO, L. C.; BARRETO, P. A. B.; OLIVEIRA, F. G. R. B.; NOVAES, A. B. **Estimativas volumétricas em povoamento de *Pinus caribaea* var. *hondurensis* no sudoeste da Bahia.** Pesquisa Florestal Brasileira, Colombo, v. 33, n. 76, p. 379-386, 2013. Acesso em: 20/01/2017. Disponível em: < <http://pfb.cnpf.embrapa.br/pfb/index.php/pfb/article/viewFile/459/336>>.

MENDONÇA, A. R.; CARVALHO, S. P. C.; CALEGARIO, N. **Modelos hipsométricos generalizados mistos na predição da altura de *Eucalyptus* sp.**

Revista Cerne, Lavras, vol. 21, n. 1, p. 107-115, 2015. Acesso em 26/08/2016. Disponível em: < <http://www.scielo.br/pdf/cerne/v21n1/2317-6342-cerne-21-01-00107.pdf>>.

MIGUEL, E. P.; CANZI, L. F.; RUFINO, R. F.; SANTOS, G. A. **AJUSTE DE MODELO VOLUMÉTRICO E DESENVOLVIMENTO DE FATOR DE FORMA PARA PLANTIOS DE *Eucalyptus grandis* LOCALIZADOS NO MUNICÍPIO DE RIO VERDE – GO.** ENCICLOPEDIA BIOSFERA, Centro Científico Conhecer - Goiânia, vol.6, n.11, p. 1-13, 2010. Acesso em: 28/11/2016. Disponível em: <<http://www.conhecer.org.br/enciclop/2010c/ajuste%20de%20modelo.pdf>>.

MIRANDA, D. L. C.; JUNIOR, V. B.; GOUVEIA, D. M. **Fator de forma e equações de volume para estimativa volumétrica de árvores em plantio de *Eucalyptus urograndis*.** Scientia Plena, vol. 11, n. 3, p. 1-8, 2015. Acesso em : 19/01/2017. Disponível em: < <https://www.scientiaplena.org.br/sp/issue/view/130>>.

MONTAÑO, R. A. N. R. **Aplicação de técnicas de aprendizado de máquina na mensuração florestal.** Tese (Doutorado). Universidade Federal do Paraná, 2016.

OLIVEIRA, B. R. **Determinação do volume de cerne produzido em árvores de *Tectona grandis* L. f. em Mato Grosso.** Dissertação (Mestrado). Universidade de Cuiabá, 2014. Acesso em: 17/01/2017. Disponível em:<<http://www.ufmt.br/ufmt/unidade/userfiles/publicacoes/64a599a7b3d3a48db5b6ae49a470cc2a.pdf>>.

PELLI, E.; NOGUEIRA, G. S.; HORTA, E. G.; PAULA, H. de. **Estimativa de volume de árvores utilizando redes neurais artificiais.** Atualidades em Mensuração Florestal [livro eletrônico]/ Ed. Ana Paula Dalla Corte...[et al.]. – 1. ed. –Curitiba, 2014.

SANQUETA, M. N. I; SANQUETA, C. R.; MOGNON, F.; CORTE, A. P. D.; RODRIGUES, A. L.; MAAS, G. C. B. **Ajuste de equações hipsométricas para a estimação da altura total de indivíduos jovens de teca.** Científica, vol. 43, n. 4, p. 400-406, 2015. Acesso em: 25/11/2016. Disponível em: <

<http://dx.doi.org/10.15361/1984-5529.2015v43n4p400-406>>.

SANTOS, M. L.; BRASIL NETO, A. B.; PAUMGARTTEN, A. E. A.; RODRIGUES, R. P.; SANTOS, C. R. **ESTIMATIVA DA RELAÇÃO HIPSOMÉTRICA PARA UM POVOAMENTO DE *Eucalyptus “urograndis”* NO MUNICÍPIO DE MOJU, NORDESTE PARAENSE**. ENCICLOPÉDIA BIOSFERA, Centro Científico Conhecer - Goiânia, v.10, n.19; p. 1039-1048, 2014. Acesso em: 28/11/2016. Disponível em: <<http://www.conhecer.org.br/enciclop/2014b/AGRARIAS/estimativa%20da%20relacao.pdf>>.

SBRAVATI, M.; FRANÇA, M.; SILVESTRE, R.; ROLIM, F. A.; BONAZZA, M.; NICOLETTI, M. F. **Atualidades em Mensuração Florestal** [livro eletrônico]/ Ed. Ana Paula Dalla Corte...[et al.]. – 1. ed. – Curitiba, 2014.

SILVA, A. J.; SILVA FILHO, J. L. F.; SILVA, M. D. T.; ROQUE, C. G.; CUNHA, F. F. **AJUSTE DE MODELOS HIPSOMÉTRICOS E VOLUMÉTRICOS PARA TRÊS CLONES DE EUCALYPTUS EM MINEIROS-GO**. Nucleus, vol.12, n.2, p. 221-230, 2015. Acesso em 28/11/2016. Disponível em: <<http://www.nucleus.feituverava.com.br/index.php/nucleus/article/view/1372>>.

SILVA, F.; CORTE, A. P. D.; SANQUETTA, C. R.; **Equações de afilamento para descrever o volume total do fuste de *Pinus caribaea* var. *hondurensis* na região do Triângulo Mineiro**. Scientia Forestalis, Piracicaba, v. 39, n. 91, p. 367-376, 2011. Acesso em: 25/01/2017. Disponível em: <<http://www.ipef.br/publicacoes/scientia/nr91/cap09.pdf>>.

SILVA, L. M. S.; BINOTI, D. H. B.; GLERIANI, J. M.; LEITE, H. G. **Ajuste do modelo de Schumacher e Hall e aplicação de redes neurais artificiais para estimar volume de árvore de eucalipto**. Rev. Árvore vol.33 no.6 Viçosa, 2009. Acesso em: 27/08/2016. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0100-67622009000600015>.

SILVA, A. M. **Utilização de redes neurais artificiais para classificação de spam**. Dissertação (Mestrado). Centro Federal de Educação Tecnológica de Minas Gerais, 2009. Acesso em: 25/11/2016. Disponível em: <<http://www.mmc.cefetmg.br/info/downloads/D047-AlissonMarquesdaSilva.pdf>>.

SOARES, C. P. B.; NETO, F. P.; SOUZA, A. L. **Dendrometria e inventário florestal**. Viçosa, MG:Universidade Federal de Viçosa, 2006.

SOUZA, G. T. O.; AZEVEDO, G. B.; BARRETO, P. A. B.; JÚNIOR, V. C. **Relações hipsométricas para *Eucalyptus urophylla* conduzidos sob regime de alto fuste e talhadia no Sudoeste da Bahia**. SCIENTIA PLENA, Vol. 9, N. 4. 2013. Acesso em: 10/09/2016. Disponível em: <<https://www.scienciaplena.org.br/sp/article/viewFile/771/671>>.

SOUZA, S. R. de. **Uso de redes neurais na estimativa volumétrica de clones de *Eucalyptus spp* no pólo gesseiro do Araripe, Pernambuco**. Dissertação (Mestrado) - Universidade Federal Rural de Pernambuco, 2015. Acesso em 27/08/2016. Disponível em:<<http://www.tede2.ufrpe.br:8080/tede/bitstream/tede2/4484/2/Syntia%20Regina%20Rodrigues%20de%20Souza.pdf>>.

SOUZA, A. S.; **MODELAGEM DA RELAÇÃO HIPSOMÉTRICA PARA UM POVOAMENTO HÍBRIDO DE EUCALIPTO, NA AMAZÔNIA BRASILEIRA**. Trabalho de Conclusão de Curso (Monografia). Universidade Federal do Pará, 2014.

SOUZA, H. S.; TSUKAMOTO FILHO, A. A.; VENDRUSCOLO, D. G. S.; CHAVES, A. G. S.; MOTTA, A. S. **Modelos hipsométricos para eucalipto em sistema de integração lavoura-pecuária-floresta**. Nativa, Sinop, v.4, n.1, p.11-14, 2016. Acesso em: 12/09/2016. Disponível em: <<http://periodicoscientificos.ufmt.br/ojs/index.php/nativa/article/viewFile/3240/pdf>>.

VIANNA, L. M.; BARRETO-GARCIA, P. A. B.; CARVALHO, T. S.; NEVES, V. S.; GOMES, A. S. **Modelos hipsométricos para um povoamento de *Eucalyptus***

***urophylla X Eucalyptus grandis* no município de Vitória da Conquista-BA.**

Enciclopédia Biosfera, Centro Científico Conhecer - Goiânia, v.13 n.24; p. 746-756, 2016. Acesso em: 17/01/2017. Disponível em: <<http://www.conhecer.org.br/enciclop/2016b/agrarias/modelos%20hipsometricos.pdf>>.

VENDRUSCOLO, D. G. S.; DRESCHER, R.; SOUZA, H. S.; MOURA, J. P. V. M.; MAMORÉ, F. M. D.; SIQUEIRA, T. A. da S. **Estimativa da altura de eucalipto por meio de regressão não linear e redes neurais artificiais.** Rev. Bras. Biom., São Paulo, v.33, n.4, p.556-569, 2015. Acesso em: 25/08/2016. Disponível em: <http://jaguar.fcav.unesp.br/RME/fasciculos/v33/v33_n4/A9_DiogoRonaldo.pdf>.