

**UNIVERSIDADE FEDERAL RURAL DE PERNAMBUCO
DEPARTAMENTO DE CIÊNCIA FLORESTAL
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS FLORESTAIS**

CÉLIO GREGÓRIO DE VASCONCELOS JOSSEFA

**USO DE REDES NEURAS ARTIFICIAIS E MÉTODOS TRADICIONAIS NA
ESTIMATIVA DO VOLUME DO FUSTE DE *Eucalyptus* spp., NA REGIÃO DO
POLO GESSEIRO DO ARARIPE.**

**RECIFE - PE
OUTUBRO - 2016**

CÉLIO GREGÓRIO DE VASCONCELOS JOSSEFA

USO DE REDES NEURAIS ARTIFICIAIS E MÉTODOS TRADICIONAIS NA ESTIMATIVA DO VOLUME DO FUSTE DE *Eucalyptus* spp., NA REGIÃO DO POLO GESSEIRO DO ARARIPE.

Dissertação apresentada à coordenação do Curso de Pós-Graduação em Ciências Florestais da Universidade Federal Rural de Pernambuco, sendo um dos requisitos para obtenção do título de Mestre em Ciências Florestais, Área de concentração: Ciências Florestais.

Orientador:

Profº. Drº. José Antônio Aleixo da Silva

Coorientador:

Profº. Drº. Rinaldo Luiz Caraciolo Ferreira

**RECIFE - PE
OUTUBRO - 2016**

Ficha catalográfica

J84r Jossefa, Célio Gregório de Vasconcelos

 Usu Redes neurais artificiais e métodos tradicionais na estimativa do volume do fuste de *Eucalyptus* spp., na região do Polo Gesseiro do Araripe / Célio Gregório de Vasconcelos Jossefa. – 2016.
 72 f.: il.

 Orientador: José Antônio Aleixo da Silva.

 Coorientador: Rinaldo Luiz Caraciolo Ferreira.

 Dissertação (Mestrado) – Universidade Federal Rural de Pernambuco, Programa de Pós-Graduação em Ciências Florestais, Recife, BR-PE, 2016.

 Inclui referências e apêndice(s).

 1. Inventário florestal 2. Inteligência artificial, 3. Análise de regressão I. Silva, José Antônio Aleixo da, orient. II. Ferreira, Rinaldo Luiz Caraciolo, coorient. III. Título


CDD 634.9

CÉLIO GREGÓRIO DE VASCONCELOS JOSSEFA


**USO DE REDES NEURAIAS ARTIFICIAIS E MÉTODOS TRADICIONAIS NA
ESTIMATIVA DO VOLUME DO FUSTE DE *Eucalyptus* spp., NA REGIÃO DO
POLO GESSEIRO DO ARARIPE.**

APROVADA em 31/10/2016


Banca Examinadora



Prof. Dr.º Tiago Alessandro Espínola Ferreira
(Membro Titular – Departamento de Biometria e Estatística Aplicada /UFRPE)



Dr.º Régis Villanova Longhi
(Membro Titular – Pós Doc / Departamento de Ciência Florestal/UFRPE)



Prof. Dr.º José Antônio Aleixo da Silva
(Orientador – Departamento de Ciência Florestal/UFRPE)

**RECIFE - PE
OUTUBRO - 2016**

Aos meus país e irmãos pelo carinho e dedicação. Ao meu filho Allen de Vasconcelos Jossefa e a minha noiva, por suportarem a minha ausência.

DEDICO

"Eu sou um filho da floresta. Nenhum telhado cobre o local onde nasci, carvalhos e folhas sombreiam sua solidão e a grama cresce em cima dele. A primeira música que ouvi foi dos pássaros da floresta, os meus primeiros ambientes foram árvores. Assim, meu nascimento determinou a minha vocação"

Heinrich Cotta (1763-1844)

AGRADECIMENTOS

Ao meu orientador Prof. Dr. José Antônio Aleixo da Silva agradeço profundamente pelos ensinamentos, amizade, orientação, incentivo, auxílio nos momentos mais difíceis e pelas valiosas contribuições na discussão do trabalho, dosando as críticas com comentários de incentivo.

Ao coorientador Prof. Dr. Rinaldo Luiz Caraciolo Ferreira pela concessão da carta de aceite para frequentar o mestrado, pelos sábios conselhos e pelo apoio em todas as fases do trabalho.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), pela concessão da bolsa de Mestrado e pelo acolhimento.

Aos colegas de turma e do laboratório de Biometria e Manejo Florestal agradeço nas pessoas de Natan, Alberto (Mexicano), Samara, Diego (Diegão), Guera, Gabi, Juan (Colombiano) pelo convívio, solidariedade e amizade compartilhadas todo esse tempo.

Aos colegas do curso de Pós-Graduação em Biometria e Estatística Aplicada, em especial ao David, Wesley, Fabio (Cariri) e Diego Alves.

Expresso os meus sinceros agradecimentos à minha família em especial ao meu tio José Vasconcelos pelos conselhos transmitidos antes da minha vinda ao Brasil e durante a estadia.

Ao Alberto, Paulo, Branca e Taís pelos momentos agradáveis e por terem me acolhido como um filho, meus sinceros agradecimentos.

A comunidade de estudantes moçambicanos em Recife, nas pessoas de Danilo e Mucaca, agradeço pela convivência, principalmente nos dias festivos.

Ao inesquecível Programa de Pós-Graduação em Ciências Florestais da Universidade Federal Rural de Pernambuco, por proporcionar um dos melhores momentos da minha vida.

Aos amigos de Moçambique por conseguirem manter essa linda amizade, nas pessoas de Luís Baptista Janota e Maquias Cornélio Chiutano.

Ao Instituto Superior Politécnico de Manica pela confiança e incentivo prestado para a realização do mestrado.

JOSSEFA, CÉLIO GREGÓRIO DE VASCONCELOS. Universidade Federal Rural de Pernambuco. 2016. **Uso de redes neurais artificiais e métodos tradicionais na estimativa do volume do fuste de *Eucalyptus* spp., na região do Polo Gesseiro do Araripe.** Orientador: Prof. Dr. José Antônio Aleixo da Silva. Co-orientador: Prof. Dr. Rinaldo Luiz Caraciolo Ferreira.

RESUMO

Uma das maneiras de tornar mais eficiente a estimativa do volume das árvores de Eucalipto é a aplicação de ferramentas capazes de tornar as estimativas bem próximas do real. O objetivo deste trabalho foi comparar duas formas de estimativas de volume: modelos matemáticos por meio de métodos de regressão e redes neurais artificiais. O conjunto de dados utilizado resultou da segunda rotação do experimento contendo 15 clones, de *Eucalyptus* spp., Implantados na Estação Experimental do Instituto Agronômico de Pernambuco (IPA), localizada na região de Araripe, Pernambuco. O conjunto de dados foi composto por 2199 árvores, cubadas pelo método de Smalian. Foi mensurada a altura total, altura do fuste e diâmetros em várias posições no fuste. Para modelagem, as árvores foram agrupadas utilizando o teste de Skott-Knott, por clone e para todos os clones juntos. A avaliação dos ajustes da Rede Neural Artificial (RNA) considerou duas formas de entrada das variáveis independentes: a) seções de volume e b) diâmetro à altura do peito (DAP) e altura total (Ht). O desempenho dos modelos matemáticos e RNA foi baseado no índice de adaptação de Schlaegel (IA_{aj}), erro quadrático médio em percentual (RMSE%) e análise gráfica de resíduos. De acordo com os resultados obtidos, o modelo de Schumacher-Hall apresentou melhor desempenho estatístico para estimar o volume individual de *Eucalyptus* spp. A Rede Neural Artificial considerando o volume das seções como variáveis de entrada foi superior quando comparado com DAP e Ht como variáveis de entrada. O modelo de Silva-Borders e as Redes Neurais Artificiais considerando o volume das seções como variáveis de entrada são mais práticos para estimar o volume porque não consideram a variável Ht, que é muitas vezes difícil de medir no campo e onerosa.

Palavras-chave: Inventário florestal, inteligência artificial, análise de regressão.

JOSSEFA, CÉLIO GREGÓRIO DE VASCONCELOS. Rural Federal University of Pernambuco. 2016. **Artificial neural network and volumetric models for estimating the volume of *Eucalyptus* spp., in the coppicing regime at the Gypsum Pole of Araripe.** Advisor: Prof. Dr. José Antônio Aleixo da Silva. Co-advisor: Prof. Dr. Rinaldo Luiz Caraciolo Ferreira.

ABSTRACT

One of the ways to estimate volumes of the *Eucalyptus* trees with efficiency is to apply formulae that can make the estimates with precision. The objective of this work was to compare two ways of volume estimations: mathematical models through regression methods and the artificial neural networks. The data set used came from the second rotation of the experiment containing 15 clones, of *Eucalyptus* spp., implanted at the Experimental Station of the Agronomic Institute of Pernambuco (IPA), located in the Araripe region, Pernambuco, Brazil. The data set was composed of 2199 trees, cubed by the Smalian method. It was measured the total height, stem height and diameters at several position in the bole. For modeling, the trees were grouped using the Skott-Knott test, per clone and for all the clones together. The evaluation of Artificial Neural Network (ANN) adjustments considered two forms of input of the independent variables: a) volume sections and b) diameter at breast height (DBH) and total height (Ht). The performance of the mathematical volumetric models and ANN was based on Schlaegel fitting index (IA_{aj}), root mean squared error in percentage (RMSE%) and graphic residuals analysis. According to the results, the Schumacher-Hall model presented better statistical performance for estimating the individual volume of *Eucalyptus* spp. The Artificial Neural Network considering the volume of the sections as input variables was superior when comparing with DBH and Ht as input variables. The Silva-Borders model and Artificial Neural Networks considering the volume of the sections as input variables are more practical to measure volumes because they do not consider the variable Ht, which is often difficult to measure in the field and costly.

Keywords: Forest inventory, artificial intelligence, regression analysis.

LISTA DE FIGURAS

Figura	Página
Figura 1 - Esquema do neurônio de McCullock - Pitts com limiar explícito.	24
Figura 2 - Estrutura da rede MLP.	26
Figura 3 - Diagrama da aprendizagem supervisionada.	28
Figura 4 - Diagrama da aprendizagem não supervisionada.	29
Figura 5 – Gráfico de distribuição de resíduos em relação ao volume predito para todas as árvores aos 5,5 anos de idade, no Polo Gesseiro do Araripe em Pernambuco.	43
Figura 6 – Gráfico de distribuição de resíduos em relação ao volume predito para clones de <i>Eucalyptus</i> spp. aos 5,5 anos de idade, no Polo Gesseiro do Araripe em Pernambuco.	44
Figura 7 – Gráfico de distribuição de resíduos em relação ao volume predito para o grupo de clones de <i>Eucalyptus</i> spp. com 5,5 anos de idade, no Polo Gesseiro do Araripe em Pernambuco.	45
Figura 8 - Gráfico de distribuição de resíduos em relação ao volume predito para todas as árvores de <i>Eucalyptus</i> spp. com 5,5 anos de idade, no Polo Gesseiro do Araripe em Pernambuco.	52
Figura 9 – Gráfico de distribuição de resíduos em relação ao volume predito para clones de <i>Eucalyptus</i> spp. aos 5,5 anos de idade, no Polo Gesseiro do Araripe em Pernambuco.	53
Figura 10 – Gráfico de distribuição de resíduos em relação ao volume predito para o grupo de clones de <i>Eucalyptus</i> spp. com 5,5 anos de idade, no Polo Gesseiro do Araripe em Pernambuco.	55

LISTA DE TABELAS

Tabelas

Página

Tabela 1 - Funções de ativação.....	25
Tabela 2 - Resultados do teste de Scott-Knott para o volume e incremento médio anual (IMA) dos 15 clones de <i>Eucalyptus</i> spp. aos 5,5 anos.	33
Tabela 3 - Modelos volumétricos testados para estimar o volume dos clones de <i>Eucalyptus</i> spp.	36
Tabela 4 - Combinações das seções da primeira tora utilizadas para modelar o volume de clones de <i>Eucalyptus</i> spp. aos 5,5 anos de idade, no Polo Gesseiro do Araripe em Pernambuco.	37
Tabela 5 – Estatísticas descritivas das variáveis amostradas.	39
Tabela 6 – Estrutura e estatística das redes neurais artificiais ao modelar todas as árvores de clones de <i>Eucalyptus</i> spp., aos 5,5 anos de idade, no Polo Gesseiro do Araripe em Pernambuco.	40
Tabela 7 – Estrutura e estatística das redes neurais artificiais ao modelar os clones de <i>Eucalyptus</i> spp. aos 5,5 anos de idade, no Polo Gesseiro do Araripe em Pernambuco.....	40
Tabela 8 - Estrutura e estatística das redes neurais artificiais ao modelar o grupo de clones de <i>Eucalyptus</i> spp. formado pelo Skott-Knott aos 5,5 anos de idade, no Polo Gesseiro do Araripe em Pernambuco.	41
Tabela 9 - Equações e estatísticas dos modelos volumétricos ao modelar todas as árvores de clones de <i>Eucalyptus</i> spp., aos 5,5 anos de idade, no Polo Gesseiro do Araripe em Pernambuco.	47
Tabela 10 - Equações e estatísticas dos modelos volumétricos ao modelar os clones de <i>Eucalyptus</i> spp. aos 5,5 anos de idade, no Polo Gesseiro do Araripe em Pernambuco.....	48
Tabela 11 - Equações e estatísticas dos modelos volumétricos ao modelar o grupo de clones de <i>Eucalyptus</i> spp. formado pelo Skott-Knott aos 5,5 anos de idade, no Polo Gesseiro do Araripe em Pernambuco.	49

LISTA DE QUADROS

Quadro	Página
Quadro 1 – Vantagens e desvantagens das RNA.....	30
Quadro 2 - Clones de <i>Eucalyptus</i> spp. utilizados no estudo para modelar o volume individual do fuste.....	32

SUMÁRIO

1 INTRODUÇÃO	14
2 REVISÃO DE LITERATURA	18
2.1 FLORESTAS ENERGÉTICAS DE EUCALIPTOS.....	18
2.2 CUBAGEM RIGOROSA.....	19
2.3 MODELAGEM VOLUMÉTRICA.....	20
2.4 ERROS NA MEDIÇÃO DA ALTURA.....	22
2.5 REDES NEURAS ARTIFICIAIS	23
2.5.1 Fundamento das redes neurais artificiais	23
2.5.2 Funções de ativação	25
2.5.3 Rede Multilayer Perceptron - MLP	26
2.5.4 Aprendizagem das redes neurais	27
2.5.5 Vantagens e desvantagens da utilização das RNA	29
2.5.6 Aplicação das redes neurais no manejo florestal	30
3 MATERIAL E MÉTODOS	31
3.1 ÁREA DE ESTUDO	31
3.2 CARACTERIZAÇÃO DO EXPERIMENTO.....	31
3.3 CUBAGEM RIGOROSA.....	32
3.4 MODELAGEM DO VOLUME	33
3.4.1 Redes neurais artificiais	34
3.4.2 Modelos volumétricos	36
3.5 AVALIAÇÃO DA QUALIDADE DOS AJUSTES	38
4 RESULTADOS E DISCUSSÃO	39
4.1 ESTATÍSTICA DESCRITIVA DAS VARIÁVEIS	39
4.2 REDES NEURAS ARTIFICIAIS	39
4.3 MODELAGEM VOLUMÉTRICA.....	47
5 CONCLUSÃO	58
REFERÊNCIAS	59
APÊNDICES	68

1 INTRODUÇÃO

A região do Polo Gesseiro do Araripe em Pernambuco, é considerada a maior produtora de gesso, representando 95% da produção total do Brasil. Essa região tem como principal fonte de energia para a calcinação da gipsita a lenha advinda da Caatinga (GADELHA et al., 2015).

De acordo com Silva (2008/2009) o estoque madeireiro da Caatinga não é suficiente para suprir a demanda da indústria do gesso, além disso, existe uma insuficiência de planos de manejo sustentáveis. Ainda de acordo com o autor, mesmo se tivesse planos de manejo sustentáveis, não seriam suficientes para uma exploração sustentável, pois o período de rotação da Caatinga é superior a 10 anos e exigiria grandes áreas manejadas, pois o incremento médio anual da Caatinga em locais bem produtivos fica em torno de 5m³/ha.

Campello (2011) constatou que apenas 11,75% da lenha utilizada pelas empresas produtoras de gesso são provenientes de planos de manejo florestal e 0,1% de reflorestamentos energéticos com eucalipto. De acordo com Rocha (2012), devido a utilização intensiva da lenha, o desmatamento coadjuvado com a degradação ambiental vem aumentando na região do Polo Gesseiro de Araripe.

Portanto, uma alternativa para a redução do desmatamento na região passa pela utilização de espécies de rápido crescimento e com um grande potencial energético. A produção e utilização de madeira para energia com espécies de rápido crescimento estão entre os temas que recebem muita atenção no contexto das energias renováveis, não só dos políticos, mais também de cientistas e grupos de interesse que representam outros setores como a agricultura, a silvicultura, o ambiente, a indústria e os consumidores.

A principal razão para esse interesse generalizado é que as diferentes partes perceberam a problemática das implicações nas mudanças climáticas do caminho empreendido pelas sociedades modernas e as indústrias no que diz respeito ao alto consumo de energia, muitas vezes advindos de florestas naturais e fontes de energia não renováveis.

No contexto brasileiro, nos últimos anos tem sido notada uma grande expressividade na utilização de espécies de rápido crescimento para fins energéticos, principalmente o eucalipto, considerado como um dos principais representantes do setor florestal brasileiro, devido ao seu rápido crescimento, excelente produção volumétrica, melhoramento genético, técnicas silviculturais, etc.

De acordo com Goulart et al. (2003), Carvalho (2010) o Brasil apresenta condições extremamente favoráveis de clima e de solo ao plantio do eucalipto, o que lhe confere rápido crescimento, atingindo os mais altos índices de produtividade do mundo.

Diante disto, na região do Polo Gesseiro do Araripe foi estabelecido no ano de 2002, em caráter experimental, um teste com 15 clones de *Eucalyptus* spp. cujo objetivo foi de identificar materiais genéticos que conciliem a boa produtividade volumétrica, resistência a doenças com as boas características tecnológicas para fins energéticos, como elevado poder calorífico, alto rendimento em carvão vegetal, baixo teor de cinzas, com o intuito de diminuir a pressão sobre o recurso florestal da Caatinga.

No entanto uma das maneiras de tornar mais eficiente o uso dos recursos florestais é a aplicação de ferramentas capazes de tornar as estimativas volumétricas bem próximas do real.

O volume é uma das formas mais importantes de informação para o conhecimento do potencial florestal, considerado como uma parte integrante do crescimento da floresta, que fornece informações para a compreensão da produtividade florestal e uma base para o planejamento das ações de manejo florestal (PHILIP, 1994; DIAMANTOPOULOU, 2006; SHATER et al., 2011; RIBEIRO; GAMA; MELO, 2014).

Em face disto, é do interesse de qualquer administrador ligado ao setor florestal conseguir quantificar e prognosticar, com confiabilidade o estoque de uma determinada floresta. O volume sempre foi considerado uma variável de difícil obtenção, principalmente quando se quer conhecer o volume de um grande número de árvores. Para Socha e Kulej (2005); Bayati e Najafi (2012), a estimação do volume por meio das características básicas dendrométricas, tais como diâmetro a altura do peito (*DAP*) e altura (*h*), tem resultado em erros, em

função da variação da forma do fuste da árvore, influenciada por fatores tais como a espécie, procedência, idade e densidade.

De acordo com Kong et al. (2012) a variação da forma do fuste é um resultado de diferenças na taxa de incremento de diâmetro em diferentes alturas. A forma da árvore não se identifica com a forma de um único sólido geométrico específico, mas sim como um neilóide na base, um parabolóide no meio e um cone no topo (HUSCH; MILLER; BEERS, 1972; BORGES, 1981; AVERY; BURKHART, 1994).

Nicoletti (2011) salienta que se fosse possível determinar o início e o fim de cada figura geométrica ao longo do fuste, bastaria aplicar fórmulas geométricas correspondentes aos vários sólidos geométricos que ocorrem ao longo do fuste e poder-se-ia obter o volume do fuste.

No entanto, esse processo é praticamente impossível, motivo que proporcionou o desenvolvimento de ferramentas ao longo dos anos para estimar a variável volume, destacando o fator de forma, quociente de forma, xilômetro, fórmulas matemáticas, modelos volumétricos, funções de afilamento ou taper (PHILIP, 1994; SCOLFORO et al., 1998; HUSCH; BEERS; KERSHAW JR, 2003; BONYAD; RAHIMNEJAD, 2004; RAMOS, 2012; PACHECO et al., 2015) e modelos que dispensam a mensuração da altura da árvore e consideram o volume das secções como variáveis independentes (SILVA; BORDERS, 1993; LYNCH, 1995).

Recentemente, uma abordagem alternativa para a estimativa do volume consiste no uso de redes neurais artificiais (RNAs). As RNAs são definidas como sistemas computacionais baseados nos princípios de sistemas neurais biológicos. Essas redes têm a capacidade de aprender, memorizar e identificar relações entre os dados (ÖKZAN; ERBEK, 2003).

De acordo com Higgins (2011), Wang e Xiong (2013), Wu (2014), as redes neurais têm se tornado uma técnica de modelagem utilizada em uma variedade de diferentes áreas de manejo de recursos florestais incluindo a classificação de terra, análise de dados espaciais, crescimento e dinâmica da floresta.

Nos últimos anos, tem sido frequente a aplicabilidade das redes neurais artificiais no campo da modelagem florestal (LIU et al., 2003; CORNE et al., 2004; DIAMANTOPOULOU, 2005a, 2005b; ÖZCELIK et al., 2010; HIGGINS, 2011; PELLI, 2013; SOARES et al., 2012; BINOTI et al., 2014; WU, 2014).

A principal razão da aplicação das redes neurais artificiais para a estimativa do volume é que a sua metodologia é comparável à modelagem estatística e poderia ser encarada como esforço complementar (sem a suposição restritiva de um modelo estatístico em particular) ou uma abordagem alternativa para dados não lineares com a capacidade de aproximar soluções e ainda resolver problemas difíceis que estão fora do alcance de modelos determinísticos e tradicionais (SANDO et al., 2005; ÖZCELIK et al., 2010; SAFI e BOUROUMI, 2013)

De acordo com o exposto, objetivou-se com a pesquisa testar a eficiência de diferentes métodos de determinação do volume individual de clones de clones de *Eucalyptus* spp., implantados na região da Chapada, utilizando os modelos tradicionais, modelo das secções da primeira tora e redes neurais artificiais e especificamente pretendeu-se:

- Comparar os ajustes gerados pelos modelos volumétricos tradicionais e modelo de volume das secções;
- Comparar dois procedimentos de variáveis de entrada das redes neurais artificiais para a estimativa de volume individual.

2 REVISÃO DE LITERATURA

2.1 FLORESTAS ENERGÉTICAS DE EUCALIPTOS

O elevando consumo de energia com o acentuamento crescimento das emissões de gases de efeito estufa e as preocupações sobre a dependência das importações de energia estão levando á mudanças globais nas fontes de qual a energia está prevista para ser derivada nos próximos anos (FERRANTI, 2014). Diante disso, o fornecimento de madeira para fins energéticos vindo das florestas nativas levou a um interesse no estabelecimento de plantações de eucalipto em várias partes do mundo, particularmente nos trópicos e subtropicos.

A energia advinda das florestas de eucalipto já é considerada competitiva com a energia fóssil em muitos países e pode oferecer alguns dos mais altos níveis de eficiência energética e de carbono entre matérias-primas de bioenergia, em especial quando utilizadas para a geração de calor e energia. Além de ser economicamente atraente, é uma opção estratégica para o aumento da segurança energética, em particular nos países que dependem consideravelmente da lenha vindo das florestas nativas (FAO, 2008).

Portanto, diante dessa conjuntura de benefícios que as florestas energéticas de rápido crescimento propiciam, aliado a exploração intensiva da Caatinga, no Polo Gesseiro do Araripe foi estabelecido um experimento no ano de 2002, com 15 clones de *Eucalyptus* spp. Esse experimento é monitorado pela UFRPE (Universidade Federal Rural de Pernambuco) e IPA (Instituto Agrônomo de Pernambuco), com apoio do CNPq (Conselho Nacional de Desenvolvimento Científico e Tecnológico), com intuito de subsidiar futuros programas de plantio florestal comercial na região, como alternativa concreta para atender à demanda de biomassa do parque industrial do gesso (FUPEF, 2007).

Neste contexto, têm-se a hipótese de que a implantação de reflorestamentos comerciais com espécies do gênero *Eucalyptus* para fins energéticos na região do Polo Gesseiro do Araripe pode ser uma alternativa técnica, ambiental e economicamente viável.

Para sustentar esta hipótese, vários estudos têm sido realizados nessa região. No estudo realizado por Silva (2008/2009) em que pretendia avaliar as potencialidades de florestas energéticas de eucaliptos no Polo Gesseiro do Araripe conclui que para uma produção de 4,2 milhões de ton. de gesso e um IMA de 15 m³/ha para o eucalipto, seriam necessários, aproximadamente, 3.360 hectares plantados com eucaliptos por ano que resulta em 16.800 ha com rotação de 5 anos. Essa simulação realizada pelo autor, enfatiza à necessidade de plantio de florestas energéticas de eucaliptos como fonte alternativa e viável para a indústria do gesso na região do Araripe.

No estudo realizado por Gadelha (2010) em que pretendia estimar o rendimento volumétrico e energético de clones de híbridos de *Eucalyptus urophylla* (Cruzamento Natural) e *Eucalyptus brassiana* conclui que estas espécies apresentaram melhor rendimento volumétrico e energético quando comparada as outras fontes de biomassa florestal usada pelas calcinadoras.

Não obstante a isso, Rocha (2012) realizou um estudo para avaliar a produtividade volumétrica de clones de *Eucalyptus* spp. e teve como resultado que a alta produtividade, aliada ao menor tempo de rotação de clones de *Eucalyptus* spp. comparada aos planos de manejo florestal sustentado da Caatinga, faz desse gênero um grande potencial para ser usado como oferta para fins energéticos e minimizar o processo de devastação da vegetação nativa.

2.2 CUBAGEM RIGOROSA

O procedimento mais adotado para a quantificação do crescimento e da produção de uma determinada floresta é a utilização de equações de volume. No entanto, para se obter essas equações é necessário recorrer ao método de cubagem rigorosa, que consiste na divisão do fuste em n secções, obtendo o volume de cada secção (CABACINHA et al., 2013).

As principais fórmulas matemáticas empregadas na obtenção do volume individual a partir da cubagem rigorosa são a de Huber, Newton e a de Smalian (AVERY; BURKHART, 1994; THIERSCH, 2002). Esses autores ressaltam que estas fórmulas empregadas na cubagem são válidas quando as secções se assemelham a um tronco de parabolóide de revolução e podem fornecer resultados idênticos se o fuste for perfeitamente cilíndrico.

De acordo com Ounekham (2009), das três fórmulas apresentadas, a fórmula de Smalian é a mais fácil de aplicar, mas pode demonstrar alguma imprecisão quando existe uma irregularidade do fuste.

No entanto, a estimativa do volume pelo uso do xilômetro é considerado o único método de cubagem rigorosa que fornece o valor do volume verdadeiro (MACHADO et al., 2006). Para Husch; Miller e Beers (1972) apesar do xilômetro apresentar resultados precisos, a sua aplicação é muito reduzida devido a elevados custos na instalação de equipamentos e no manuseio de toras com grande volume.

Desta forma, a fórmula mais usada para cubar rigorosamente o volume de uma árvore, consiste em derrubar e cubar as secções da árvore usando a fórmula de Smalian.

2.3 MODELAGEM VOLUMÉTRICA

No manejo florestal, fórmulas complexas baseadas em relações propostos por Huber, Smalian e Newton são usadas para estimar o volume das árvores. Todos esses relacionamentos exigem muitas medidas de diâmetros em determinadas alturas que são difíceis de obter em árvores em pé, especialmente quando as medições de diâmetro têm de ser tomadas a vários metros acima do solo (DIAMANTOPOULOU, 2006).

De acordo com Adekunle et al. (2013) a prática comum para solucionar o problema acima mencionado é a aplicação de modelos volumétricos. Esses modelos têm sido usados com frequência em empresas do setor privado para a construção de tabelas de volume (OLIVEIRA et al., 2009).

Na construção de tabelas de volume são considerados os modelos de simples e dupla entrada. Os modelos de simples entrada utilizam apenas o diâmetro como estimador do volume total ou comercial, sendo indiscutivelmente práticos e normalmente aplicados quando a correlação entre o diâmetro e a altura é muito forte, ou seja, onde há bastante homogeneidade no desenvolvimento em altura das árvores de mesmo diâmetro (OLIVEIRA et al., 2009).

Os modelos de dupla entrada empregam como variáveis independentes o diâmetro e a altura, ou uma combinação dessas aplicadas para povoamentos em que há uma maior heterogeneidade no desenvolvimento da altura das árvores com mesmo diâmetro (SCHNEIDER, 1993; THIERSCH et al., 2006; SCHRÖDER et al., 2013).

Campos e Leite (2013) consideram que dos tantos modelos existentes, os modelos desenvolvidos por Schumacher e Hall e Spurr são considerados os mais difundidos, talvez por causa das suas propriedades estatísticas e facilidade no ajustamento. Estes modelos são apresentados nas expressões 1 e 2, com a seguinte designação:

$$V_i = \beta_0 \cdot DAP_i^{\beta_1} \cdot H_i^{\beta_2} \cdot \varepsilon_i \quad (1)$$

$$V_i = \beta_0 + \beta_1 (DAP^2 H)_i + \varepsilon_i \quad (2)$$

Lynch (1995); Berger et al. (2014) realçam que um dos grandes problemas na modelagem volumétrica é a estimativa do volume individual das árvores com a variável altura, considerada como uma grande fonte de erro e custos na avaliação das estimativas no inventário florestal.

No entanto, Silva e Borders (1993) desenvolveram um modelo apresentado na expressão 3 para a estimativa do volume de árvores individuais para *Pinus taeda* L. no Sudeste dos Estados Unidos, considerando o volume das secções da primeira tora como variáveis independente, dispensando a variável altura. Este modelo desenvolvido por estes autores, estimou o volume com uma grande precisão, aproximando a equação de volume local derivado do modelo 1.

$$V_i = \beta_0 + \beta_i \sum_{i=1}^n X_i + \varepsilon_i \quad (3)$$

Em que:

V_i = volume total da árvore i ;

X_i = volume das secções 1 a n ;

β_0 e β_i = parâmetros do modelo;

ε_i = erro aleatório da árvore i .

2.4 ERROS NA MEDIÇÃO DA ALTURA

Na silvicultura, a altura da árvore é uma variável importante em programas de inventário florestal, definida como sendo a distância vertical do nível do solo para o ponto mais alto da árvore. Esta variável é um atributo fundamental em inventários florestais, que pode ser determinada ou estimada, para a estimativa do volume, biomassa, carbono e índice de sítios (MCCOMBS; ROBERTS; EVANS, 2003; WEST, 2009).

Os erros de medição influem diretamente na precisão da estimativa do volume de árvores individuais e conseqüentemente do povoamento florestal (COUTO; BASTOS, 1988). Zhang et al. (2014), salientam que o diâmetro em relação à altura, é relativamente fácil de medir, com boa precisão e com poucos custos.

Devido à dificuldade na sua estimativa em campo utilizando as técnicas convencionais, o que tem resultado em erros de medição, vários silvicultores têm desenvolvido várias técnicas com abordagem mais econômica, classificados por método direto ou expedito e método indireto ou de estimação que atendem aos padrões de precisão (ANDERSEN; REUTEBUCH; MCGAUGHEY, 2006; BRAGG, 2008; GATZIOLI; FRIED; MONLEON, 2010; BRAGG et al., 2011).

De acordo com Larjavaara e Muller-Landau (2013), a maioria dos métodos diretos para medir a altura das árvores (até 25 m) envolve a utilização de trenas ou vara telescópica que são fiáveis, mas susceptíveis a erros de medição, que podem atingir os 10%. Esse método requer dois técnicos de campo, porque a altura relativa das partes superiores é difícil de julgar diretamente a baixo e é relativamente limitado a pequenas árvores (por exemplo, abaixo de 10 m de altura).

No entanto Andersen, Reutebuch e Mcgaughey (2006) salientam que devido às dificuldades práticas na medição da altura das árvores diretamente, os silvicultores recorrem a técnica de medida indireta, usando os ângulos da base da árvore (θ), do topo da árvore (ρ) e a distância horizontal (h_d) com a seguinte fórmula básica da trigonometria, expresso pela Fórmula 4:

$$h = h_d(\tan \rho + \tan \theta) \quad (4)$$


2.5 REDES NEURAIS ARTIFICIAIS

2.5.1 Fundamento das redes neurais artificiais

Uma rede neural é um sistema computacional constituído por várias unidades de processamento, com um funcionamento bastante simples, conhecidas como neurônios (KHANNA,1990; HAJEK, 2005; KRIESEL, 2005). O comportamento do neurônio artificial utilizado para caracterizar o neurônio biológico, é o passo inicial para compreender as redes neurais (VALENÇA, 2005).

De acordo com Rumelhart, Hinton e Williams (1986) a primeira proposta de uma representação de uma unidade de processamento, para representar o neurônio biológico utilizando uma regra de propagação e uma função de ativação (Figura 1), foi feita por McCulloch e Pitts em 1943. A emissão de sinal por esse neurônio está baseada em um limiar em analogia com a *Lei do Tudo ou Nada*.

Figura 1 - Esquema do neurônio de McCulloch - Pitts com limiar explícito.



Fonte: Adaptado de Safi e Bouroumi (2013).

Na estrutura do neurônio de McCulloch e Pitts observa-se:

- Um conjunto de entradas que recebem os sinais de entrada do neurônio;
- Um conjunto de sinapses cujas intensidades são representadas por pesos associados a cada uma delas;
- Uma função de ativação que relaciona as entradas e suas sinapses ao limiar da função a fim de definir se o neurônio será ativado ou não.

Considerando que $x_1, x_2, x_3, \dots, x_n$, como sendo as variáveis de entrada $x_j (j = 1, \dots, n)$ do neurônio de saída y . A entrada líquida net_i é dada pela seguinte regra de propagação, expressa pela Fórmula 5:

$$net_i = \sum_{j=1}^n w_{ij} x_j - \theta \quad (5)$$

Em que: w_{ij} são os pesos sinápticos e θ é o limiar.

2.5.2 Funções de ativação

O papel da função de ativação (Tabela 1) é determinar a forma e a intensidade de alteração dos valores transmitidos de um neurônio a outro, sendo que cada neurônio possui uma única função de ativação (HAYKIN, 2001; BRAGA; CARVALHO; LUDERMIR, 2007).

Tabela 1 - Funções de ativação.

Função de ativação	Equação matemática	Representação gráfica
Rampa simétrica	$g(u) = \begin{cases} a, & \text{se } u > a \\ u, & \text{se } -a \leq u \leq a \\ -a, & \text{se } u < -a \end{cases}$	
Logística	$g(u) = \frac{1}{1 + e^{-\beta u}}$	
Tangente hiperbólica	$g(u) = \frac{1 - e^{-\beta u}}{1 + e^{-\beta u}}$	
Gaussiana	$g(u) = e^{-\frac{(u-c)^2}{2\sigma^2}}$	
Linear	$g(u) = u$	

Fonte: Özkan e Erbek (2003); Favan (2015).

Em que: β = estimativa do parâmetro que determina inclinação da função; u = potencial de ativação da função; c = centro da função gaussiana; σ = desvio padrão.

2.5.3 Rede Multilayer Perceptron - MLP

Uma Rede MLP consiste de uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída. Valença (2010) considera que, a rede perceptron de múltiplas camadas (MLP), é uma generalização da rede perceptron simples pela adição de pelo menos uma camada intermediária.


Braga; Carvalho e Ludermir (2007) salientam que as funções de ativação dos neurônios devem ser não lineares e a rede MLP com uma camada escondida e função de ativação sigmoide pode aproximar qualquer função contínua arbitrária.

A Figura 2 apresenta uma rede MLP com três camadas, onde na camada de entrada existem 3 neurônios, na camada escondida 2 neurônios e na camada de saída 1 neurônio. O sinal nessa rede se propaga da camada de entrada para a camada de saída, portanto, as entradas líquidas (net_j) dos neurônios da camada escondida serão dadas pelas Fórmulas 6 e 7:

$$net_{1,2} = w_{0,1}x_0 + w_{1,1}x_1 + w_{2,1}x_2 + w_{3,1}x_3 \quad (6)$$

$$net_{2,2} = w_{0,2}x_0 + w_{1,2}x_1 + w_{2,2}x_2 + w_{3,2}x_3 \quad (7)$$

Figura 2 - Estrutura da rede MLP.



Fonte: Valença (2005).

Na Figura 2, os neurônios ao receberem as entradas, emitirão um sinal para o neurônio da camada seguinte, por meio da função de ativação $f(net_j)$. Considerando a função de ativação sigmoide, os sinais podem ser calculados com as Fórmulas 8 e 9:

$$f_{1,2}(net_{1,2}) = \frac{1}{1 + e^{-net_{1,2}}} \quad (8)$$

$$f_{2,2}(net_{2,2}) = \frac{1}{1 + e^{-net_{2,2}}} \quad (9)$$

Portanto, esses sinais se propagam para a camada seguinte, gerando a entrada líquida para os neurônios da próxima camada, nesse caso é a camada de saída com um único neurônio. Logo essa entrada líquida ($net_{1,3}$) é calculada recorrendo a Fórmula 10:

$$net_{1,3} = w_{0,3} \cdot 1 + w_{1,3} \cdot f_{1,2}(net_{1,2}) + w_{2,3} \cdot f_{2,2}(net_{2,2}) \quad (10)$$

Assim, o sinal do neurônio de saída (y) será dada pela Fórmula 11:

$$y = f_{1,3}(net_{1,3}) = \frac{1}{1 + e^{-net_{1,3}}} \quad (11)$$

O algoritmo tradicionalmente utilizado para o treinamento das redes MLP é o *back-propagation*, um algoritmo com paradigma supervisionado cujo treinamento ocorre em duas fases: a fase *forward* e a fase *backward*.

2.5.4 Aprendizagem das redes neurais

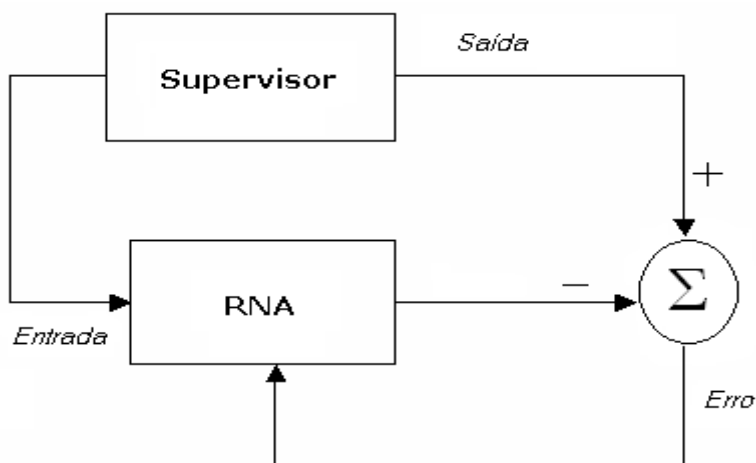
A propriedade que é de importância primordial para uma rede neural é a sua habilidade de aprender a partir de seu ambiente e de melhorar o seu desempenho por meio da aprendizagem. Uma rede neural aprende acerca do seu ambiente por meio de um processo iterativo de ajustes aplicados a seus pesos sinápticos e níveis de vieses (SOARES; SILVA, 2011). De acordo com Pelli (2013), 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.

De acordo com Valença (2010); Príncipe, Euliano e Lefebvre (1999) as redes neurais artificiais, possuem alguma forma de regra de aprendizagem que são responsáveis pela modificação dos pesos sinápticos, em função dos exemplos de entrada que são repetidamente apresentados. Assim, o treinamento das RNAs pode ser realizado por meio do aprendizado supervisionado ou do aprendizado não supervisionado.

2.5.4.1 Aprendizado supervisionado

Aprendizagem supervisionada, que é também denominada “aprendizagem com um professor”, é um método desenvolvido pela disponibilização de um professor que verifique os desvios da rede a um determinado conjunto de dados de entrada (SOARES; SILVA, 2011). Em termos conceituais, o professor é considerado como tendo conhecimento sobre o ambiente, sendo representado por um conjunto de exemplos de entrada-saída, como ilustrado na Figura 3.

Figura 3 - Diagrama da aprendizagem supervisionada.




Fonte: Adaptado de Haykin (2001).

2.5.4.2 Aprendizado não supervisionado

De acordo com Braga, Carvalho e Ludermir (2007), no aprendizado não supervisionado (Figura 4) não há a presença de um supervisor, apenas os padrões de entrada são passados para rede, sem saber qual a saída desejada para cada um deles. Os pesos da rede são modificados em função de critérios internos, tais como, por exemplo, a repetição de padrões de ativação em paralelo de vários neurônios.

Figura 4 - Diagrama da aprendizagem não supervisionada.



Fonte: Binoti (2010).

2.5.5 Vantagens e desvantagens da utilização das RNA

Em comparação com os modelos estatísticos, as redes neurais artificiais (RNAs) representam uma abordagem relativamente nova para o desenvolvimento de modelos preditivos (BLACKARD; DEAN, 1999). De acordo com Wu (2014) devido à sua flexibilidade e adaptabilidade, as redes neurais artificiais (RNAs) constituem uma abordagem alternativa e válida para a modelagem de ecossistemas biológicos dinâmicos de longa duração não lineares e complexos, como as florestas.

No entanto, elas tornaram-se muito populares por poderem aprender padrões e tendências complexas dos dados e também por serem ligeiramente afetados por problemas de qualidade de dados, como viés. Embora que existe uma grande popularidade da aplicação das redes neurais artificiais, elas apresentam vantagem assim como desvantagem na sua aplicação (Quadro 1).

Quadro 1- Vantagens e desvantagens das RNA.

Vantagens	Desvantagens
Os modelos das redes neurais requerem menos pressupostos estatísticos para modelar.	As redes neurais são uma "caixa preta" e têm capacidade limitada de identificar explicitamente possíveis relações causais.
Modelos de redes neurais podem detectar implicitamente relações não lineares complexas entre variáveis independentes e dependentes.	O tamanho da amostra tem que ser grande.
Modelos de redes neurais têm a capacidade de detectar todas as possíveis interações entre as variáveis preditoras.	Modelagem da rede neural exige mais recursos computacionais.
As redes neurais podem ser desenvolvidas usando vários algoritmos de treinamento diferentes.	Modelos de redes neurais são propensas a overfitting.
As transformações das variáveis são automatizadas no processo computacional.	O modelo da rede neural desenvolvido é empírico, e muitas questões metodológicas continuam por resolver.

Fonte: Tu (1996).

2.5.6 Aplicação das redes neurais no manejo florestal

A aplicação das redes neurais artificiais no manejo florestal começou com o desenvolvimento de sistemas inteligentes para a resolução de problemas e tomada de decisão para a maximização da produção (PENG; WEN, 1999).

Segundo Shao e Reynolds (2006), Higgins (2011), Soares (2012), Favani (2015), nos últimos tempos tem se notado um grande avanço na utilização das redes neurais, considerada como alternativa a modelagem de fenômenos não lineares e complexos na ciência florestal, sido aplicados dentro uma variedade de áreas no contexto de manejo florestal.

Um dos avanços de sucesso é a aplicação das redes neurais artificiais na modelagem do crescimento e dinâmica da floresta, com intuito de prever a prognose e avaliar a composição, estrutura e função do ecossistema (PENG; WEN, 1999; CASTRO et al., 2013). No entanto, as redes neurais artificiais também tem sido aplicadas com grande expressividade na estimativa de volume (GORGENS et al. 2009; WU, 2014; BHERING et al. 2015; BINOTI et al., 2015).

3 MATERIAL E MÉTODOS

3.1 ÁREA DE ESTUDO

O projeto foi desenvolvido na Estação Experimental do Instituto Agrônomo de Pernambuco (IPA), localizada na região do Araripe, no Município de Araripina, no semi-árido de Pernambuco, com coordenadas geográficas de posição 07°29'00' S e 54°36'00' W e uma altitude de 831 m, com solos do tipo (LA 19), definido como Latossolo Amarelo + Latossolo Vermelho - Amarelo (LIMA FILHO et al., 2012).

O clima regional predominante é do tipo BShw' de Koppen, quente e seco das baixas latitudes, com chuvas de verão, com uma precipitação média anual é de 650 mm, concentrada entre os meses de dezembro a março representando mais de 80% do total anual, o que provoca deficiências hídricas que se acumulam a partir do mês de maio até o mês de outubro, quando esta é mínima, sendo atenuada nos meses de fevereiro a abril nos quais ocorre um pequeno excesso (ARAÚJO, 2004).

3.2 CARACTERIZAÇÃO DO EXPERIMENTO

O experimento foi implantado em março de 2002, num espaçamento de 3m x 2m, em uma área de 2,352ha, contendo 15 clones, entre híbridos e espécies de *Eucalyptus* spp., provenientes da Comercial Agrícola Paineras Ltda localizada no município de Urbano Santos, no Estado Maranhão (Quadro 2).

Os dados utilizados são provenientes da segunda rotação do povoamento, coletados no ano de 2015, no sistema de talhadia conduzido com dois fustes, com uma idade de 5,5 anos. O corte da primeira rotação do experimento foi realizado em 2009, com uma idade de 7,5 anos, cortado a uma altura de 15 cm acima do solo.

As parcelas experimentais foram de 14x21m, com uma área total de 294m², constituída por 49 árvores por parcela e 25 árvores na parte útil.

Quadro 2 - Clones de *Eucalyptus* spp. utilizados no estudo para modelar o volume individual do fuste.

Tratamento	Clone	Híbridos
T01	C49	<i>Eucalyptus tereticornis</i> (cruzamento natural)
T02	C80	<i>E. urophylla</i> x <i>E. tereticornis</i> * (polinização controlada)
T03	C315	<i>E. urophylla</i> x <i>E. Tereticornis</i> * (polinização controlada)
T04	C101	<i>E. urophylla</i> x <i>E. tereticornis</i> * (polinização controlada)
T05	C78	<i>E. urophylla</i> x <i>E. tereticornis</i> * (polinização controlada)
T06	C156	<i>E. urophylla</i> x <i>E. tereticornis</i> x <i>E. pellita</i> (polinização controlada)
T07	C39	<i>E. urophylla</i> (cruzamento natural)
T08	C27	<i>E. brassiana</i> (cruzamento natural)
T09	C51	<i>E. urophylla</i> x <i>E. tereticornis</i> * (polinização controlada)
T10	C158	<i>E. urophylla</i> x <i>E. tereticornis</i> * (polinização controlada)
T11	C41	<i>E. urophylla</i> (cruzamento natural)
T12	C31	<i>E. brassiana</i> (cruzamento natural)
T13	C25	<i>E. brassiana</i> (cruzamento natural)
T14	C33	<i>E. urophylla</i> (cruzamento natural)
T15	C11	<i>E. brassiana</i> (cruzamento natural)

Observação: *As mudas dos clones C80, C315, C101, C78, C51, C158 foram produzidos com material genético de procedência da região de Laura, Queensland, Austrália.

3.3 CUBAGEM RIGOROSA

Foram derrubadas e seccionadas 2199 árvores, sendo mensuradas as alturas totais, altura do fuste e as circunferências, nas posições a 0,30; 0,50; 0,70; 0,90 1,10; 1,30; 1,50; 1,70; 2,30m; quando maior que 2,30m foi mensurada de 1,00 a 1,00 m até a altura total.

Devido à facilidade dos cálculos e rapidez na medição das pequenas secções, a fórmula geral de Smalian foi empregada, para calcular o volume das secções, utilizando a Fórmula 12 (CAMPOS; LEITE, 2013):

$$v_i = \frac{g_1 + g_2}{2} \cdot l \quad (12)$$

O volume total de cada indivíduo foi obtido pela somatória do volume das secções v_i usando a Fórmula 13.

$$V_i = \sum_{i=1}^n v_i + \frac{1}{3} \cdot g \cdot l \quad (13)$$

Em que:

v_i = volume da secção i (m^3)

V_i = volume da árvore i (m^3);

g_1 = área transversal na base da secção i da tora (m^2);

g_2 = área transversal no topo da secção i (m^2);

l = comprimento da seção (m);

i = número das secções da tora ($i = 1, 2, 3, \dots, n$).

3.4 MODELAGEM DO VOLUME

A modelagem do volume foi realizada considerando o resultado do teste de Scott-Knott (Tabela 2) realizado por Fontenele (2016), na qual resultou em 3 grupos de volume, em que no grupo A têm-se os clones C39 e C101; no grupo B os clones C41, C158, C80, C78, C51 e no grupo C os clones C27, C315, C156, C33, C11, C49, C25, C31. Também foi realizado o ajuste por espécie e para todas as espécies em conjunto.

Tabela 2 - Resultados do teste de Scott-Knott para o volume e incremento médio anual (IMA) dos 15 clones de *Eucalyptus* spp. aos 5,5 anos.

Tratamento	Descrição	Volume (m^3/ha)	IMA (m^3/ha)
7 C39	<i>E. urophylla</i> (cruzamento natural)	72,99 a	13,03 a
4 C101	<i>E. urophylla</i> x <i>E. tereticornis</i> (polinização controlada)	70,85 a	12,65 a
11 C41	<i>E. urophylla</i> (cruzamento natural)	57,68 b	10,30 a
10 C158	<i>E. urophylla</i> x <i>E. tereticornis</i> (polinização controlada)	56,23 b	10,04 a
2 C80	<i>E. urophylla</i> x <i>E. tereticornis</i> (polinização controlada)	51,37 b	9,17 a
5 C78	<i>E. urophylla</i> x <i>E. tereticornis</i> (polinização controlada)	45,32 b	8,09 a
9 C51	<i>E. urophylla</i> x <i>E. tereticornis</i> (polinização controlada)	46,09 b	8,23 a
8 C27	<i>E. brassiana</i> (cruzamento natural)	39,08 c	6,98 a
3 C315	<i>E. urophylla</i> x <i>E. tereticornis</i> (polinização controlada)	37,52 c	6,70 a
6 C156	<i>E. urophylla</i> x <i>E. tereticornis</i> x <i>E. pellita</i> (polinização controlada)	34,96 c	6,24 b
14 C33	<i>E. urophylla</i> (cruzamento natural)	29,05 c	5,18 b
15 C49	<i>E. brassiana</i> (cruzamento natural)	26,56 c	4,74 b
1 C49	<i>Eucalyptus tereticornis</i> (cruzamento natural)	23,01 c	4,10 b
13 C25	<i>E. brassiana</i> (cruzamento natural)	27,16 c	4,85 b
12 C31	<i>E. brassiana</i> (cruzamento natural)	14,49 c	2,58 c

3.4.1 Redes neurais artificiais

Para a estimativa do volume, foi utilizada a rede neural MLP (Multilayer Perceptron), em que foram treinadas 100 redes neurais de forma supervisionada, empregando o algoritmo de retropropagação do erro (*backpropagation*).

Ao modelar a rede, a análise foi concentrada nas etapas que incluem divisão dos dados, normalização dos dados, seleção das variáveis de entradas e saídas do modelo, melhor arquitetura da rede, o treinamento (critérios de parada, parâmetros, valores iniciais dos pesos) e a verificação do desempenho da rede.

O treinamento das RNAs foi realizado em duas etapas. A primeira etapa consistiu em fazer a análise de sensibilidade das variáveis de entrada e a segunda foi o treinamento com as variáveis selecionadas na análise de sensibilidade.

3.4.1.1 Divisão dos dados

O conjunto dos dados foi dividido em três subconjuntos independentes, um conjunto para ajustar os pesos durante o treinamento (50% da amostra), um conjunto para a validação cruzada (25% da amostra) e um conjunto para a verificação do desempenho do modelo (25% da amostra).

3.4.1.2 Normalização dos dados

Para que as variáveis em intervalos diferentes tivessem a mesma atenção durante o treinamento, de tal maneira que os seus valores fossem proporcionais aos limites das funções de ativação usadas na camada de saída, os dados foram normalizados no intervalo [0 1], utilizando a expressão 14.

$$y = \frac{(b - a)(x_i - x_{min})}{(x_{max} - x_{min})} + a \quad (14)$$

Em que:

y = valor normalizado;

x_i = valor original;

x_{min} = valor mínimo da variável;

x_{max} = valor máximo da variável;

b = limite superior da normalização;

a = limite inferior da normalização.

3.4.1.3 Seleção das variáveis de entrada

Para avaliar o desempenho das redes neurais artificiais em modelar o volume foram consideradas duas alternativas das variáveis de entrada. A primeira considerou-se as variáveis comumente utilizadas, *DAP* e *H* e a segunda o volume das secções da tora.

No entanto, como se tinha 28 secções, foi necessário aplicar a técnica de análise de sensibilidade (determinação da importância ou combinações das variáveis) para selecionar as variáveis de entrada, verificando a medida de quanto o valor predito da rede neural muda para os diferentes valores da variável independente e como critério de seleção, considerou-se a análise de sensibilidade de 80% (Apêndice).

3.4.1.4 Arquitetura da rede

A quantidade de neurônios necessários na camada intermediária foi obtida através da fórmula de Baum-Haussler, relacionando o número de neurônios ocultos com o tamanho da rede e o erro permitido, de acordo com a expressão 15.

$$N_{hid} \leq \frac{N \varepsilon_{train}}{N_{inp} + N_{out}} \quad (15)$$

Em que:

N_{hid} = número de neurônios na camada intermediária;

N = número de exemplos utilizados para o treinamento;

N_{inp} = número de neurônios na camada de entrada;

N_{out} = número de neurônios na camada de saída;

$N\epsilon_{train}$ = erro tolerado no treinamento.

3.4.1.5 Treinamento da rede

O número máximo de ciclos ou a fixação de um erro mínimo para o conjunto de treinamento são critérios de parada que têm sido utilizados em diversos estudos. Portanto, neste estudo foi considerado como critério de parada do treinamento da rede a validação cruzada, que consistiu em utilizar o conjunto de dados de 25% da amostra. Para o treinamento das RNAs utilizou-se o software livre *NeuroForest* 3.2 disponível em (<http://neuroforest.ucoz.com>).

3.4.2 Modelos volumétricos

Para a modelagem volumétrica, foram considerados 4 modelos volumétricos, dos quais 1 não linear e 3 lineares (Tabela 3).

Tabela 3 - Modelos volumétricos testados para estimar o volume dos clones de *Eucalyptus* spp.

Número	Modelo	Autor
1	$V_i = \beta_0 + \beta_1(DAP^2H)_i + \epsilon_i$	Spurr
2	$V_i = \beta_0.DAP_i^{\beta_1}.H_i^{\beta_2}.\epsilon_i$	Schumacher e Hall
3	$V_i = \beta_0 + \beta_1DAP^2_i + \beta_2H_i + \beta_3DAP^2H_i + \epsilon_i$	Stoate
4	$V_i = \beta_0 + \beta_1VS_i + \dots + \beta_nVS_n + \epsilon_i$	Silva e Borders

Em que: V_i = volume por árvore; DAP = diâmetro à altura do peito; H_i = altura da árvore i ; VS_i = volume das secções (1-28); β_i = parâmetro do modelo; ϵ_i = erro aleatório, sendo $\epsilon \sim N(0, \sigma^2)$.

No modelo de Silva e Borders, considerou-se 28 combinações de volume das secções da primeira tora (Tabela 4). Portanto, por este modelo ter muitas variáveis independentes, foi modificado, aplicando o *Stepwise* para selecionar quais variáveis mais influenciam o conjunto de saída, diminuindo assim o número de variáveis a compor a equação de regressão final.

No processo de *stepwise*, a primeira variável inserida no modelo de regressão foi a que apresentou um maior coeficiente de correlação simples com a variável dependente. O ajuste dos modelos e o *stepwise* foram realizados com o software R (2016). Para a seleção das variáveis foi utilizado o teste F em nível de $p < 0,01$.

Tabela 4 - Combinações das seções da primeira tora utilizadas para modelar o volume de clones de *Eucalyptus* spp. aos 5,5 anos de idade, no Polo Gesseiro do Araripe em Pernambuco.

Número da Secção	Intervalo das secções (m)	Comprimento da secção (m)
1	0,30-0,50	0,20
2	0,30-0,70	0,40
3	0,30-0,90	0,60
4	0,30-1,10	0,80
5	0,30-1,30	1,00
6	0,30-1,50	1,20
7	0,30-1,70	1,40
8	0,50-0,70	0,20
9	0,50-0,90	0,40
10	0,50-1,10	0,60
11	0,50-1,30	0,80
12	0,50-1,50	1,00
13	0,50-1,70	1,20
14	0,70-0,90	0,20
15	0,70-1,10	0,40
16	0,70-1,30	0,60
17	0,70-1,50	0,80
18	0,70-1,70	1,00
19	0,90-1,10	0,20
20	0,90-1,30	0,40
21	0,90-1,50	0,60
22	0,90-1,70	0,80
23	1,10-1,30	0,20
24	1,10-1,50	0,40
25	1,10-1,70	0,60
26	1,30-1,50	0,20
27	1,30-1,70	0,40
28	1,50-1,70	0,20

3.5 AVALIAÇÃO DA QUALIDADE DOS AJUSTES

Entre os critérios estatísticos comumente utilizados, a avaliação da qualidade dos ajustamentos das redes neurais e dos modelos volumétricos, foi realizada com base no índice de ajuste corrigido, erro quadrático médio e pela análise gráfica dos resíduos. Esses critérios estatísticos foram obtidos pelas Expressões 16, 17, 18.

a) Índice de ajuste ajustado de Schlaegel (AKINDELE; LEMAY, 2006)

$$IA_{aj} = IA - (1 - IA) \cdot \left(\frac{n - 1}{n - p} \right) \quad (16)$$

$$IA = 1 - \frac{SQ_{res}}{SQ_{total}}$$

b) Raiz quadrada do erro quadrático médio (RQEM)

$$RQEM_{(\%)} = \frac{100}{\bar{Y}} \sqrt{\frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n}} \quad (17)$$

c) Análise gráfica dos resíduos

$$E_i = \left(\frac{Y_i - \hat{Y}_i}{Y_i} \right) \cdot 100 \quad (18)$$

Em que:

\hat{Y}_i = valor estimado;

Y_i = valor observado;

\bar{Y} = média dos valores observados e;

n = número de observações;

p = número de variáveis independentes o modelo;

IA_{aj} = Índice de ajuste ajustado;

IA = índice de ajuste.

4 RESULTADOS E DISCUSSÃO

4.1 ESTATÍSTICA DESCRITIVA DAS VARIÁVEIS

Na Tabela 5 estão apresentadas as estatísticas das variáveis analisadas para estimar o volume individual de clones de *Eucalyptus* spp. Nota-se que não existe uma grande diferença das variáveis *DAP* e *Ht* em relação à média, desvio padrão e variância para os clones *Eucalyptus urophylla*, *Eucalyptus brassiana*, *Eucalyptus urophylla* x *Eucalyptus tereticornis* e *Eucalyptus tereticornis*.

Tabela 5 – Estatísticas descritivas das variáveis amostradas.

Clones	Variáveis	Mínimo	Máximo	Média	Desvio padrão	Variância
<i>E. urophylla</i>	<i>DAP</i>	1,60	12,50	6,31	2,32	5,40
	<i>Ht</i>	2,96	16,70	9,21	2,76	7,63
<i>E. brassiana</i>	<i>DAP</i>	1,60	11,10	5,79	1,93	3,71
	<i>Ht</i>	2,70	12,80	8,22	2,08	4,32
<i>E. urophylla</i> x <i>E. tereticornis</i>	<i>DAP</i>	1,50	10,90	6,04	1,69	2,86
	<i>Ht</i>	2,20	15,48	9,40	2,17	4,71
<i>Eucalyptus tereticornis</i>	<i>DAP</i>	1,30	9,10	5,18	1,73	2,98
	<i>Ht</i>	2,45	12,10	7,17	2,13	4,52

Em que *DAP* = Diâmetro medido a 1,3m de altura, *Ht* = altura total.

4.2 REDES NEURAS ARTIFICIAIS

Antes de se modelar a rede neural considerando as 28 combinações do volume das secções, foi necessário verificar a medida de quanto o valor predito da rede neural muda para os diferentes valores da variável independente (Apêndice) com o objetivo de selecionar as variáveis independentes que fariam parte da rede neural considerando o volume das secções. As redes neurais foram modeladas considerando todas as árvores, por clone e por grupo de clone resultante do teste de médias de Skott-Knott.

Os resultados apresentados (Tabelas 6, 7 e 8) pretendem avaliar as estatísticas obtidas, considerando duas formas de entrada das variáveis independentes na rede neural artificial para estimar o volume.

Tabela 6 – Estrutura e estatística das redes neurais artificiais ao modelar todas as árvores de clones de *Eucalyptus* spp., aos 5,5 anos de idade, no Polo Gesseiro do Araripe em Pernambuco.

Rede	Variáveis de entrada	Arquitetura	IA_{aj}	$RQEM$ (%)		Função de ativação	
				Trein.	Teste	Camada oculta	Saída
MLP	<i>DAP e H</i>	2-8-1	0,981	0,794	0,850	Exponencial	Tanh
MLP	<i>VS</i> (16, 24 e 15)	3-6-1	0,996	0,216	0,221	Logística	Identidade

Em que: *DAP* = diâmetro a altura do peito; *H* = altura total da árvore; IA_{aj} = índice de ajuste ajustado; $RQEM$ = raiz quadrada do erro médio; *MLP* = *multilayer perceptron*; *VS* = volume das secções 16, 24 e 15; Trein. = Treinamento.

Tabela 7 – Estrutura e estatística das redes neurais artificiais ao modelar os clones de *Eucalyptus* spp. aos 5,5 anos de idade, no Polo Gesseiro do Araripe em Pernambuco.

Clones	Rede	Variáveis de entrada	Arquitetura	IA_{aj}	$RQEM$ (%) Trein.	$RQEM$ (%) Teste	Função de ativação	
							Camada oculta	Saída
<i>Eucalyptus urophylla</i>	MLP	<i>DAP e H</i>	2-9-1	0,967	0,674	0,726	Exponencial	Logística
	MLP	<i>VS</i> (11)	1-7-1	0,996	0,218	0,222	Logística	Identidade
<i>Eucalyptus brassiana</i>	MLP	<i>DAP e H</i>	2-6-1	0,994	0,405	0,447	Logística	Identidade
	MLP	<i>VS</i> (6 e 21)	2-7-1	0,998	0,258	0,265	Logística	Identidade
<i>E. u x E. t</i>	MLP	<i>DAP e H</i>	2-8-1	0,989	0,412	0,415	Tanh	Exponencial
	MLP	<i>VS</i> (28, 4 e 21)	3-9-1	0,992	0,524	0,549	Tanh	Tanh
<i>Eucalyptus tereticornis</i>	MLP	<i>DAP e H</i>	2-3-1	0,990	0,208	0,223	Logística	Identity
	MLP	<i>VS</i> (27)	1-5-1	0,991	0,195	0,213	Tanh	Tanh

Em que: *DAP* = diâmetro a altura do peito; *H* = altura total da árvore; IA_{aj} = índice de ajuste ajustado; $RQEM$ = raiz quadrada do erro médio; *MLP* = *multilayer perceptron*; *VS* = volume das secções 11; Trein. = Treinamento; *E. u x E. t* = *Eucalyptus urophylla x Eucalyptus tereticornis*; Tanh = tangente hiperbólica.

Tabela 8 - Estrutura e estatística das redes neurais artificiais ao modelar o grupo de clones de *Eucalyptus* spp. formado pelo Skott-Knott aos 5,5 anos de idade, no Polo Gesseiro do Araripe em Pernambuco.

Grupos	Rede	Variáveis de entrada	Arquitetura	IA_{aj}	$RQEM$ (%) Trein.	$RQEM$ (%) Teste	Função de ativação	
							Camada oculta	Saída
A	MLP	DAP e H	2-4-1	0,983	0,294	0,346	Tanh	Tanh
	MLP	VS (17, 27 e 14)	3-10-1	0,984	0,284	0,334	Identidade	Identidade
B	MLP	DAP e H	2-5-1	0,996	0,191	0,192	Exponencial	Identidade
	MLP	VS (25, 26, 19)	3-6-1	0,998	0,202	0,213	Tanh	Tanh
C	MLP	DAP e H	2-7-1	0,990	0,623	0,306	Logística	Identidade
	MLP	VS (17, 2, 15, 23 e 24)	5-11-1	0,992	0,619	0,293	Identidade	Identidade

Em que: DAP = diâmetro a altura do peito; H = altura total da árvore; IA_{aj} = índice de ajuste ajustado; $RQEM$ = raiz quadrada do erro médio; MLP = *multilayer perceptron*; VS = volume das secções 17, 27 e 14; Trein. = Treinamento; Tanh= tangente hiperbólica.

De um modo geral as arquiteturas das redes, considerado como variáveis de entrada os volumes das secções e considerando o DAP e a altura, apresentaram um bom desempenho do índice de ajuste e raiz quadrada do erro médio.

Os baixos valores da $RQEM$ obtidos ao modelar a rede neural para estimativa de volume, para todas as árvores, por clone e por grupo de clone pode ser justificada por os indivíduos pertencerem a mesma classe de idade, típico de florestas equiâneas e mesmo material genético.

Esses resultados corroboram com os resultados apresentados por Miguel et al. (2016) em que pretendia utilizar ferramentas de inteligência artificial na previsão do volume de árvores dentro de um povoamento florestal, obteve um $RQEM$ variando de 1.75 a 2.22%.

No estudo realizado por Soares et al. (2012) em que pretendia estudar a previsão recursiva de diâmetros para estimar o volume comercial de clones de *Eucalyptus* spp., sem o conhecimento prévio da altura total da árvore

utilizando redes neurais artificiais, obteve um *RQEM* baixo, variando de 0,41 a 1,30%.

Silva (2015), no estudo sobre o emprego de redes neurais artificiais com *skip-layer connections* na mensuração florestal, obteve um *RQEM* de 4,27%. Binoti; Binoti e Leite (2014), ao avaliarem diferentes configurações do treinamento de Redes Neurais Artificiais (RNA) para a estimativa do volume de árvores, teve um *RQEM* de 7,28%.

Diante disso, os resultados obtidos evidenciam que o uso da rede neural artificial para a estimativa do volume, não depende apenas do melhor desempenho estatístico, mas de sua praticidade e simplicidade na obtenção das variáveis de entrada. Em vários estudos em que se pretendem estimar o volume da árvore utilizando as redes neurais artificiais, tem sido utilizado na sua maioria como variáveis de entrada o *DAP* e a *H*.

Por exemplo, Araújo (2015), no estudo da modelagem da altura, volume e afilamento do fuste de *Calycophyllum spruceanum* Benth. empregando regressão e redes neurais artificiais utilizou como variáveis contínuas de entrada (*inputs*) *DAP*, altura total e idade.

Diamantopoulou (2005a), na estimativa do volume total utilizando redes neurais, considerou como variáveis de entrada o *DAP* e a altura.

Wu (2014) na estimativa de volume utilizando a rede neural artificial utilizou como variáveis de entrada *DAP* e altura.

Binoti et al. (2014) ao utilizarem as redes neurais artificiais para estimativa do volume de árvores, consideraram como variáveis de entrada *DAP* a *H* e os diâmetros nas posições de 0,0; 0,5; 1,0; 1,5; 2,0; e 4,0 m.

Gorgens et al. (2009) na estimativa do volume de árvores utilizando redes neurais artificiais, as variáveis de entrada foram o *DAP*, a altura e o local.

Portanto, embora que as duas formas de entrada das variáveis independentes propiciaram estatísticas satisfatórias no que tange ao índice de ajuste ajustado e raiz quadrada do erro médio, em termos de erros associados a medição de altura, tanto do operador, como do aparelho de medição, as variáveis de entrada da rede neural artificial considerando o volume das secções é o recomendado por não necessitar a estimativa da variável altura, considerado uma variável de difícil obtenção.

As Figuras 5, 6, 7 apresentam a distribuição gráfica dos resíduos, com um comportamento distinto e semelhante para cada arquitetura da rede neural analisado, para todas as árvores, por clone e por grupo de clone.

Figura 5 – Gráfico de distribuição de resíduos em relação ao volume predito para todas as árvores aos 5,5 anos de idade, no Polo Gesseiro do Araripe em Pernambuco.

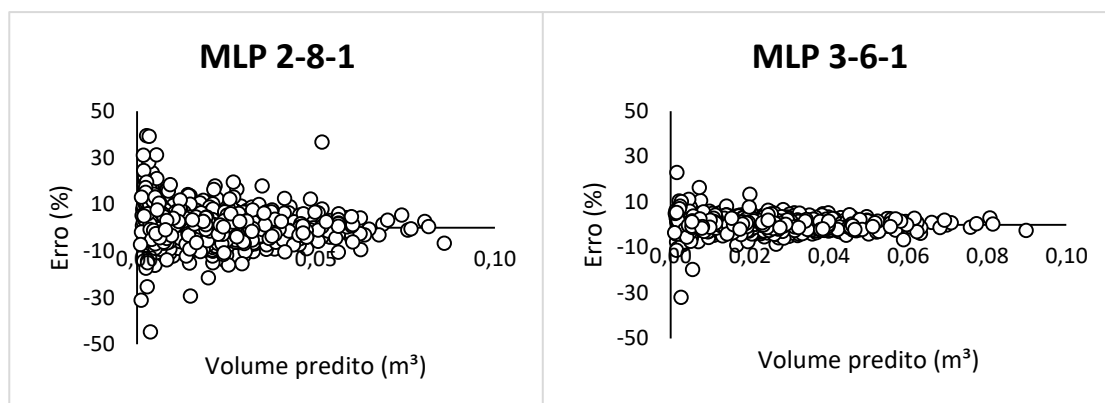


Figura 6 – Gráfico de distribuição de resíduos em relação ao volume predito para clones de *Eucalyptus* spp. aos 5,5 anos de idade, no Polo Gesseiro do Araripe em Pernambuco.

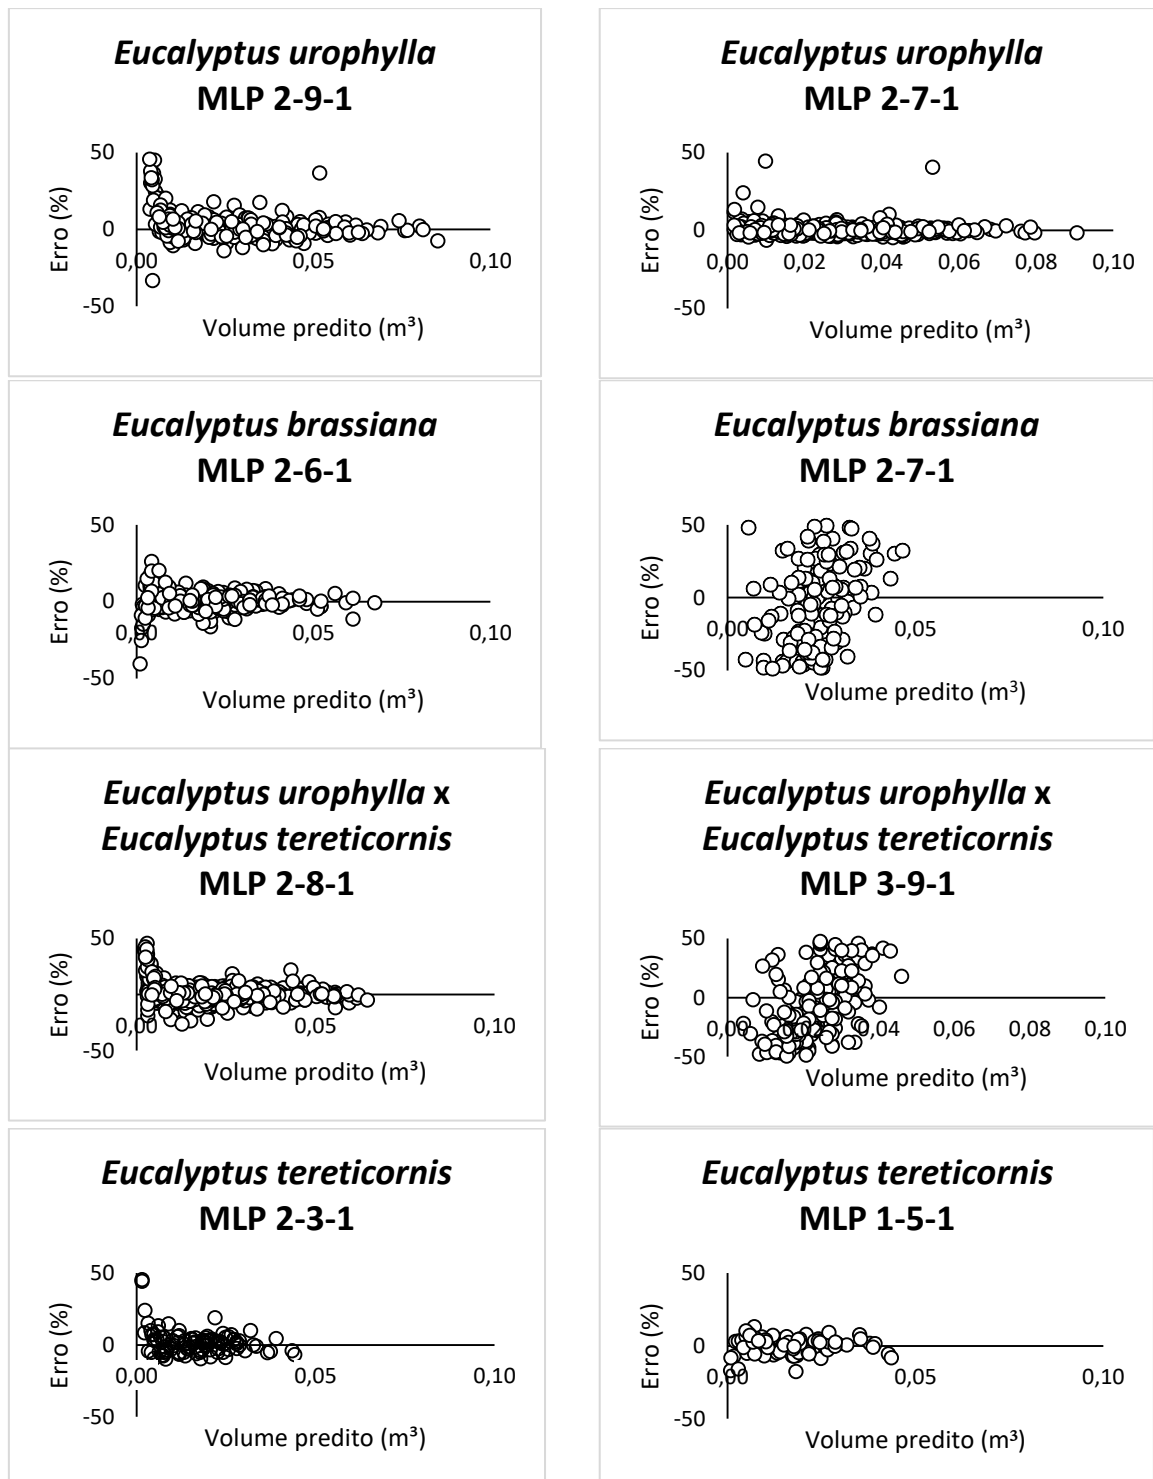
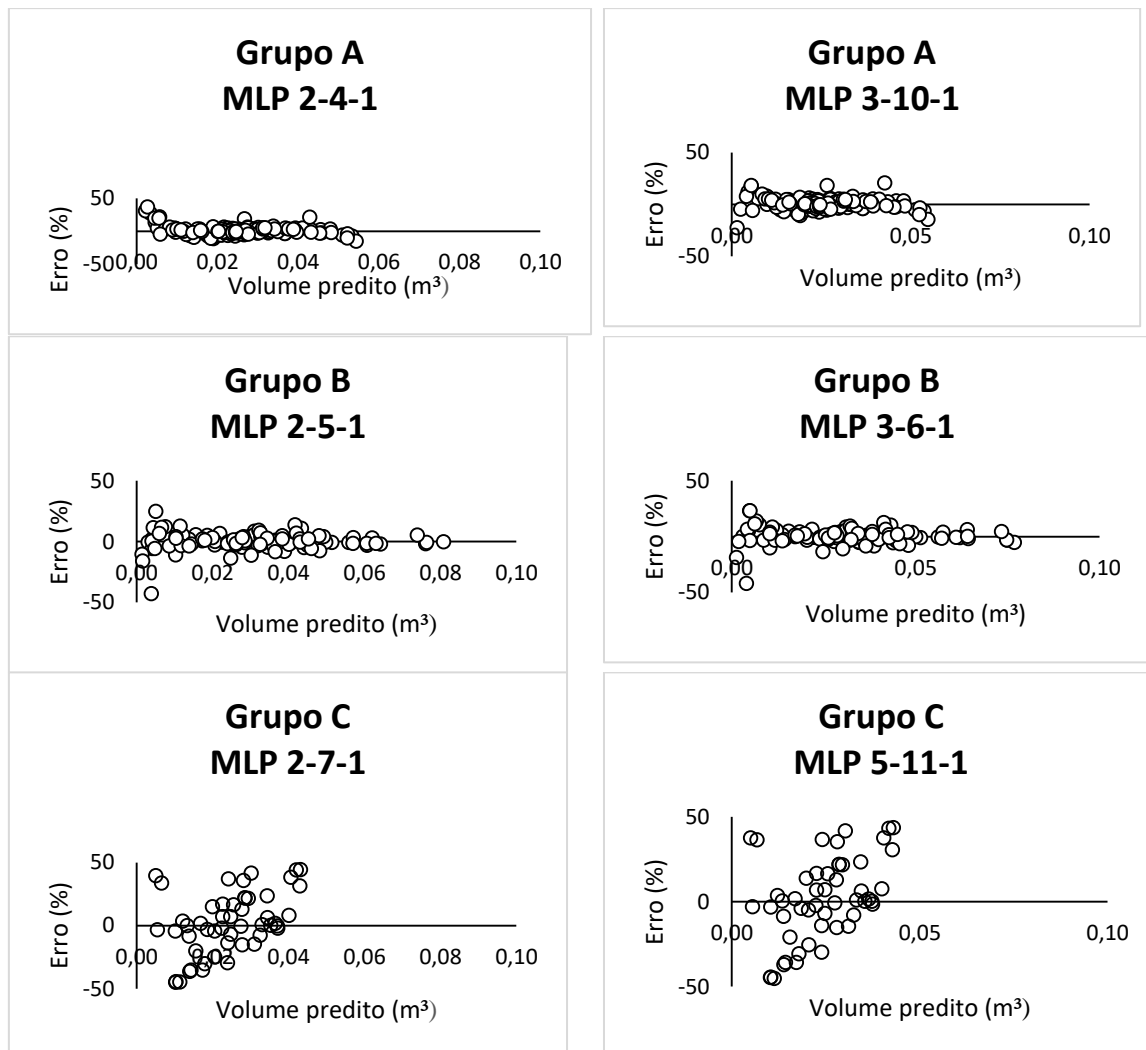


Figura 7 – Gráfico de distribuição de resíduos em relação ao volume predito para o grupo de clones de *Eucalyptus* spp. com 5,5 anos de idade, no Polo Gesseiro do Araripe em Pernambuco.



Na Figura 5, o gráfico de distribuição de resíduos para a modelagem com todas as árvores, a arquitetura MLP 2-8-1 teve uma ligeira tendência de superestimativa e subestimativa do resíduo para valores maiores e menores do volume predito. A arquitetura MLP 3-6-1 os resíduos se distribuíram de forma aleatória em torno de zero, sem muita tendenciosidade.

O gráfico de distribuição de resíduos em relação ao volume predito para *Eucalyptus urophylla*, a arquitetura MLP 2-9-1, apresentou subestimativa dos volumes maiores, no entanto, a arquitetura MLP 2-7-1, a distribuição de resíduo foi sem tendenciosidade (Figura 6).

A distribuição de resíduos em relação ao volume predito para *Eucalyptus brassiana*, a arquitetura MLP 2-6-1 a distribuição de resíduo teve a tendência de superestimar os valores menores do volume real. A distribuição de resíduo para a arquitetura MLP 2-7-1 se comportou de forma satisfatória, seguindo um padrão de distribuição, ou seja, a condição de independência é satisfeita (Figura 6).

O gráfico de distribuição de resíduos em relação ao volume predito para *Eucalyptus urophylla* x *Eucalyptus tereticornis* a arquitetura MLP 2-8-1 teve uma ligeira tendência de superestimativa dos menores valores do volume real. No entanto, a arquitetura MLP 3-9-1 apresentou uma distribuição aleatória do resíduo (Figura 6).

O gráfico de distribuição de resíduos em relação ao volume predito para *Eucalyptus tereticornis* a arquitetura MLP 2-3-1 teve uma tendência de superestimar valores menores de volume e a arquitetura MLP 1-5-1 teve a tendência de subestimar (Figura 6).

O gráfico de distribuição de resíduos em relação ao volume predito para o grupo A, as arquiteturas MLP 2-4-1 e MLP 3-10-1 em relação a distribuição de resíduos tiveram um comportamento não satisfatório, caracterizado por superestimar e subestimar o volume real (Figura 7).

No grupo B, as arquiteturas MLP 2-5-1 e MLP 3-6-1 tiveram comportamento semelhante, com uma distribuição uniforme do resíduo sem grandes tendências ao estimar o volume predito (Figura 7).

O gráfico de distribuição de resíduos em relação ao volume predito para o grupo C às arquiteturas MLP 2-7-1 e MLP 5-11-1, tiveram um bom ajuste da distribuição dos resíduos (Figura 7).

4.3 MODELAGEM VOLUMÉTRICA

Os resultados obtidos após o processo de *stepwise* para a seleção das variáveis independentes no modelo contendo as 28 combinações do volume das secções, eliminando aquelas cujas contribuições não foram significativas e as estatísticas dos modelos de Spurr, Schumacher-Hall, Stoate e Silva-Borders estão apresentados nas Tabelas 9, 10, 11.

Tabela 9- Equações e estatísticas dos modelos volumétricos ao modelar todas as árvores de clones de *Eucalyptus* spp., aos 5,5 anos de idade, no Polo Gesseiro do Araripe em Pernambuco.

Modelos	Equações geradas	IA_{aj}	RQEM (%)
Spurr	$\hat{V}_i = 0,00623 + 0,00000403(DAP^2H)$	0,9366	1,31
Shumacher-Hall	$\hat{V}_i = 0,0006 * DAP^{1,9471} * H^{0,0478}$	0,9668	1,16
Stoate	$\hat{V}_i = -0,000113 + 0,000536DAP^2 + 0,0000921H + 1,22709DAP^2H$	0,9410	1,26
Silva-Borders	$\hat{V}_i = 0,00002 + 4,0959D_{0,50}^2 + 0,4115D_{0,70}^2 + 11,4955D_{0,90}^2 + 4,1817D_{1,10}^2 + 9,7629D_{1,30}^2 + 4,9556D_{1,50}^2 + 7,1745D_{1,70}^2$	0,9482	1,13

Em que: IA_{aj} = índice de ajuste ajustado; RQEM = raiz quadrada do erro médio; DAP = diâmetro a altura do peito; H = altura total da árvore.

Tabela 10 - Equações e estatísticas dos modelos volumétricos ao modelar os clones de *Eucalyptus* spp. aos 5,5 anos de idade, no Polo Gesseiro do Araripe em Pernambuco.

Modelos	Equações geradas (<i>Eucalyptus urophylla</i>)	IA_{aj}	RQEM (%)
Spurr	$\hat{V}_i = 0,006804 + 0,000038(DAP^2H)$	0,9429	1,73
Shumacher-Hall	$\hat{V}_i = 0,000553 * DAP^{1,942636} * H^{0,057213}$	0,9856	1,03
Stoate	$\hat{V}_i = 0,001207 + 0,000509DAP^2 - 0,000048H + 0,000004DAP^2H$	0,9717	1,51
Silva-Borders	$\hat{V}_i = 0,0031 + 30,3142(D^2_{1,10} + D^2_{1,70}) - 27,9894(D^2_{0,30} + D^2_{0,50}) - 24,8904(D^2_{0,90} + D^2_{1,30}) + 16,6590(D^2_{0,70} + D^2_{1,50})$	0,9562	1,52
Modelos	Equações geradas (<i>Eucalyptus brassiana</i>)	IA_{aj}	RQEM (%)
Spurr	$\hat{V}_i = 0,003746 + 0,000051(DAP^2H)$	0,9555	1,41
Shumacher-Hall	$\hat{V}_i = 0,000547 * DAP^{2,000902} * H^{0,013909}$	0,9892	1,21
Stoate	$\hat{V}_i = -0,0000385 + 0,000556DAP^2 + 0,000007H + 0,000001DAP^2H$	0,9785	1,21
Silva-Borders	$\hat{V}_i = -0,0011 + 23,2074(D^2_{0,70} + D^2_{1,30}) - 30,2022(D^2_{0,30} + D^2_{1,70}) + 11,7592(D^2_{0,50} + D^2_{1,50}) - 0,3113(D^2_{0,90} + D^2_{1,10})$	0,9572	1,93
Modelos	Equações geradas (<i>Eucalyptus urophylla</i> x <i>Eucalyptus tereticornis</i>)	IA_{aj}	RQEM (%)
Spurr	$\hat{V}_i = 0,005996 + 0,970738(DAP^2H)$	0,9339	1,35
Shumacher-Hall	$\hat{V}_i = 0,000551 * DAP^{1,909524} * H^{0,086658}$	0,9896	1,15
Stoate	$\hat{V}_i = -0,000830 + 0,000532DAP^2 + 0,000203H + 0,000001DAP^2H$	0,9795	1,12
Silva-Borders	$\hat{V}_i = -0,00002 + 0,396314D^2_{0,30} + 0,606799D^2_{0,70} + 0,339525D^2_{1,10} + 0,663588D^2_{1,50}$	0,9079	1,07
Modelos	Equações geradas (<i>Eucalyptus tereticornis</i>)	IA_{aj}	RQEM (%)
Spurr	$\hat{V}_i = 0,005230215 + 0,949549(DAP^2H)$	0,9310	1,75
Shumacher-Hall	$\hat{V}_i = 0,000594 * DAP^{1,941059} * H^{0,028433}$	0,9922	1,46
Stoate	$\hat{V}_i = -0,000370554 + 0,975768DAP^2 + 0,030413H - 0,004373DAP^2H$	0,9842	1,63
Silva-Borders	$\hat{V}_i = -0,0156 + 0,58190D^2_{0,30} + 1,78916D^2_{0,50} + 0,29085D^2_{0,70} + 0,23880D^2_{1,10} - 1,70904D^2_{1,30} - 1,07509D^2_{1,50}$	0,9009	1,57

Em que: IA_{aj} = índice de ajuste ajustado; RQEM = raiz quadrada do erro médio.

Tabela 11 - Equações e estatísticas dos modelos volumétricos ao modelar o grupo de clones de *Eucalyptus* spp. formado pelo Skott-Knott aos 5,5 anos de idade, no Polo Gesseiro do Araripe em Pernambuco.

Modelos	Equações geradas (Grupo A)	IA_{aj}	RQEM (%)
Spurr	$\hat{V}_i = 0,006989041 + 0,000036(DAP^2H)$	0,9536	1,70
Shumacher-Hall	$\hat{V}_i = 0,000496 * DAP^{1,841748} * H^{0,183471}$	0,9952	1,07
Stoate	$\hat{V}_i = -0,000860 + 0,000488DAP^2 + 0,000261H + 0,000003DAP^2H$	0,9903	1,32
Silva-Borders	$\hat{V}_i = 0,000094 + 21,10100(D^2_{0,70} + D^2_{1,50}) + 7,09823(D^2_{0,30} + D^2_{1,70})$	0,9274	1,21

Modelos	Equações geradas (Grupo B)	IA_{aj}	RQEM (%)
Spurr	$\hat{V}_i = 0,008735762 + 0,000036(DAP^2H)$	0,9459	1,71
Shumacher-Hall	$\hat{V}_i = 0,000555 * DAP^{1,963628} * H^{0,041773}$	0,9969	1,40
Stoate	$\hat{V}_i = -0,0000634 + 0,000548DAP^2 + 0,000064H + 0,000001DAP^2H$	0,9937	1,42
Silva-Borders	$\hat{V}_i = 0,0000239 + 19,09316D^2_{0,70} + 13,58148D^2_{1,10} + 5,51168D^2_{1,50} + 7,94757(D^2_{0,30} + D^2_{1,70})$	0,9500	1,57

Modelos	Equações geradas (Grupo C)	IA_{aj}	RQEM (%)
Spurr	$\hat{V}_i = 0,003377016 + 0,000049(DAP^2H)$	0,9829	1,49
Shumacher-Hall	$\hat{V}_i = 0,000481 * DAP^{1,896185} * H^{0,153291}$	0,9975	1,26
Stoate	$\hat{V}_i = -0,000743771 + 0,000495DAP^2 + 0,000201H + 0,000004DAP^2H$	0,9948	1,27
Silva-Borders	$\hat{V}_i = 0,00000935 + 14,8329D^2_{0,50} + 8,821874D^2_{1,10} + 6,011075D^2_{1,50} + 4,990720(D^2_{0,30} + D^2_{1,30}) + 7,579853(D^2_{0,90} + D^2_{1,70})$	0,9716	1,30

Em que: IA_{aj} = índice de ajuste ajustado; RQEM = raiz quadrada do erro médio; DAP = diâmetro a altura do peito; H = altura total da árvore.

Os resultados indicam um bom desempenho para todos os modelos em termos de índice de ajuste ajustado (IA_{aj}) e raiz quadrada do erro médio ($RQEM\%$), o que estatisticamente evidencia que todos os modelos podem ser utilizados para a estimativa do volume individual dos clones de *Eucalyptus* spp. implantados na região do polo Gesseiro do Araripe em Pernambuco.

O modelo de Schumacher-Hall e Spurr é frequentemente utilizado no desenvolvimento das equações de volume do fuste. A superioridade do modelo de Schumacher-Hall foi claramente demonstrada neste estudo.

De acordo com Silva et al. (2009) este modelo é difícil de ser superado, porque a conformação logarítmica e a combinação das variáveis independentes DAP e altura H confere propriedades estatísticas muito favoráveis na estimativa volumétrica.

Em relação ao modelo de Spurr de variável combinada DAP^2H de acordo com Bi e Hamilton (1998); Sanquetta et al. (2015a); Huat; Tsai e Chubo (2009); Ounekham (2009) esta variável representa o volume de diâmetro D e altura do fuste H e isso faz com que esta esteja diretamente correlacionada com o volume.

No entanto, vários estudos realizados para a modelagem do volume têm relatado a robustez deste modelo para estimar o volume. Azevedo et al. (2011), ao aplicar modelos volumétricos para estimativa de volume em povoamentos de eucalipto sob regime de alto fuste e talhadia no Sudoeste da Bahia, conclui que modelo de Schumacher e Hall e de Spurr são os mais indicados para estimar o volume dos povoamentos nas duas condições de manejo.

No estudo realizado por Bi (1994), em que pretendia melhorar a estimativa do volume da rebrota de *Eucalyptus fastigata*, conclui que a equação de volume com variável combinada foi a mais adequada.

Não obstante a isso, Tewari e Kumar (2003) também indicaram que a melhor equação para estimar o volume da árvore total de *Eucalyptus camaldulensis*, plantada em uma área árida na Índia, foi a equação da variável combinada. O mesmo modelo também foi relatado como o melhor para

estimativa do volume total de *Eucalyptus paniculata* no estudo realizado por (BI; HAMILTON, 1998).

No entanto, os modelos de Spurr, Schumacher-Hall e Stoate tem uma particularidade de além do *DAP* terem a altura para a estimativa do volume, considerado como um dos fatores de perda de eficiência e precisão. De acordo com Bayati e Najafi (2012); Sanquetta et al., (2015b) na prática, precisão, e economia desempenham um papel muito importante ao decidir quais os métodos a utilizar para estimativa do volume.

Entretanto, olhando para estes aspetos, o modelo de Silva-Borders é adequado para estimar o volume dos 15 clones de *Eucalyptus* spp., por não considerar a variável altura. A vantagem advogada por vários autores em relação ao não uso da altura como variável independente na estimativa do volume é pela demora nas medições, dificuldades na sua mensuração e consequentemente, erros de medição que não são computados no uso da equação.

Para Sanquetta et al. (2014) a medição da altura encarece o inventário florestal e está sujeita a erros que se propagam para as estimativas volumétricas.

Silva e Borders (1993) salientam que o uso do volume das pequenas secções da primeira tora como variáveis independentes para predizer o volume total tem uma vantagem de não ser necessário à mensuração da altura.

Wink et al. (2015) corrobora com a ideia dos autores, enfatizando que vantagem dos modelos que tem somente o volume das secções como variável independente é que é muito fácil de obter e não requerem muito tempo para a sua mensuração e consequentemente o custo para o inventário será menor.

As Figuras 8, 9 e 10 apresentam a distribuição do resíduo dos modelos em relação ao volume predito, na modelagem considerando todas as árvores, por clones e por grupo de clones resultantes do teste de médias de Skott-Knott.

Figura 8 - Gráfico de distribuição de resíduos em relação ao volume predito para todas as árvores de *Eucalyptus* spp. com 5,5 anos de idade, no Polo Gesseiro do Araripe em Pernambuco.

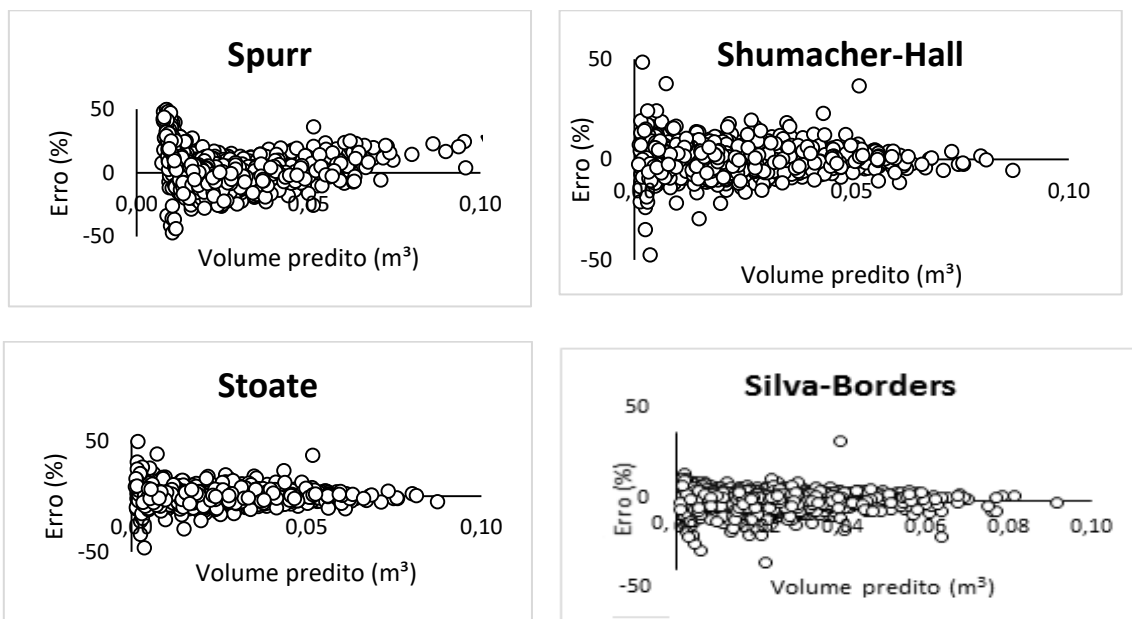
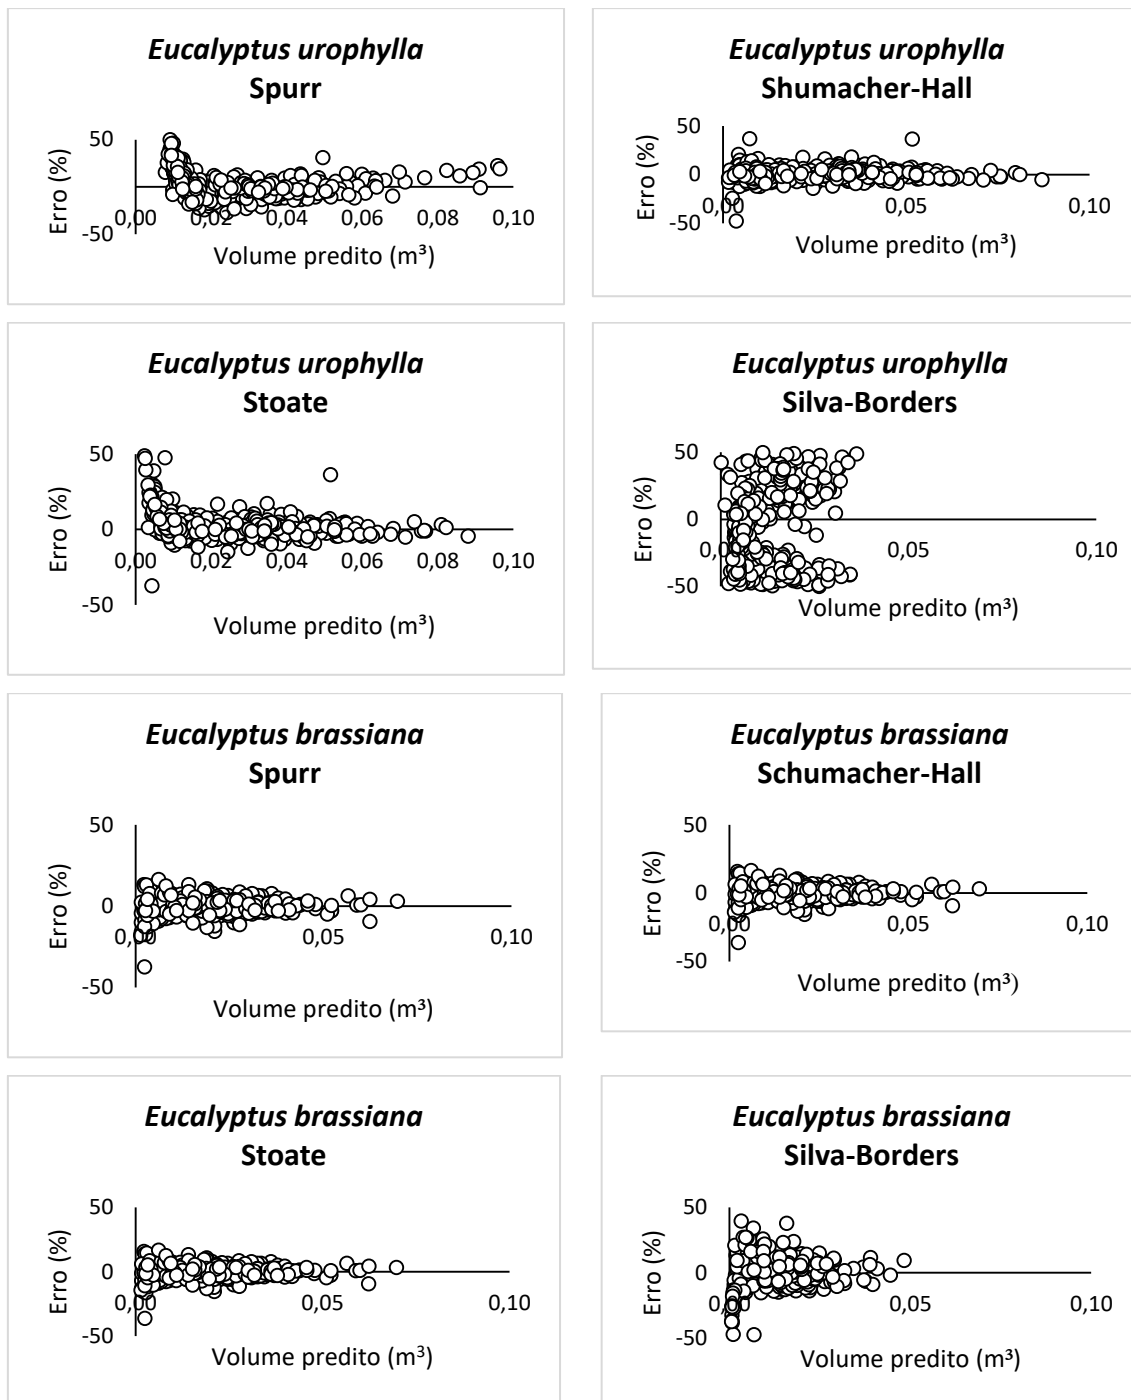


Figura 9 – Gráfico de distribuição de resíduos em relação ao volume predito para clones de *Eucalyptus* spp. aos 5,5 anos de idade, no Polo Gesseiro do Araripe em Pernambuco.



Continua

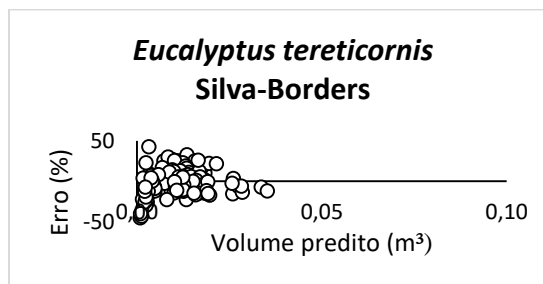
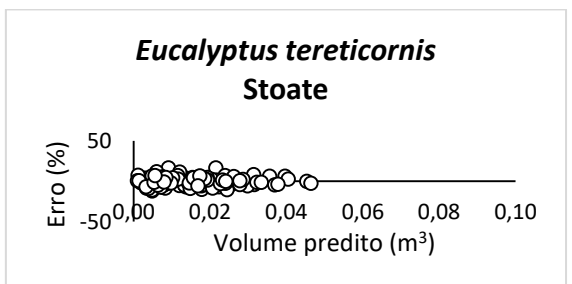

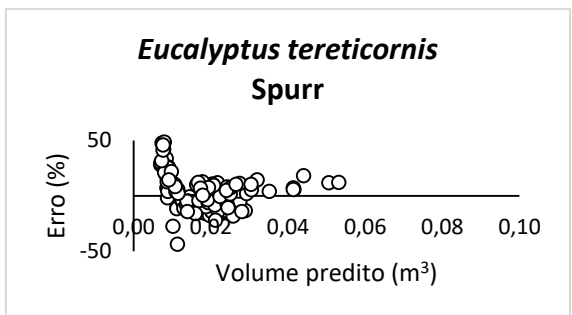


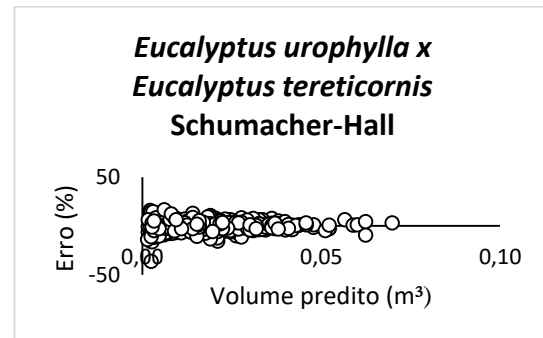

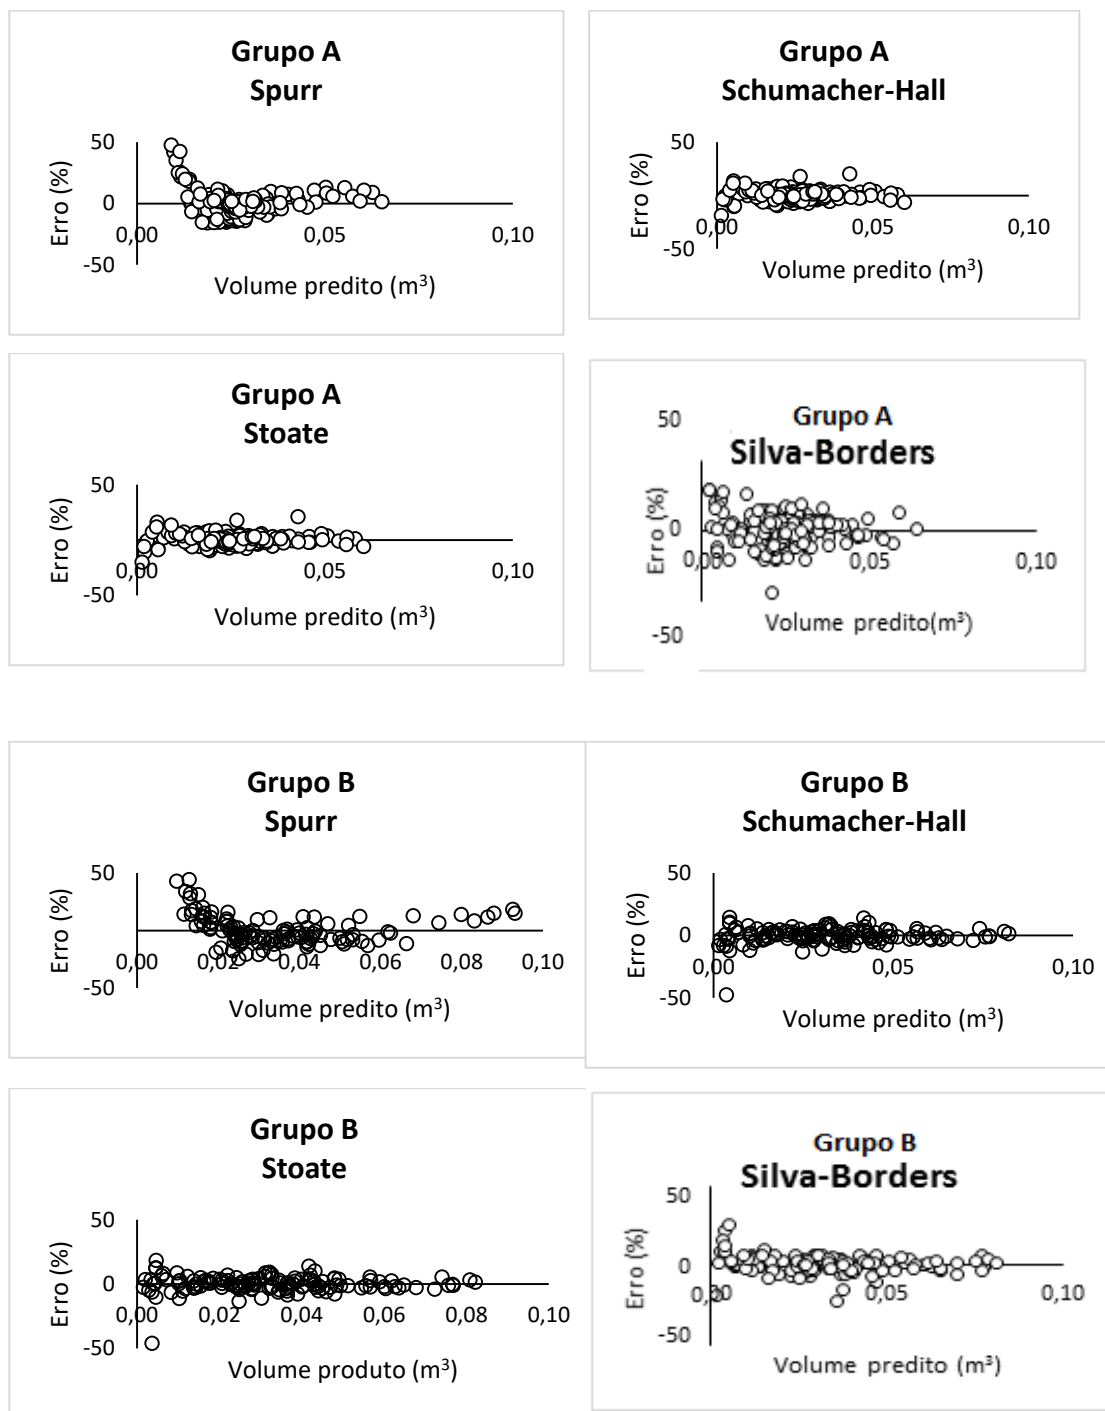
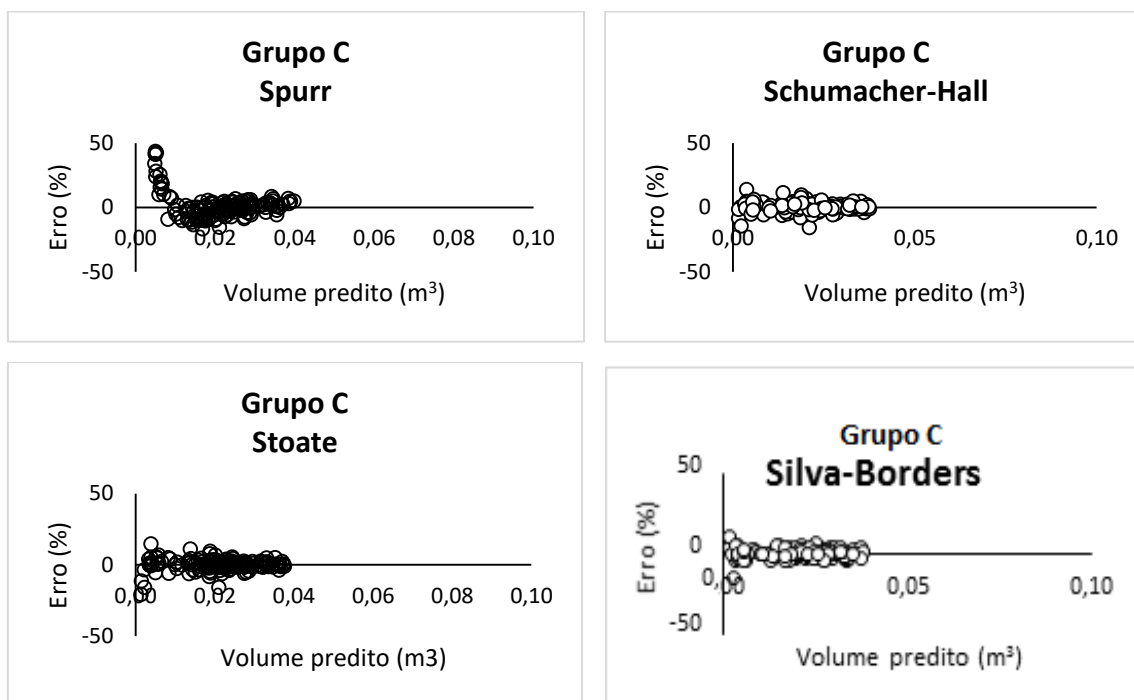


Figura 10 – Gráfico de distribuição de resíduos em relação ao volume predito para o grupo de clones de *Eucalyptus* spp. com 5,5 anos de idade, no Polo Gesseiro do Araripe em Pernambuco.



Continua



Na Figura 8, a distribuição de resíduos em relação ao volume predito para todas as árvores de *Eucalyptus* spp, o modelo de Spurr teve uma tendenciosidade de subestimar e superestimar o volume. O modelo de Schumacher-Hall, Stoate e Silva-Borders tiveram um comportamento semelhante, com uma boa distribuição do resíduo em torno do eixo x.

O gráfico de distribuição de resíduos em relação ao volume predito para *Eucalyptus urophylla* (Figura 9), indica uma superestimativa do volume predito para o modelo de Spurr e Stoate. O modelo de Schumacher-Hall teve os seus resíduos distribuídos de forma aleatória e o modelo de Silva-Borders não teve uma boa distribuição dos resíduos.

No gráfico de distribuição de resíduos em relação ao volume predito para *Eucalyptus brassiana* (Figura 9), os modelos de Spurr, Schumacher-Hall, Stoate tiveram uma uniformidade na distribuição dos resíduos, diferente do modelo de Silva-Borders que teve tendência em subestimar os valores menores do volume predito.

A distribuição de resíduos em relação ao volume predito para *Eucalyptus urophylla* x *Eucalyptus tereticornis* (Figura 9) apresentou tendências em superestimar ou subestimar o volume para os modelos de Spurr e Stoate. O modelo de Schumacher-Hall e Silva-Borders apresentaram uma distribuição uniforme do resíduo, sem tendenciosidade.

Na Figura 9, o modelo de Spurr foi o único a apresentar tendenciosidade em superestimar o volume predito de *Eucalyptus tereticornis*. Os modelos de Schumacher-Hall, Stoate e Silva-Borders, tiveram uma distribuição do resíduo sem grande tendenciosidade.

Na Figura 10, a distribuição de resíduos em relação ao volume predito para o grupo A de clones de *Eucalyptus* spp., os modelos de Spurr, Schumacher-Hall e Stoate mostraram tendenciosidade em estimar os volumes menores preditos. No entanto, o modelo de Silva-Borders teve um comportamento sem tendenciosidade, com uma distribuição aleatória do resíduo.

Na Figura 10 a distribuição de resíduos em relação ao volume predito para o grupo B de clones de *Eucalyptus* spp., o modelo de Spurr se mostrou tendencioso em superestimar valores maiores do volume. Os restantes modelos tiveram uma distribuição aleatória do resíduo sem tendenciosidade.

Na Figura 10 a distribuição de resíduos em relação ao volume predito para o grupo C de clones de *Eucalyptus* spp., apresentou uma tendenciosidade em superestimar o volume para o modelo de Spurr. Os restantes modelos tiveram uma distribuição uniforme do resíduo.

5 CONCLUSÃO

Em relação as equações geradas e as redes neurais artificiais, pode-se inferir que:

O modelo de Schumacher-Hall apresentou um melhor ajuste estático em relação aos outros modelos na estimativa do volume individual de clones de *Eucalyptus* spp.;

O modelo de Silva-Borders e as redes neurais artificiais considerando o volume das secções como variáveis de entrada, são menos propícios a erros associados a medição da altura e mais práticos em campo para estimar o volume individual de clones de *Eucalyptus* spp., por não necessitar a variável altura;

A rede neural artificial considerando o volume das secções como variáveis de entrada teve um melhor desempenho estatístico em relação a rede neural artificial considerando o *DAP* e *H* como variáveis de entrada para a estimativa do volume individual.

REFERÊNCIAS

ADEKUNLE, V. A. J. et al. Models and form factors for stand volume estimation in natural forest ecosystems: a case study of Katarniaghat Wildlife Sanctuary (KGWS), Bahraich District, India. **Journal of Forestry Research**, China, v. 24, n. 2, p. 217–226, 2013.

AKINDELE, S. O.; LEMAY, V. M. Development of tree volume equations for common timber species in the tropical rain forest area of Nigeria. **Forest Ecology and Management**, v. 226, n. 1-3, p. 41-48, 2006.

ANDERSEN, H.; REUTEBUCH, S. E.; MCGAUGHEY, R. J. A rigorous assessment of tree height measurements obtained using airborne lidar and conventional field methods. **Canadian Journal of Remote Sensing**, Vancouver, Canada, v. 32, n. 5, p. 355-366, 2006.

ARAÚJO, B. H. P. **Modelagem da altura, volume e afilamento do fuste de *Calycophyllum Spruceanum* Benth. empregando regressão e redes neurais artificiais**. 2015. 53 f. Dissertação (Mestrado em ciências florestais tropicais) - Instituto Nacional de Pesquisas da Amazônia, 2015.

ARAÚJO, S.M.S. **O Pólo Gesseiro do Araripe: unidades geo-ambientais e impactos da mineração**. 2004. 276 f. Tese (Doutorado em Geociências) - Universidade de Campinas, Campinas-SP, 2004.

AVERY, T.E.; BURKHART, H. E. **Forest measurement**. 4th ed. McGraw Hill Book Co., New York. 1994. 408p.

AZEVEDO, G. B et al. Estimativas volumétricas em povoamentos de eucalipto sob regime de alto fuste e talhadia no sudoeste da Bahia. **Pesquisa Florestal Brasileira**, Colombo, v. 31, n. 68, p. 309-318, 2011.

BAYATI, H.; NAJAFI, A. Models determination to estimate the volume, in the volume revising and extraction operations (case study: District 3, 46 Watershed, Iran). **Scholars Research Library**, Annals of Biological Research, India, 2012, v. 3, n. 8, p. 4054-4058, 2012.

BERGER, A et al. Effects of measurement errors on individual tree stem volume estimates for the Austrian National Forest Inventory. **Forest Science**, Praha 2, Czech Republic, v. 60, n. 1, p. 14–24, 2014.

BHERING, L. L et al. Application of neural networks to predict volume in *Eucalyptus*. **Crop Breeding and Applied Biotechnology**, Viçosa - MG, v. 15: p. 125-131, 2015.

BI, H. Improving stem volume estimation of regrowth *Eucalyptus fastigata* with a lower stem form quotient. **Australian Forestry**, Australia, v. 57, n. 3, p.98-104, 1994.

BI, H.; HAMILTON, F. Stem volume equations for native tree species in southern New South Wales and Victoria. **Australian Forestry**, Australia, v. 61, n. 4, p. 275-286, 1998.

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. 5, n. 1, p. 58-67, 2014.

BINOTI, M. L. M. S. et al. Prognose em nível de povoamento de clones de Eucalipto empregando redes neurais artificiais. **Cerne**, Lavras, MG, v. 21 n. 1, p. 97-105, 2015.

BINOTI, M. L. M. S. et al. Redes neurais artificiais para estimação do volume de árvores. **Revista Árvore**, Viçosa, MG, v. 38, n.2, p.283-288, 2014.

BINOTI, M. L. M. S. **Redes neurais artificiais para prognose da produção de povoamentos não desbastados de Eucalipto**. 2010. 54 f. Dissertação (Mestrado em Ciências Florestais) - Universidade Federal de Viçosa, 2010.

BLACKARD, J. A.; DEAN, D. J. Comparative accuracies of artificial neural networks and discriminant analysis in predicting forest cover types from cartographic variables. **Computers and Electronics in Agriculture**, Athens, Greece, v. 24, n. 3, p. 131-151, 1999.

BONYAD, A.; RAHIMNEJAD, S. Volume table estimation of loblolly pine in the north of Iran. **Pajouhesh-va-sazandegi**, Shabestar, Iran, v. 66, n. 1, p. 43-47, 2004.

BORGES, J.F. **Seccionamento do fuste de *Pinus taeda* L. para obtenção do volume de madeira serrada através da função polinomial**. 1981. 69 f. Dissertação (Mestrado em Engenharia Florestal) - Universidade Federal do Paraná, 1981.

BRAGA, A. P.; CARVALHO, A. C. P. L. F.; LUDERMIR, T. B. **Redes Neurais Artificiais: teoria e aplicações**. 2. ed. Rio de Janeiro: LTC, 2007. 238 p.

BRAGG, D. C. An improved tree height measurement technique tested on mature southern Pines: Technical note. **Southern Journal of Applied Forestry**, Washington, US, v. 32, n. 1, p. 38-43, 2008.

BRAGG, D. C. et al. The sine method: an alternative height measurement technique. **The Forest Service, United States Department of Agriculture (USDA)**, Research Note SRS-22, 2011.

CABACINHA, C. D et al. Uma nova abordagem para o método geométrico usando o índice da parábola. **Ciência Florestal**, Santa Maria, v. 23, n. 1, p. 261-271, 2013.

- CAMPELLO, F. C. B. **Análise do consumo específico de lenha nas indústrias gesseiras: a questão florestal e sua contribuição para o desenvolvimento sustentável da região do Araripe – Pe.** 2011. 61 f. Dissertação (Mestrado em Ciências florestais) - Universidade Federal Rural de Pernambuco, 2011.
- CAMPOS, J. C. C.; LEITE, H. G. **Mensuração florestal: perguntas e respostas.** 4.ed. Viçosa, MG: Universidade Federal de Viçosa, 2013. 605 p.
- CARVALHO, S. P. C. **Uma nova metodologia de avaliação do crescimento e da produção de *Eucalyptus* sp clonal para fins energéticos.** 2010. 103 f. Dissertação (Mestrado em Ciências Florestais) - Universidade Federal de Lavras, 2010.
- CASTRO, R. V. O. et al. Individual growth model for *Eucalyptus* stands in Brazil using artificial neural network. **ISRN Forestry**, Cairo, Egypt, v. 2013, p. 1-12, 2013.
- CORNE, S. A. et al. Predicting forest attributes in southeast Alaska using artificial neural networks. **Forest Science**, Praha 2, Czech Republic, v. 50, n. 2, p. 259-276, 2004.
- COUTO, H. T. Z.; BASTOS, N. L. M. Erros de medição de altura em povoamentos de *Eucalyptus* em região plana. **IPEF**, Piracicaba, SP, n. 39, p. 21-31, 1988.
- DIAMANTOPOULOU, M. Artificial neural networks as an alternative tool in pine bark volume estimation. **Computers and Electronics in Agriculture** v. 48, n. 3, p. 235-244, 2005a.
- DIAMANTOPOULOU, M. Total tree volume estimation using Artificial Neural Network models. In: Congress "increasing work efficiency in agriculture, horticulture and forestry, 5., 2005b, Germany. **Annals...Germany: CIOSTA-CIGR**, 2005b. p. 140-147.
- DIAMANTOPOULOU, M. Tree-bole volume estimation on standing pine trees using cascade correlation artificial neural network models. Agricultural Engineering International: **The CIGR Ejournal**. Manuscript IT 06 002, v.8, p.1-13, 2006.
- FAO. **Forests and energy.** Forestry paper n.154, Rome, 2008.
- FAVAN, J. R. **Utilização de redes neurais artificiais aplicadas na discriminação de padrões de doenças florestais.** 2015. 69 f Dissertação (Mestrado em Ciências Florestais) - Faculdade de Ciências Agrônômicas da UNESP, Campus de Botucatu, 2015.
- FERRANTI, F. **Energy wood: A challenge for European forests Potentials, environmental implications, policy integration and related conflicts.** European Forest Institute, EFI Technical Report 95, 2014.

FONTENELE, N. M. **Comparação entre a produtividade de *Eucalyptus* no sistema de alto fuste e talhadia no polo Gesseiro do Araripe – Pe.** 2016. 51 f. Dissertação (Mestrado em Ciências florestais) - Universidade Federal Rural de Pernambuco, 2016.

FUPEF. **Apoio técnico e institucional para o desenvolvimento do programa florestal da Chapada do Araripe em Pernambuco.** Curitiba: FUPEF, 2007.

GADELHA, F. H. L. **Rendimento volumétrico e energético de clones de híbridos de *Eucalyptus uruphylla* (cruzamento natural) e *Eucalyptus brassiana* (cruzamento natural) na Chapada do Araripe – PE.** 2010. 65 f. Dissertação (Mestrado em Ciências Florestais) - Universidade Federal Rural de Pernambuco, 2010.

GADELHA, F. H. I. et al. Produtividade de clones de eucaliptos em diferentes sistemas de manejo para fins energéticos. **Pesquisa Florestal Brasileira**, Colombo, v. 35, n. 83, p. 263-270, 2015.

GATZIOLIS, D.; FRIED, J. S.; MONLEON, V. S. Challenges to estimating tree height via lidar in closed-canopy forests: a parable from Western Oregon. **Forest Science**, Praha 2, Czech Republic, v. 56, n. 2, p. 139 -155, 2010.

GORGENS, E. B et al. Estimação do volume de árvores utilizando redes neurais artificiais. **Revista Árvore**, Viçosa-MG, v.33, n.6, p.1141-1147, 2009.

GOULART, M. et al. Massa específica básica e massa seca de madeira de *Eucalyptus grandis* sob o efeito do espaçamento de plantio e da posição axial no tronco. **Ciência Florestal**, Santa Maria, v. 13, n. 2, p. 167-175, 2003.

HAJEK, M. **Neural Networks**. University of KwaZulu-Natal, 2005. 114 p.

HAYKIN, S. **Redes Neurais: Principio e Prática**. 2. ed. Porto Alegre: Bookman, 2001. 900 p.

HIGGINS, J. **A neural network growth and yield model**. 2011. 108 f. Thesis (degree of Master of Applied Science) - University Halifax, Nova Scotia, 2011.

HUAT, O. K.; TSAI, L. M.; CHUBO, J. K. Juvenile stem volume equations for planted *Azadirachta excelsa* in the state of johore, Peninsular Malaysia. **Pertanika Journal of Tropical Agricultural Science**, Selangor, Malaysia v.32, n. 2, p. 133-141, 2009.

HUSCH, B.; BEERS, T. W.; KERSHAW JR., J. A. **Forest mensuration**. 4.ed. New Jersey: John Wiley & Sons, 2003. 443p.

HUSCH, B.; MILLER, C.I. BEERS, T.W. **Forest mensuration**. 2. ed. New York, Ronald Press, 1972. 410 p.

KHANNA, T. **Foundations of neural networks**. Menlo Park: Addison-Wesley, 1990. 196 p.

KONG, L. et al. Stand volume equation developed from an experimental form factor with the breast height form quotient. **Taiwan Journal of Forest Science**, Tehran, Iran, v. 27, n. 4, p. 357-367, 2012.

KRIESEL, D. **A Brief Introduction to Neural Networks**. 2005. 226 p.
Disponível em: <http://www.dkriesel.com>.

LARJAVAARA, M.; MULLER-LANDAU, H. C. Measuring tree height: a quantitative comparison of two common field methods in a moist tropical forest. **Methods in Ecology and Evolution**, London, v. 4, p. 793–801, 2013.

LIMA FILHO, L. M. A.; SILVA, J. A. A.; CORDEIRO, G. M.; FERREIRA, R. L. C. Modelagem do crescimento de clones de *Eucalyptus* usando o modelo de Chapman-Richards com diferentes distribuições simétricas dos erros. **Ciência Florestal**, Santa Maria, v. 22, n. 4, p. 777 - 785, 2012.

LIU, C. et al. Comparison of neural networks and statistical methods in classification of ecological habitats using FIA data. **Forest Science**, Praha 2, Czech Republic, v. 49, n. 4, p. 619-631, 2003.

LYNCH, T. B. Use of a tree volume equation based on two lower-stem diameters to estimate forest volume from sample tree counts. **Canadian Journal of Forest Research**, Vancouver, Canada, v. 25, n. 6, p. 871-877, 1995.

MACHADO, S. A. et al. Comparação de métodos de cubagem absolutos com o volume obtido pelo xilômetro para bracatinga (*Mimosa scabrella* Bentham). **Cerne**, Lavras, v. 12, n. 3, p. 239-253, 2006.

MCCOMBS, J. W.; ROBERTS, S. D.; EVANS, D. L. Influence of fusing Lidar and multispectral imagery on remotely sensed estimates of stand density and mean tree height in a managed Loblolly Pine plantation. **Forest Science**, Praha 2, Czech Republic, v. 49, n. 3, p. 457-4 466, 2003.

MIGUEL, E. P. et al. Artificial intelligence tools in predicting the volume of trees within a forest stand. **African Journal of Agricultural Research**, Nigeria, v. 11, n. 21, p. 1914-1923, 2016.

MONTGOMERY, D. C. **Design and analysis of experiments**. 8 ed. United States: John Wiley & Sons, Inc, 2013. 69 p.

NICOLETTI, M. F. **Comparação de métodos não-destrutivos de cubagem de árvores em pé visando à determinação da biomassa**. 2011. 83 f.
Dissertação (Mestrado em Ciências Florestais) - Universidade de São Paulo: Escola Superior de Agricultura “Luiz de Queiroz”, Piracicaba, 2011.

- OLIVEIRA, M. L. R. et al. Estimação do volume de árvores de clones de Eucalipto pelo método da similaridade de perfis. **Revista árvore**, Viçosa, MG, v.33, n.1, p.133-141, 2009.
- OUNEKHAM, K. **Developing volume and taper equations For *Styrax tonkinensis* in Laos**. 2009. 77 f. Thesis (Degree of Master of Forestry Science) - University of Canterbury, New Zealand, 2009.
- ÖZCELİK, R. et al. Estimating tree bole volume using artificial neural network models for four species in Turkey. **Journal of Environmental Management**, London, England, v. 91, n. 3, p. 742-753, 2010.
- ÖZKAN, C.; ERBEK, F. S. The comparison of activation functions for multispectral landsat tm image classification. **Photogrammetric Engineering & Remote Sensing**, Maryland, EUA, v. 69, n. 11, p. 1225–1234, 2003.
- PACHECO, J. M. et al. Effect of spacing on the form factor of *Pinus taeda* L. **Australian Journal of Basic and Applied Sciences**, Jordan v. 9, n. 23, p. 222-226, 2015.
- PELLI, E. **Comparação dos algoritmos máquina de aprendizagem extrema e retropropagação do erro para estimação de altura e volume de árvores**. 2013. 58 f. Dissertação (Mestrado em Ciências Florestais) – Universidade Federal dos Vales do Jequitinhonha e Mucuri, 2013.
- PENG, C.; WEN, X. **Recent Applications of Artificial Neural Networks in Forest Resource Management: An Overview**. In Corté, U. and Sánchez-Marrè, M. (Eds.), *Environmental Decision Support Systems And Artificial Intelligence*, Technical Report WS-99-07. Menlo Park, CA: AAAI, p. 15-22, 1999.
- PHILIP, M. **Measuring trees and forest**. 2 e.d. CAB International: Wallingford, 1994. 336 p.
- PRINCIPE, J. C.; EULIANO, N. R.; LEFEBVRE, W. C. **Neural and adaptive systems: fundamentals through simulations**. 1. ed., New York: John Wiley & Sons, 1999. 656 p.
- R Development Core Team: **A language and environment for statistical computing**. R Foundation for Statistical Computing, Vienna, Australia, 2016.
- RAMOS, M. **Comparação de métodos para estimar o volume comercial em floresta ombrófila densa no Estado do Amazonas**. 2012. 49 f. Dissertação (Mestrado em Ciências florestais) - Universidade Estadual do Centro-Oeste, 2012.
- RIBEIRO, R. B. S; GAMA, J. R.V; MELO, L. O. Seccionamento para a cubagem e escolha de equações de volume para a floresta nacional do Tapajós. **Revista Cerne**, Lavras, v.20, n. 4, p, 605-612, 2014.

ROCHA, K. D. **Produtividade volumétrica de clones de *Eucalyptus* spp. na região do polo Gesseiro do Araripe**. 2012. 92 f. Dissertação (Mestrado em Ciências Florestais) - Universidade Federal Rural de Pernambuco, 2012.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. **Learning internal representations by error propagation**. In: Rumelhart, D. E.; McClelland, J.L., PDP Research Group (Eds.), *Parallel Distributed Processing*. Foundations, v. 1. MIT Press, 1986, p. 318-362.

SAFI, Y.; BOUROUMI, A. Prediction of forest fires using artificial neural networks. **Applied Mathematical Sciences**, University of Tuscia, Italy, v. 7, n. 6, p. 271-286, 2013.

SANDO, T. et al. Advantages and disadvantages of different crash modeling techniques. **Journal of Safety Research**, USA, v. 36, n. 5, p. 485-487, 2005.

SANQUETTA, C. A et al. Modelling crown volume in *Acacia mearnsii* stands. **African Journal of Agricultural Research**, Nairobi, Kenya, v. 10, n. 28, p. 2756-2762, 2015a.

SANQUETTA, M. N. I. et al. Contribuição de um segundo diâmetro na estimação de volume individual de plantios jovens de *Tectona grandis* L.f. **Revista Agro@ambiente On-line**, Boa Vista, Roraima, v. 9, n. 4, p. 446-454, 2015b.

SANQUETTA, M. N. I. et al. Incremento diamétrico e percentuais de cerne e de casca em povoamentos de *Tectona grandis* L.f. no sudeste do Pará. **Enciclopédia Biosfera**, Goiânia-GO, v. 10, n. 18, p. 1946-1954, 2014.

SCHNEIDER, P. R. **Introdução ao manejo florestal**. Santa Maria: CEPEF/FATEC/UFSM, 1993. 348 p.

SCHRÖDER et al. Métodos de estimativa de volume comercial para *Eucalyptus grandis*: especificidades e recomendações. **Pesquisa Florestal Brasileira**, Colombo, v. 33, n. 73, p. 01-07, 2013.

SCOLFORO, J. R. S. et al. Acuracidade de equações de afilamento para representar o perfil de *Pinus elliottii*. **Revista Cerne**, Lavras, v. 4, n.1, p. 100-122, 1998.

SHAO, G.; REYNOLDS, K. M. Computer applications in sustainable forest management: Including perspectives on collaboration and integration. **Springer**, v. 11, n. 1, p. 143-169, 2006.

SHATER, Z. et al. A growth and yield model for even-aged *Pinus brutia* Ten. stands in Syria. **Annals of Forest Science**, Institut National de la Recherche Agronomique (INRA), v. 68, n. 1, p. 149-157, 2011.

SILVA, J. A. A. Potencialidades de florestas energéticas de *Eucalyptus* no Pólo Gesseiro do Araripe – Pernambuco. Recife, **Anais da Academia Pernambucana de Ciência Agrônômica**, Recife, vols. 5 e 6, p.301-319, 2008-2009.

SILVA, J.A.A.; BORDERS, B.E. A tree volume equation based on two lower, stem diameters for Loblolly Pine in the Southeastern United States. **Southern Journal of Applied Forestry**, Washington, US, v.17, n.4, p. 160-162, 1993.

SILVA, M. L. M. et al. Ajuste do modelo de Schumacher e Hall e aplicação de redes neurais artificiais para estimar volume de árvores de eucalipto. **Revista Árvore**, Viçosa-MG, v. 33, n. 6, p. 1133-1139, 2009.

SILVA, P. V. **Emprego de redes neurais artificiais com skip-layer connections na mensuração florestal**. 2015. 56 f. Dissertação (Mestrado em Ciências Florestais) - Universidade Federal dos Vales do Jequitinhonha e Mucuri, Diamantina – MG, 2015.

SOARES, F. A. A. M. N. 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**, London, Englan, v. 12, n. 8, p. 2030-2039, 2012.

SOARES, F. A. A. M. N. **Predição recursiva de diâmetros de clones de Eucalipto utilizando rede perceptron de múltiplas camadas para o cálculo de volume**. 2012. 93 f. Tese (Doutorado em Engenharia Elétrica) - Universidade Federal de Uberlândia, Faculdade de Engenharia Elétrica, 2012.

SOARES, P. L. B; SILVA, J. P. Aplicação de redes neurais artificiais em conjunto com o método vetorial da propagação de feixes na análise de um acoplador direcional baseado em fibra ótica. **Revista Brasileira de Computação Aplicada**, Passo Fundo, v.3, n.2, p.58-72, 2011.

SOCHA, J.; KULEJ, J. M. Provenance-dependent variability of *Abies grandis* stem form under mountain conditions of Beskid Sadecki (southern Poland). **Canadian Journal of Forest Research**, Canada, v. 35, n. 11, p. 1-14, 2005.

TEWARI, V. P.; KUMAR V. S. K. Volume equations and their validation for irrigated plantations of *Eucalyptus camaldulensis* in the hot desert of India. **Journal of Tropical Forest Science**, Malaysia, v. 15, n. 1, p. 136-146, 2003.

THIERSCH, C. R. et al. Acurácia dos métodos para a estimativa do volume comercial de clones de *Eucalyptus* sp. **Cerne**, Lavras, v. 12, n. 2, p. 167-181, 2006.

THIERSCH, C. R. **Modelagem da densidade básica, do volume e do peso seco para plantios de clones de Eucalyptus spp**. 2002. 197 f. Dissertação (Mestrado em Engenharia Florestal) - Universidade Federal de Lavras, 2002.

TU, J. V. Advantages and Disadvantages of Using Artificial Neural Networks versus Logistic Regression for Predicting Medical Outcomes. **Journal of Clinical Epidemiology**, Amsterdam, The Netherlands v. 49, n 11, p. 1225-1231, 1996.

VALENÇA, M. **Fundamentos das redes neurais**. 2. ed. Rev - ampl. Olinda, PE: Livro rápido, 2010. 386 p.

VALENÇA, M. **Aplicando redes neurais: Um guia completo**. 1. ed. Ver - ampl. Olinda, PE: Livro, 2005. 284 p.

WANG, Y; XIONG, Z. Prediction of the forest health based on BP neural networks. **Advanced Materials Research**, Pfaffikon, Switzerland, v. 726-731, p. 4303-4306, 2013.

WEST, P. W. **Tree and forest measurement**. 2nd edition. Springer-Verlag Berlin Heidelberg, 2009. 191 p.


WINCK, R. A. et al. Modelos predictivos de biomasa aérea de *Eucalyptus grandis* para el noreste de Argentina. **Ciência Florestal**, Santa Maria – RS, v. 25, n. 3, p. 595-606, 2015.

WU, S. Estimation of forest volume based on LM - BP neural network model. **Computer Modelling & New Technologies**, Latvia, v. 18, n. 4, p. 131-137, 2014.


ZHANG Q. B. et al. Estimating Tree Height-Diameter Models with the Bayesian Method. **The Scientific World Journal**, United States, v. 2014, p. 1-9, 2014.

APÊNDICES


Apêndice 1- Resultados da medida de quanto o valor predito pela rede neural artificial muda para os diferentes valores da variável independente para todas as árvores.



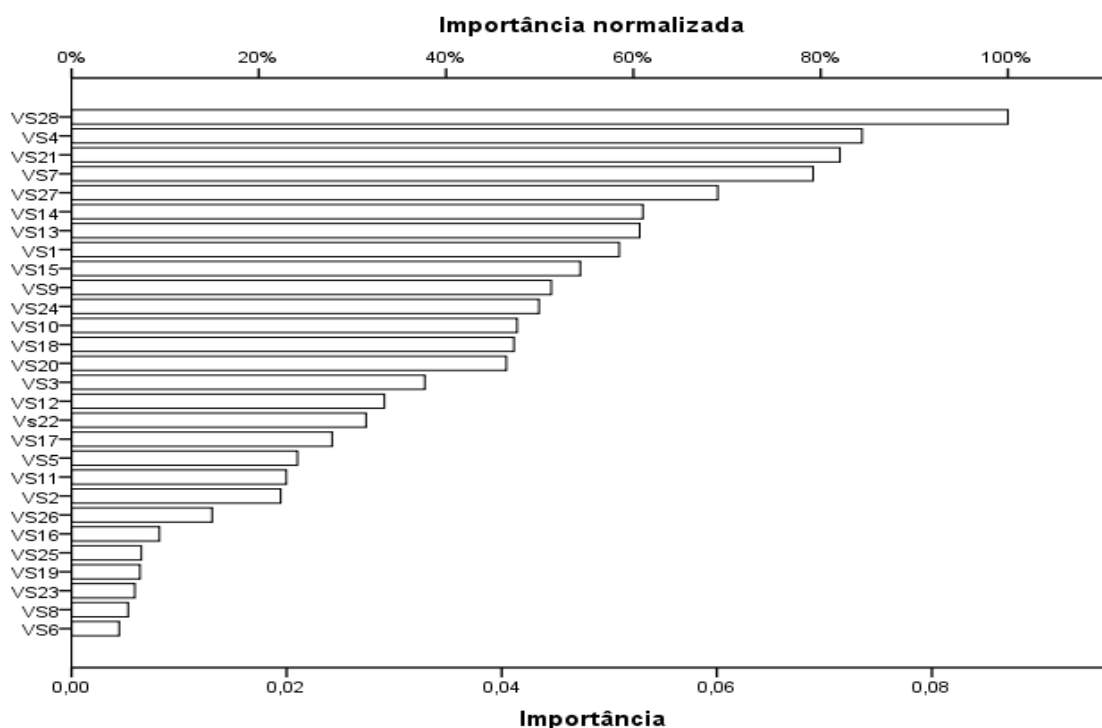
Apêndice 2- Resultados da medida de quanto o valor predito pela rede neural artificial muda para os diferentes valores da variável independente para o clone *Eucalyptus urophylla*.




Apêndice 3- Resultados da medida de quanto o valor predito pela rede neural artificial muda para os diferentes valores da variável independente para o clone *Eucalyptus brassiana*.



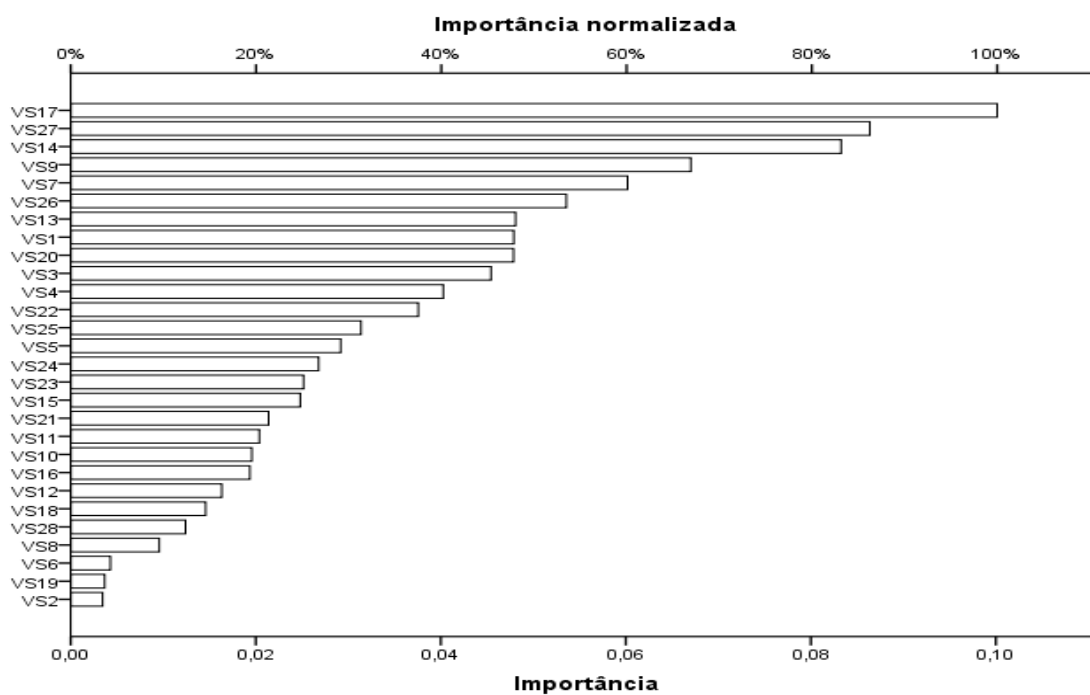
Apêndice 4- Resultados da medida de quanto o valor predito pela rede neural artificial muda para os diferentes valores da variável independente para o clone *Eucalyptus urophylla x Eucalyptus tereticornis*.




Apêndice 5- Resultados da medida de quanto o valor predito pela rede neural artificial muda para os diferentes valores da variável independente para o clone *Eucalyptus tereticornis*.



Apêndice 6- Resultados da medida de quanto o valor predito pela rede neural artificial muda para os diferentes valores da variável independente para o grupo A.



Apêndice 7- Resultados da medida de quanto o valor predito pela rede neural artificial muda para os diferentes valores da variável independente para o grupo B.



Apêndice 8- Resultados da medida de quanto o valor predito pela rede neural artificial muda para os diferentes valores da variável independente para o grupo C.

