

**UNIVERSIDADE FEDERAL DOS VALES DO  
JEQUITINHONHA E MUCURI – UFVJM**

**Kaio Cesar Mendes da Silva Nery**

**REDUÇÃO DO NÚMERO DE PARCELAS PARA MODELAGEM DA PROGNOSE  
DO VOLUME DE FLORESTA**

**DIAMANTINA/MG**

**2016**

**Kaio Cesar Mendes da Silva Nery**

**REDUÇÃO DO NÚMERO DE PARCELAS PARA MODELAGEM DA PROGNÓSE  
DO VOLUME DE FLORESTA**

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

**Orientador: Profº Drº Sidney Araújo Cordeiro**

**DIAMANTINA/MG**

**2016**

Ficha Catalográfica – Serviço de Bibliotecas/UFVJM  
Bibliotecário Anderson César de Oliveira Silva, CRB6 – 2618.

N456r	<p>Nery, Kaio Cesar Mendes da Silva Redução do número de parcelas para modelagem da prognose do volume de floresta / Kaio Cesar Mendes da Silva Nery. – Diamantina, 2016. 41 p. : il.</p> <p>Orientador: Sidney Araujo Cordeiro Coorientador: Mayra Luiza Marques da Silva</p> <p>Dissertação (Mestrado – Programa de Pós-Graduação em Ciência Florestal) - Universidade Federal dos Vales do Jequitinhonha e Mucuri.</p> <p>1. Redes Neurais Artificiais. 2. Inteligência Artificial. 3. Inventário Florestal. I. Título II. Universidade Federal dos Vales do Jequitinhonha e Mucuri.</p> <p style="text-align: right;"><b>CDD 634.9</b></p>
-------	--

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

**REDUÇÃO DO NÚMERO DE PARCELAS PARA MODELAGEM DA PROGNOSE  
DO VOLUME DE FLORESTA**

**Kaio Cesar Mendes da Silva Nery**

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

APROVADO EM 11 / 03 / 2016

---

Prof. Dr. Marcio Leles Romarco de Oliveira- UFVJM

---

Prof. Dr<sup>a</sup>. Mayra Luiza Marques da Silva - UFES

Coorientadora

---

Prof. Dr. Sidney Araújo Cordeiro - UFVJM

Orientador

**DIAMANTINA/MG**

**2016**

## **AGRADECIMENTOS**

Agradeço a Deus, por ter me permitido chegar até aqui. Serei eternamente grato aos meus pais, em especial a minha mãe por sempre ter incentivado meus estudos e ter me apoiado em cada decisão que eu tomei.

A Universidade Federal dos Vales do Jequitinhonha e Mucuri (UFVJM) pela bolsa cedida ao longo do período que permaneci em Diamantina e ao Departamento de Engenharia Florestal, pela ajuda e suporte.

A professora e coorientadora Mayra Luiza Marques da Silva pelo apoio neste trabalho e pelos socorros nos momentos de desespero.

Ao Daniel Henrique Breda Binoti, por ter se colocado à disposição em me ajudar durante todo o trabalho.

Ao meu orientador Sidney, pelos seus ensinamentos, sua paciência, orientação e confiança depositada em mim. Meu muito obrigado!

Àqueles que me acolheram como parte da turma no momento que iniciei meus estudos no PPGCF, Lídia, Emília, Gabi e a Laís. Em especial a Paula, pelos seus conselhos e ajuda, ao Marcelino e Ludmila pelas saídas e conversas divertidas e a Karyn que é uma amiga de longa data com quem dividi e divido momentos felizes e tristes.

Minha gratidão e meu muito obrigado a todos.

## SUMÁRIO

<b>1. INTRODUÇÃO .....</b>	<b>10</b>
<b>2. REVISÃO DE LITERATURA .....</b>	<b>12</b>
2.1    Prognose e modelagem da produção florestal .....	12
2.2    Redes Neurais Artificiais (RNAs) .....	17
<b>3. MATERIAL E MÉTODOS.....</b>	<b>20</b>
3.1    Descrição dos dados.....	20
3.2    Modelagem e crescimento da produção.....	21
3.3    Redes neurais artificiais (RNA).....	22
3.3.1. Estudo 1 e 2.....	22
3.3.2. Treinamento e generalização das redes neurais artificiais .....	23
3.3.3. Prognose da produção florestal .....	23
3.3.4. Avaliação das estimativas geradas pelas redes neurais artificiais.....	23
<b>4. ANÁLISE DE CUSTO.....</b>	<b>24</b>
<b>5. RESULTADOS E DISCUSSÃO .....</b>	<b>25</b>
5.1    Modelo de Clutter .....	25
5.2    Estudo 1 .....	27
5.3    Estudo 2 .....	33
<b>6. CONCLUSÕES .....</b>	<b>37</b>
<b>7. REFERÊNCIAS BIBLIOGRÁFICAS .....</b>	<b>38</b>

## LISTA DE TABELAS

<b>Tabela 1:</b> Estudo 1: Quantidade de parcelas correspondente as percentagens em cada classe de site.....	22
<b>Tabela 2:</b> Estudo 2: Quantidade de parcelas escolhidas em cada classe de site.....	22
<b>Tabela 3:</b> Valor gasto para mensurar as 658 parcelas.....	24
<b>Tabela 4:</b> Raiz quadrada do erro quadrado médio (RMSE) e correlação entre os valores dos volumes observados e estimados.....	27
<b>Tabela 5:</b> Valor gasto na remedição utilizando a metodologia do estudo 1. ....	32
<b>Tabela 6 -</b> Raiz quadrada do erro quadrado médio (RMSE) e correlação entre os valores dos volumes observados e estimados.....	33
<b>Tabela 7.</b> Total gasto na remedição, utilizando o estudo 2.....	36

## LISTA DE FIGURAS

<b>Figura 1.</b> Representação de um neurônio artificial (Fonte: HAYKIN,2001.) .....	18
<b>Figura 2.</b> Principais Funções de Ativação nas RNAs. (Fonte: CASTRO, 2011) .....	19
<b>Figura 4.</b> Histograma dos erros obtidos pelas estimativas geradas através dos modelos de Clutter (1963). .....	25
<b>Figura 3.</b> Gráfico de resíduos das estimativas geradas através do modelo de Clutter (1963). .....	25
<b>Figura 5.</b> Projeção volumétrica do modelo de Clutter (1963). .....	26
<b>Figura 6.</b> Volume observados e estimados através do modelo de Clutter (1963). .....	26
<b>Figura 7.</b> Distribuição dos resíduos percentuais dos volumes totais estimados pelas redes neurais artificiais (eixo y) em função dos valores observados (eixo x) no treinamento e validação, para o Estudo1. ....	29
<b>Figura 8 -</b> Gráfico de histogramas da frequência dos erros percentuais obtidos pelas estimativas geradas através do treinamento e validação efetuado pela RNA para a Estudo 1. ....	31
<b>Figura 9:</b> Distribuição dos resíduos percentuais dos volumes totais estimados pelas redes neurais artificiais (eixo y) em função dos valores observados (eixo x) no treinamento e validação 10 (A), 20 (B), 30 (C), 40 (D), 50 (E) e 60 (F) parcelas respectivamente em cada classe de sítio, para o Estudo 2. ....	34
<b>Figura 10:</b> Gráfico de resíduos e histogramas de frequência dos erros percentuais obtidos pelas estimativas geradas através do treinamento e validação efetuada pela RNA para o Estudo 2. ....	35



## RESUMO

NERY, Kaio Cesar Mendes da Silva. **Redução do número de parcelas para modelagem da prognose do volume de florestas**, 2016.42p. (Dissertação- M. Sc. Em Ciência Florestal) – Universidade Federal dos Vales do Jequitinhonha e Mucuri, Diamantina, 2016.

O objetivo deste estudo foi avaliar o efeito da redução de parcelas permanentes no custo da realização do inventário florestal contínuo e realizar a prognose do volume de floresta comparando o emprego das Redes Neurais Artificiais ao modelo tradicionalmente utilizado proposto por Clutter (1963). Os dados utilizados foram provenientes de povoamentos localizados no litoral norte da Bahia, totalizando cerca de 3.000 hectares de floresta. Foram propostas duas metodologias para auxiliar na redução das parcelas. Para a metodologia proposta no estudo 1, os dados foram divididos aleatoriamente em dois grupos: treinamento (10, 20, 30, 40, 50, 60, 70, 80, e 90%) e generalização (90, 80, 70, 60, 50, 40, 30, 20, 10%). Os dados do treinamento foram utilizados para gerar as redes neurais artificiais enquanto que os dados da generalização serviram para validar a capacidade das redes em gerar resultados precisos para dados desconhecidos. A metodologia proposta no estudo 2 dividiu aleatoriamente os dados em dois grupos: treinamento a escolha fixa de quantidades de parcelas pré-estabelecidas nas três classes de sítio (10, 20, 30, 40, 50 e 60) totalizando 30, 60, 90, 120, 150 e 180 parcelas utilizadas para o treino das redes neurais e os demais dados foram utilizados para validar a capacidade das redes. A estimativa da variável de estudo foi gerada no sistema computacional *Neuroforest* 3.3. A aplicação das Redes Neurais Artificiais apresentaram resultados satisfatórios bem como a aplicação de ambas metodologias permitiram reduzir consideravelmente o custo para a realização do inventário florestal.

**Palavras-chave:** Redes Neurais Artificiais; Inteligência Artificial; Inventário Florestal.

## ABSTRACT

NERY, Kaio Cesar Mendes da Silva. **Redcution the plots number for modeling the prognosis of size forest**, 2016.42p. (Dissertation- M.Sc. in Forest Sciences) – Universidade Federal dos Vales do Jequitinhonha e Mucuri, Diamantina, 2016.

This study aimed to evaluate the effects of permanent plots in the cost of carrying out the continuous forest inventory and to perform prognosis of forest production comparing the use of Artificial Neural Networks to the traditional model proposed by Clutter (1963). Data were obtained from municipalities located in the northern region of Bahia state yielding 3,000 hectares of forest. Two different methodologies were proposed to reduce the number of parcels. The methodology proposed for the study 1 involved the random division of the data into two groups consisting of random reducing portions of 10, 20, 30, 40, 50, 60, 70, 80, and 90% with these percentages used for training and the remaining 90, 80, 70, 60, 50, 40, 30, 20, 10% used for validation. The methodology proposed for study 2 consisted of random reduction in parcels with a fixed parcel per site 10, 20, 30, 40, 50 and 60 in each class (30, 60, 90, 120, 150 and 180 parcels). The estimates of the study variables were generated in the computer system *Neuroforest 3.3*. The applications of Artificial Neural Networks showed satisfactory results and the application of both methodologies have considerably reduced the cost for conducting the forest inventory.

**Key-words:** Artificial Neural Networks; prognosis; forest inventory.

## 1. INTRODUÇÃO

O Brasil é um dos países com maior biodiversidade de áreas florestais do mundo, possuindo, aproximadamente, 60% do território nacional coberto por florestas (SAE, 2014). De acordo com dados do IBÁ (2015), as florestas plantadas são responsáveis 91% de toda a madeira produzida para fins industriais no País – sendo que os 9% vêm de florestas nativas legalmente manejadas.

Árvores dos gêneros *Eucalyptus* e *Pinus* destacam-se no Brasil por possuírem rápido crescimento e aplicações diversificadas, trazendo contribuições significativas ao produto interno bruto (PIB) do país (OLIVEIRA, 2012; SALLES, *et. al.*, 2012). A madeira do eucalipto pode ser utilizada para diversos fins, como, por exemplo, para a produção do carvão vegetal. Quando oriunda de plantios florestais, essa produção apresenta um custo superior ao proveniente de mata primária, sendo as siderúrgicas integradas as maiores consumidoras, uma vez que com a produção verticalizada elas podem suportar preços de insumos mais altos, em especial os do carvão vegetal elaborado a partir de biomassa originada de reflorestamentos (MONTEIRO, 2006).

A maior parte da madeira de eucalipto utilizada na carbonização é cortada em plantios com seis ou sete anos, idade determinada de acordo com aspectos econômicos (VIEIRA, 2013). Para que a exploração do recurso florestal madeireiro seja feita de forma eficiente, é necessário conhecer o estoque de crescimento e de colheita por meio da medição e estimativa de características das árvores e da área na qual elas estão plantadas.

A estimativa de estoques de crescimento e de colheita é um importante elemento no manejo florestal, uma vez que fornece informações quantitativas sobre a floresta, auxiliando na definição do plano de manejo e em análises econômicas que irão servir de base para as prescrições do manejo (BINOTI, 2012). Outro elemento importante é o conhecimento a longo prazo dos investimentos econômicos, o que permite analisar a viabilidade econômica para a implementação do projeto.

Desse modo, podendo prognosticar o desenvolvimento da floresta, será possível definir economicamente a área que irá suprir a demanda madeireira de uma determinada região.

Alguns métodos são utilizados para quantificar o volume de madeira atual e futuro em povoamentos florestais, dentre estes, o emprego da análise de regressão com variáveis como diâmetro, altura e idade das árvores, considerando características do plantio como

espaçamento, espécie ou clone e capacidade produtiva para fins de estratificação (CAMPOS;LEITE 2013).

Como alternativa aos modelos tradicionais de regressão, as Redes Neurais Artificiais (RNA) tem sido amplamente utilizadas no setor florestal podendo citar como exemplo a modelagem do afileamento do fuste de árvores (LEITE *et al.*, 2011); obtenção do volume de casca de pinus (DIAMANTOPOULOU, 2005); estimação do volume de árvores (DIAMANTPOULOU, 2005; GORGENS, 2006; SILVA *et a.l.*, 2009; DIAMANTOPOULOU; MILIOS, 2010; LEITE *et al.*, 2010; SILVA, 2010); modelagem em nível de povoamentos, modelagem por classe diamétrica e estimação da altura (BINOTI, 2010; BINOTI, 2012), estimação de biomassa e de carbono (FERRAZ, 2012), dentre outros, apresentando resultados satisfatórios e promissores.

Em mensuração florestal, as Redes Neurais Artificiais (RNA) têm sido usadas como uma alternativa para reduzir tempo e custo da realização de inventários florestais podendo citar como exemplo um estudo desenvolvido por Binoti (2012) onde foi possível realizar a redução do número de medições de altura das árvores dentro das parcelas sem que houvesse perda de precisão e exatidão. Dessa forma, a avaliação da viabilidade econômica da utilização das RNA torna-se de suma importância, tanto para orientar os potenciais usuários, quanto para subsidiar os tomadores de decisão na escolha entre soluções alternativas que fazem referência a produção ou implantações de novas abordagens.

O objetivo deste estudo foi avaliar o efeito da redução de parcelas permanentes no custo da realização do inventário florestal contínuo e realizar a prognose do volume de floresta comparando o emprego das Redes Neurais Artificiais ao modelo tradicionalmente utilizado proposto por Clutter (1963).

## 2. REVISÃO DE LITERATURA

### 2.1 Prognose e modelagem da produção florestal

Com o surgimento do manejo das florestas veio o desejo de influenciar e poder prognosticar o crescimento com a finalidade de dominar a produção da matéria-prima madeira. Esse desejo baseou-se nas circunstâncias especiais da produção florestal destacando-se os longos prazos e ao fato de que as decisões e intervenções dificilmente poderiam ser desfeitas (SPATHELF; NUTTO 2000).

De acordo com Santos *et. al.*, (2006), as florestas clonais de eucalipto proporcionam maior uniformidade da matéria-prima florestal, se adaptam bem aos diferentes ambientes de plantio, produz uma maior quantidade de madeira por unidade de área, permitem uma racionalização das atividades operacionais e a idade de corte pode ser reduzida. Diante desse contexto, o uso adequado de práticas de manejo é fundamental para o planejamento correto do empreendimento florestal.

Os três elementos principais que compõe o manejo de florestas equiâneas são: a classificação das terras; prescrições envolvendo rotação regulatória, regime de corte e tratamentos silviculturais; e prognose do crescimento e da produção florestal (CAMPOS; LEITE, 2013).

O manejo florestal envolve diversas variáveis, dentre as quais se destacam as biológicas, que envolvem o potencial produtivo de uma espécie florestal ou clone em um determinado tipo de solo ou topografia, as econômicas, como o preço da madeira, o custo e impostos que incidem sobre a produção e as sociais, que tem como exemplo as leis que refletem na mão-de-obra empregada nas fases do processo produtivo (BOUNGIORNO; GUILLES, 2003; DAVIS *et. al.*, 2005; BETTINGER, *et. al.*, 2009).

O crescimento dos indivíduos em um povoamento florestal está ligado ao fator tempo e às condições ambientais do local. Quando as condições ambientais são favoráveis ao desenvolvimento dos indivíduos, estes expressam a sua máxima capacidade de crescimento (ENCINAS *et. al.*, 2005). Assim, o manejador deve estar atento a qualquer alteração na taxa de crescimento para interpretar melhor a prognose da produção.

De acordo com Binoti (2010), o termo prognose é utilizado como referência a predição, projeção ou qualquer outro procedimento que tenha por objetivo prever estoques de crescimento e, ou, de colheita em idades futuras. A predição está relacionada com o uso de uma função que inclui uma variável independente como a idade. Ao contrário da predição, a

projeção envolve funções onde a produção futura é relacionada com a produção atual, dentre outras variáveis (CAMPOS; LEITE, 2013).

O conhecimento da idade de um povoamento florestal, é extremamente importante, uma vez que a partir dela avalia-se o incremento em termos de volume, diâmetro ou altura de uma espécie em um determinado local. Também é necessário conhecer a idade quando se quer construir curvas de índice de sítio (SILVA; NETO, 1979).

Além da idade, os povoamentos florestais possuem outras importantes características mensuradas, como por exemplo, a altura total, o diâmetro a 1,30 m da base da árvore (*dap*) ou a circunferência (*cap*), utilizadas no cálculo do volume, da área basal ou do crescimento.

Silva *et. al.*, (1979) destaca quatro razões pelas quais o *dap* ou *cap* são tomados como as medidas mais importantes sob a árvore, sendo elas:

- O *dap* ou *cap* são mais acessíveis, mais fáceis de mensurar;
- Afetam o cálculo do volume quadraticamente, pois  $V = g \cdot h \cdot f$  onde: “h” é altura e “f” é o fator de forma.
- Por meio da distribuição diamétrica é possível determinar a frequência com que as árvores ocorrem no povoamento;
- Calcula-se a área basal de um povoamento pelo somatório das áreas transversais de todas as árvores  $G = (\sum g_i) \cdot f$  dependendo assim dos diâmetros das árvores.

Tendo o conhecimento da estrutura diamétrica, é possível avaliar o comportamento da espécie, levando em consideração vários fatores que possam interferir em seu crescimento, dentre eles, o manejo e as atividades de exploração comercial. A variável diâmetro é bem correlacionada com outras variáveis, tais como o volume, a qualidade de produção e os custos de exploração (BARTOSZECK *et. al.*, 2004).

Ao obter uma estimativa volumétrica por parcela, extrapola-se por hectare para ter conhecimento do volume total de um determinado povoamento. Para isto, além do conhecimento a respeito da idade e do *dap*, é necessário mensurar ou estimar a altura total (*Ht*) e altura comercial (*h*).

A altura total em povoamentos equiâneos é utilizada como *input* em equações de *taper* e de volume, já em inequiâneas, é mais comum empregar a altura comercial. Ao empregar equações de volume ou de *taper* é necessário a utilização de equações específicas

para poder estimar a altura das árvores, tomando com base em dados disponíveis e ajustadas a partir de modelos que são denominados de hipsométricos (CAMPOS; LEITE, 2013).

Scolforo (1998) fez uma discussão a respeito do crescimento e produção das variáveis dendrométricas que são de importante conhecimento na definição das estratégias de manejo de um povoamento (diâmetro, altura, altura dominante, área basal por hectare, volume por hectare), indicando quais fatores influenciam o comportamento de cada variável, exemplificando com dados de experimentos em plantios equiâneos. Segundo esse autor, pode-se inferir que os fatores de maior influência no crescimento das diversas variáveis dendrométricas são o material genético utilizado, a qualidade do sítio e a densidade do povoamento. Somado a estes fatores há ainda a idade do povoamento, a qual é a expressão do tempo e das mudanças acontecidas na floresta com o passar deste.

De acordo com Jones (1969), os métodos de avaliação da capacidade produtiva podem ser definidos em três categorias: avaliação da qualidade do lugar pela vegetação indicadora; avaliação por fatores climáticos, edáficos, fisiográficos e bióticos; e a avaliação por meio da relação altura dominante e idade, com a definição de índices de local.

Sabe-se que as práticas silviculturais como adubação realizada de maneira constante podem ocasionar mudanças na capacidade produtiva do local. Devido a isso, o método de índices de local pode ter resultados alterados, pois o uso de fertilizantes em florestas plantadas pode variar a classificação desses índices. Além disso, povoamentos florestais oriundos de brotação ou corte de talhadia podem apresentar crescimento um pouco diferenciado do original (LEITE, 2013).

O inventário florestal contínuo (IFC) é um dos métodos mais utilizados para acompanhar o crescimento da floresta, sendo imprescindível para um conhecimento do potencial de recursos florestais em uma determinada área, auxiliando assim na realização do manejo. Segundo Oliveira (2012), esta técnica permite mensurar um maior número de informações sobre a floresta executando assim um bom manejo de seus recursos, favorecendo na tomada de decisões para que se obtenha uma produção mais rentável.

Para que a tomada de decisão seja favorável, é necessário que as informações sejam verdadeiras e consistentes e, para isso, são empregados modelos de crescimento e produção (SILVA, 2001). De acordo com Santos (2008), estes modelos são conjuntos de relações matemáticas que fornecem uma descrição quantitativa da dinâmica de um povoamento sendo classificados em: modelos em nível de povoamento, modelos de distribuição diamétrica e modelos de árvores individuais.

A escolha de um modelo que retrate o crescimento e produção de uma floresta depende do nível de detalhamento das respostas desejadas e das práticas de manejo a serem avaliadas. Normalmente a modelagem do crescimento e da produção é utilizada para prever e projetar quatro objetivos: 1) o crescimento e a produção do povoamento auxiliando o tomador de decisão no plano de manejo; 2) o crescimento em um local específico para que sejam feitas análises de opções de investimento; 3) o crescimento de povoamentos sobre diferentes regimes de manejo e práticas silviculturais, por exemplo, para escolher o melhor espaçamento de plantio, rotação e intensidade de desbaste; 4) a produção e agregá-la a um fluxo de custos e receitas para análises econômicas (PHILIP, 1994).

A aplicação dos modelos deve ocorrer a partir da sua forma tabular ou gráfica. Com a evolução computacional surgiram duas formas de aplicação sendo elas por *simulação* e por *otimização*. A primeira emprega um *software* que gera tabelas ou gráficos para cada povoamento em particular. A segunda exige o emprego de um programa específico que auxilie no planejamento florestal, proporcionando resultados para diferentes restrições silviculturais, da colheita e econômica. A otimização tem por objetivo maximizar ou minimizar uma função por meio de uma combinação de níveis de atividades (CAMPOS; LEITE, 2013).

O principal objetivo dos modelos de crescimento e produção é regular uma floresta para que seu volume e tamanho, em todas as classes de idades, sejam iguais, podendo assim suprir a demanda do mercado por um longo período de tempo.

Segundo Leuschner (1984), uma floresta é considerada regulada quando os volumes ou tamanhos (áreas) explorados permaneçam os mesmos periodicamente, possibilitando o suprimento da demanda de produtos no mercado em um determinado período de tempo.

Regular uma floresta significa definir e aplicar prescrições de manejo visando obter uma estrutura de classes de idade, que após um período de transição, ou horizonte de planejamento (HP), resulte em uma produção sustentável. Nessa estrutura regulada, após o período HP, os compartimentos terão idades que variam entre 1 e R anos, sendo R a rotação regulatória, ou seja, o período em que a floresta irá sofrer mudança (CAMPOS; LEITE, 2013).

Os modelos são considerados como abstração do sistema real e influenciam nas mudanças ocorridas na estrutura e na produtividade dos povoamentos, permitem a atualização de dados passados e auxiliam na projeção dos povoamentos no futuro (ABREU, 2000).



De acordo com Campos e Leite (2013), para elaborar um modelo de regulação é necessário realizar uma descrição detalhada da floresta, mapear a capacidade produtiva atual, definir claramente as unidades de manejo, estabelecer as prescrições de manejo para cada uma dessas unidades e usar tabelas de produção específicas para cada unidade.

Um grande desafio para o gestor florestal é saber qual a melhor abordagem de modelagem já que essa escolha terá implicação econômica. Além disso, informações consistentes com relação ao volume produzido irão garantir a auto-suficiência do setor (BUONGIORNO; GILLES, 2003). No Brasil, o principal modelo empregado é o de Clutter (1963). Este modelo expressa a produção em função das idades atual e futura, do índice de local na idade atual e das áreas basais atual e futura. É um modelo consistente uma vez que as estimativas resultam em valores idênticos àqueles observados (CAMPOS; LEITE, 2013).

Segundo Leite (2013), a condição necessária para o emprego desse modelo é que existam dados de parcelas com, no mínimo, duas medições. Caso existam parcelas com apenas uma medição é recomendada a sua exclusão para poder ajustar o modelo de densidade variável escolhido.

Uma estimativa mais exata do volume de povoamentos equiâneos depende da qualidade das estimativas obtidas em nível de árvores. As medições de diâmetros e alturas de árvores individuais são comumente aplicadas para obtenção da estimativa do estoque de crescimento e a realização de análises de viabilidade econômica. Sabe-se que os diâmetros podem ser medidos a um baixo custo, ao contrário das medições das alturas que são demoradas, muitas vezes imprecisas e relativamente de difícil medição em plantios densos. Desse modo as alturas são derivadas indiretamente dos diâmetros, utilizando uma relação conhecida ou estimada entre os diâmetros e alturas (VAL LAAR; AKÇA, 1997; CAMPOS;LEITE 2013).

Segundo Clutter *et. al.* (1983), a avaliação do estoque de crescimento pode ser feita de duas formas distintas, sendo elas:

- Acrescentando-se ao cálculo da renda obtida até o último corte de cada alternativa, o valor da renda da madeira em pé ao final do horizonte de planejamento da respectiva alternativa, qualquer que seja a sua idade (preço em potencial daquele lote);
- Prolongar o manejo até o final de seu ciclo e acrescentar ao cálculo da renda o valor esperado da terra (VET), o qual representa um ganho de uma sequência infinita de rotações ótimas, cada qual com seu valor atualizado.

De acordo com Davis e Johnson (1987), um sistema de projeção não pode representar perfeitamente o sistema real modelado. Portanto, quando comparado as alternativas disponíveis, os usuários devem se preocupar com a qualidade de um sistema de projeção. Frequentemente, o problema é decidir se um novo sistema é melhor do que o usado atualmente.

Desse modo, os manejadores florestais têm buscado por modelos que sejam compatíveis, lógicos e que forneçam informações sobre o desenvolvimento futuro dos povoamentos florestais (SCOLFORO, 1990).

## **2.2 Redes Neurais Artificiais (RNAs)**

As primeiras informações sobre a utilização das Redes Neurais Artificiais datam de 1943, onde McCulloch e Pitts estudaram o comportamento do neurônio biológico humano, tendo como objetivo criar um modelo matemático inspirado no cérebro humano (VELLASCO, 2007). Desde então, muitas outras informações foram surgindo com o objetivo de aperfeiçoar cada vez mais a utilização das RNA.

Em 1951, Marvin Minsky criou o primeiro neurocomputador chamado *Snark*. Apesar de não ter executado uma função de processamento com informações relevantes, serviu como “molde” para futuras estruturas. No ano de 1958, Frank Rosenblatt e Charles Wightman juntos com outros estudiosos desenvolveram o primeiro neurocomputador bem sucedido, onde, por meio dos seus estudos, conseguiram sustentar os modelos do tipo *perceptron* (redes de um nível) e *MLP (Perceptrons de múltiplas camadas)* (VELLASCO, 2007).

Na década de 80, os estudos com redes neurais tomaram um impulso diferenciado. Em 1982, o físico John Hopfield criou uma rede que apresentava conexões recorrentes (sinal não se propaga exclusivamente para frente), baseando-se em um aprendizado não supervisionado com os neurônios competindo entre si. Já em 1986, Rumelhart, Hinton e Willians desenvolveram a teoria de redes em multinível (*MLP*), treinadas com o algoritmo de aprendizado por retropropagação (*Backpropagation*) contribuindo assim para o reaparecimento das redes do tipo *Perceptrons*. A partir daí foram criados um contexto favorável para o desenvolvimento das pesquisas em neurocomputação (HAYKIN, 2001)


As Redes Neurais Artificiais (RNA) nada mais são do que um modelo computacional baseado na arquitetura biológica do cérebro humano. É constantemente identificada como uma subespecialidade da Inteligência Artificial, como uma classe de modelos matemáticos auxiliando em problemas de classificação e reconhecimento de padrões,

também como uma parte da teoria conexionista dos processos mentais e finalmente, como uma categoria de modelos originados através do conhecimento (KOVÁCS, 2006).

De acordo com Haykin (2001), as RNAs se assemelham ao cérebro em dois aspectos: o conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem; E as forças de conexão entre neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido.

O sistema nervoso é composto por bilhões de células nervosas e a rede neural artificial também é formada por unidades conhecidas como pequenos módulos que simulam o funcionamento de um neurônio. Os funcionamentos destes módulos estão interligados aos elementos que foram inspirados, tendo como objetivo principal receber e transmitir as informações (LEMOS, 2003).


O neurônio artificial é um dispositivo simples capaz de calcular o somatório de  $N$  entradas ponderadas onde o resultado passa através de uma função não linear. Este dispositivo é caracterizado por um “offset” ou limiar interno e por algum tipo de função não linear, como mostra a Figura 1. A saída  $y$  é a função do somatório das entradas  $x_0, x_1 \dots x_{n-1}$ , ponderadas pelos pesos  $w_0, w_1 \dots w_{n-1}$  menos o offset  $\theta$  (ARANTES, 2005).



**Figura 1.** Representação de um neurônio artificial (Fonte: HAYKIN,2001.)

Cada neurônio artificial é uma unidade de processamento composto por uma função de ativação. Essa função de ativação corresponde a uma função matemática que combinada linearmente com as variáveis de entrada e os pesos que chegam a determinado neurônio, irá fornecer como retorno um valor de saída. A função de ativação limita as entradas a uma amplitude finita, variando no intervalo fechado entre 0 e 1 (HAYKIN, 2001). De acordo com este mesmo autor, existem várias funções matemáticas que podem ser

utilizadas como função de ativação. Entre as mais comuns estão: a função limiar (a); função linear por partes (b) e a função sigmoide (c) (Figura 2).



**Figura 2.** Principais Funções de Ativação nas RNAs. (Fonte: CASTRO, 2011)

A arquitetura de uma RNA é a forma que os neurônios estão estruturados e suas conexões, ou seja, número de camadas da rede, número de neurônios em cada camada, tipo de conexão entre os neurônios. Esses parâmetros definem o problema que pode ser tratado pela rede (BRAGA *et al.*, 2000).

A utilização das RNAs segue uma metodologia que pode ser decomposta em sucessivas etapas: Definição do problema, onde é verificado se as características do problema são condizentes com o uso de uma RNA; Escolha e adequação dos dados, onde se deve dispor de dados em quantidades e qualidade suficientes para fazer uso de uma RNA; Treinamento da Rede até ser atingido o comportamento desejado; Testar a Rede para verificar se o modelo criado tem um índice de acerto aceitável em dados novos; Se as etapas anteriores apresentarem sucesso o modelo utilizado poderá ser implementado para uso contínuo, ou seja, uso em campo. Mesmo assim, ao longo desse uso poderão surgir problemas o que irá remeter o retorno a uma etapa anterior reiniciando assim o processo (KINNERBROCK, 1992).

As Redes Neurais Artificiais possuem a habilidade de aprender com exemplos, melhorando assim seu desempenho. A etapa de aprendizagem consiste em um processo onde os parâmetros da rede são ajustados, ou seja, os pesos das conexões entre os neurônios artificiais são estabelecidos, guardando ao final do processo o conhecimento adquirido pela rede dentro do ambiente em que estava operando (BRAGA *et al.*, 2000; HAYKIN,2001).

Para que a rede possa aprender uma determinada tarefa, existe um algoritmo de aprendizado que consiste num conjunto de procedimentos com o objetivo de adaptar os parâmetros de uma RNA (BRAGA *et al.*, 2000; HAYKIN,2001)). No processo de

aprendizado os métodos de treinamentos podem ser divididos em dois tipos: aprendizado supervisionado e aprendizado não supervisionado.

No processo supervisionado, as entradas e saídas são apresentadas sucessivamente pelo usuário. Ao longo desse processo a rede ajusta os pesos das conexões até que o erro seja minimizado. Já no processo não supervisionado a rede recebe apenas os padrões de entrada, determina algumas propriedades dos conjuntos de dados que irá refletir na saída.

Os estudos na área de RNA são justificados por apresentarem diversas propriedades úteis e capacidades como: tolerância a falhas e ruídos, aprendizagem e generalização a partir de dados de treinamento, paralelismo massivo tornando-as muito eficientes, uniformidade de análise e projeto, analogia neurobiológica, mapeamento entrada-saída e não linearidade (BRAGA *et. al.*, 2000; HAYKIN, 2001; BULLINARIA, 2010).

A eficiência desta técnica, em áreas do manejo florestal, foi comprovada por alguns autores, podendo destacar Gorgens (2006) e Silva et al., (2009) que estudaram as RNA para estimar volumes individuais de eucalipto e de pinus; e também para estimar a produção volumétrica de eucalipto em nível de povoamento total e das variáveis diâmetro e altura em nível de árvores individuais (BINOTI, 2010); Binoti (2012) fez uso das redes neurais para estimar altura de árvores, bem como a projeção dos parâmetros da função Weibull, cubagem de árvores e modelos de distribuição de diâmetro, além de testar diferentes configurações de redes tendo como objetivo buscar a parametrização para estimar o volume de árvores. Nas indústrias de celulose e papel, alguns autores têm estudado esta técnica (GE, *et. al.*, 1998 LEMMETIL *et. al.*, 1998; HAYKIN, 2001; MALMBERG *et al.*, 2005; BARBER; SCOTT, 2007).

De acordo com Binoti (2010), a prognose da produção florestal pode ser desenvolvida utilizando RNA ao empregar dados de crescimento e produção bem como variáveis dendrométricas, tradicionais dos bancos de dados de inventário florestais, variáveis edáficas, climáticas e coordenadas geográficas.

As RNA têm apresentado um ótimo desempenho em relação à regressão, sendo mais eficiente para muitas aplicações em modelagem florestal.

### **3. MATERIAL E MÉTODOS**

#### **3.1 Descrição dos dados**

Os dados utilizados foram provenientes das parcelas permanentes de inventários florestais contínuos (IFC) realizados em povoamentos não desbastados de clones de eucalipto,

localizados no litoral norte da Bahia, em uma área com aproximadamente 3.000 hectares de floresta com 37 clones de eucalipto implantados sob diferentes arranjos espaciais. As variáveis numéricas consideradas foram diâmetro a altura de 1,3m do solo, altura dominante (m), idade (meses), área basal ( $m^2ha^{-1}$ ), volume ( $m^3ha^{-1}$ ) e as variáveis categóricas foram projeto, material genético e espaçamento. O número de medições variou de 3 a 4, compreendendo 658 parcelas permanentes, com área média de 400  $m^2$ .

### 3.2 Modelagem e crescimento da produção

O método da curva guia (CLUTTER *et al.*, 1983) foi utilizado para determinar a capacidade produtiva dos povoamentos, estipulando-se 72 meses como idade índice através do modelo exponencial desenvolvido por Schumacher (1933).

$$Hd = e^{\alpha + \beta^{-1}} + \mathcal{E}$$

Em que:  $Hd$  = altura dominante (m);  $I$  = idade (meses);  $\alpha, \beta$  = parâmetros; e  $\mathcal{E}$  = erro aleatório,  $\mathcal{E} \sim NID(0, \sigma^2)$ .

A partir da variação da altura dominante na idade índice, foram geradas 12 curvas de capacidade produtivas S(15), S(17), S(19), S(21), S(23), S(25), S(27), S(29), S(31), S(33), S(35) e S(37), sendo as mesmas, separadas em três categorias: I - alta capacidade produtiva ( $Hd > 28$ ), II - média capacidade produtiva ( $20 \leq Hd \leq 28$ ) e III - baixa capacidade produtiva ( $Hd \leq 20$ ).

Após a estimação do índice de local das parcelas, para a realização da projeção do crescimento e produção foram utilizadas as equações obtidas pelo ajustamento de Clutter (1963), sendo:

$$Ln(B_2) = LnB_1 \left( \frac{1}{I_2} \right) + \alpha_0 \left( 1 - \frac{I_1}{I_2} \right) + \alpha_1 \left( 1 - \frac{I_1}{I_2} \right) S_1 + Lne$$

$$Ln(V_2) = \beta_0 + \beta_1 \left( \frac{1}{I_2} \right) + \beta_2 S + \beta_3 Ln\beta_2 + Lne$$

em que:

$Ln$  = logaritmo neperiano;

$B_1$  e  $B_2$  = áreas basais atual e futura;

$\alpha_0$  e  $\alpha_1$  = parâmetros da função

$I_1$  e  $I_2$  = idades atual e futura;

$S$  = índice de sítios atual;

$V_2$  = volume futuro;

$B_0$  e  $\beta_3$  = parâmetros da função.

### 3.3 Redes neurais artificiais (RNA)

#### 3.3.1. Estudo 1 e 2

Primeiramente, avaliou-se a quantidade de parcelas que seriam retiradas do IFC para a validação das redes neurais. A simulação consistiu na escolha aleatória das parcelas dentro de cada classe de site (Tabela 1 – Estudo 1), levando-se em consideração as seguintes proporções: 10, 20, 30, 40, 50, 60, 70, 80, 90% das parcelas utilizadas para treinamento das RNA e o restante dos dados (90, 80, 70, 60, 50, 40, 30, 20 e 10% respectivamente), para a generalização. Os dados foram organizados pareando as informações de cada ano para cada parcela, ou seja, IFC1-IFC2, IFC2-IFC3 e assim sucessivamente. 7

**Tabela 1:** Estudo 1: Quantidade de parcelas correspondente as percentagens em cada classe de site.

%	I	II	III	TOTAL*
10	16	43	7	66
20	32	87	13	132
30	48	130	20	198
40	64	173	26	263
50	80	216	33	329
60	96	259	40	395
70	112	302	46	460
80	128	345	53	526
90	144	389	59	592

\* Total de parcelas que foram utilizadas para o treino do estudo 1.

Também foi estabelecido um número fixo de parcelas para cada classe, onde tomou-se por base o número máximo de parcelas existentes em uma das classes (classe III com 68 parcelas) e a partir daí foram definidas as quantidades de parcelas (Tabela 2- Estudo 2) correspondentes a cada classe.

**Tabela 2:** Estudo 2: Quantidade de parcelas escolhidas em cada classe de site.

I	II	III	TOTAL*
60	60	60	180
50	50	50	150
40	40	40	120
30	30	30	90
20	20	20	60
10	10	10	30

\*Total de parcelas que foram utilizadas para o treino do estudo 2.

### 3.3.2. Treinamento e generalização das redes neurais artificiais

As redes treinadas foram do tipo *Perceptrons* de múltiplas camadas, mais conhecidas como *MLP (Multilayer Perceptron)*, que consistem em duas camadas de neurônios artificiais que processam os dados (camada intermediária e camada de saída) e uma camada de neurônios artificiais que apenas recebem os dados (camada de entrada) e direciona-os à camada intermediária.

As RNA treinadas são do tipo ântero-alimentadas utilizando o algoritmo *Resilient Propagation (RPROP+)*, que realiza uma adaptação das atualizações de peso de acordo com o comportamento da função de erro (RIEDMILLER; BRAUN, 1993).

O critério de parada utilizada foi o erro médio ou o número de ciclos, sendo assim, o treinamento da rede foi finalizado quando o primeiro parâmetro foi atingido. O limite de parada foi de 0,0001 para erro médio e 3.000 para o número de ciclos.

Para a etapa da generalização foram utilizados os dados remanescentes das parcelas permanentes que não foram utilizados durante o treinamento.

O *software* utilizado para o treinamento das RNA nas duas metodologias foi o *NeuroForest 3.3* (BINOTI, 2012), que é gratuito e foi desenvolvido para uso no meio florestal, a fim de resolver os problemas específicos do setor. Já o ajuste do modelo de crescimento foi realizado no *SifProg* versão 4.4.

### 3.3.3. Prognose da produção florestal

Para realização da prognose foram aplicadas as redes que apresentaram resultados mais exatos no treinamento e na generalização. Os dados remanescentes tanto para o estudo 1 quanto para o estudo 2, que não foram utilizados no treinamento, serviram para realizar a projeção da variável de saída que foi o volume 2. Nesta etapa também foi utilizado o *software* *NeuroForest 3.3*.

### 3.3.4. Avaliação das estimativas geradas pelas redes neurais artificiais

A avaliação das estimativas das Redes Neurais Artificiais foi feita por estatísticas e análise gráfica. As estatísticas utilizadas foram a correlação entre os volumes estimados e observados, a raiz do erro quadrado médio (RMSE%) e o erro médio percentual (erro %). A análise gráfica dos erros foi utilizada na avaliação dos modelos de RNA, sendo construídos histogramas com a frequência de observações por classe de erro percentual:

$$erro\% = \frac{\hat{Y} - Y}{Y} \times 100$$



em que,  $Y$  é a saída observada nos inventários,  $\hat{Y}$  é a saída estimada pela RNA.

O grau de associação entre valores observados e estimados é indicado pela correlação e juntamente com a análise de resíduos é possível inferir sobre a qualidade da prognose ou estimação onde quanto mais próxima de 1, maior a correlação entre as variáveis (BINOTI, 2010), sendo:

$$r_{y\hat{y}} = \frac{cov(Y, \hat{Y})}{\sqrt{s^2(Y)s^2(\hat{Y})}}$$

em que, “s<sup>2</sup>” é a variância e “cov” é a covariância.

A raiz do erro quadrado médio (RMSE) avalia a diferença média entre os valores observados e os valores estimados, onde quanto menor o RMSE, melhor a precisão da estimativa (MEHTÄTALO *et al.*, 2006), sendo:

$$RMSE (\%) = 100 \sqrt{\frac{\sum_{i=1}^n (Y - \hat{Y})^2}{n}} / \bar{Y}$$

em que,  $\bar{Y}$  é a média da saída observada e  $n$  é o número total de dados.

#### 4. ANÁLISE DE CUSTO

A análise de custo consistiu na redução do custo com relação ao valor unitário de cada parcela. Na tabela 3 é apresentado o valor unitário da parcela, bem como o valor total que foi gasto com a remedição das 658 parcelas.

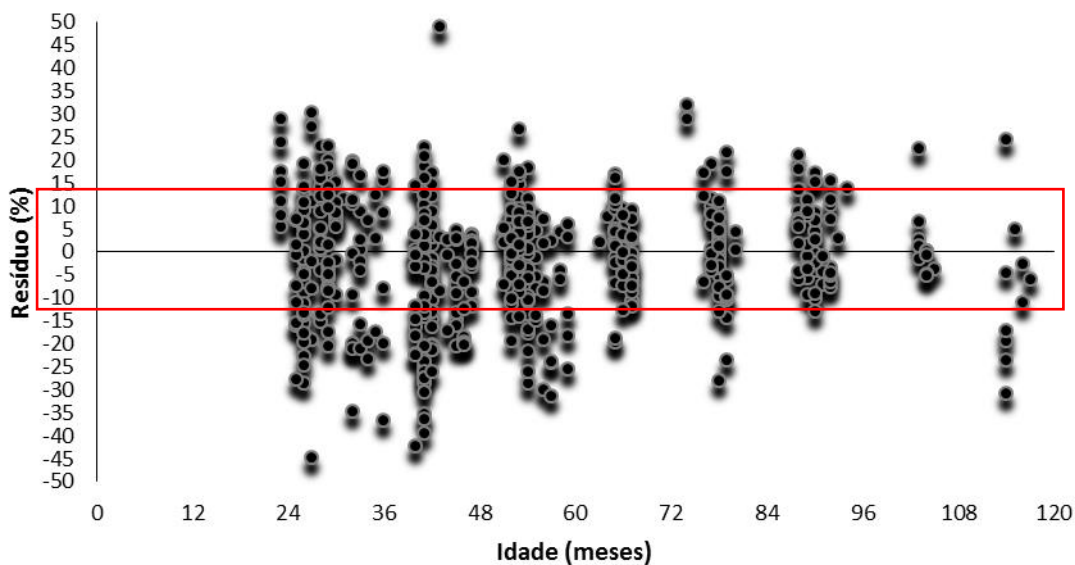
**Tabela 3.** Valor gasto para mensurar as 658 parcelas.

Serviço	Quantidade	Unidade	Preço/Unidade	Total
Coleta de dados - Parcelas Permanentes	658	Parcela	88,40	R\$ 58.167,20

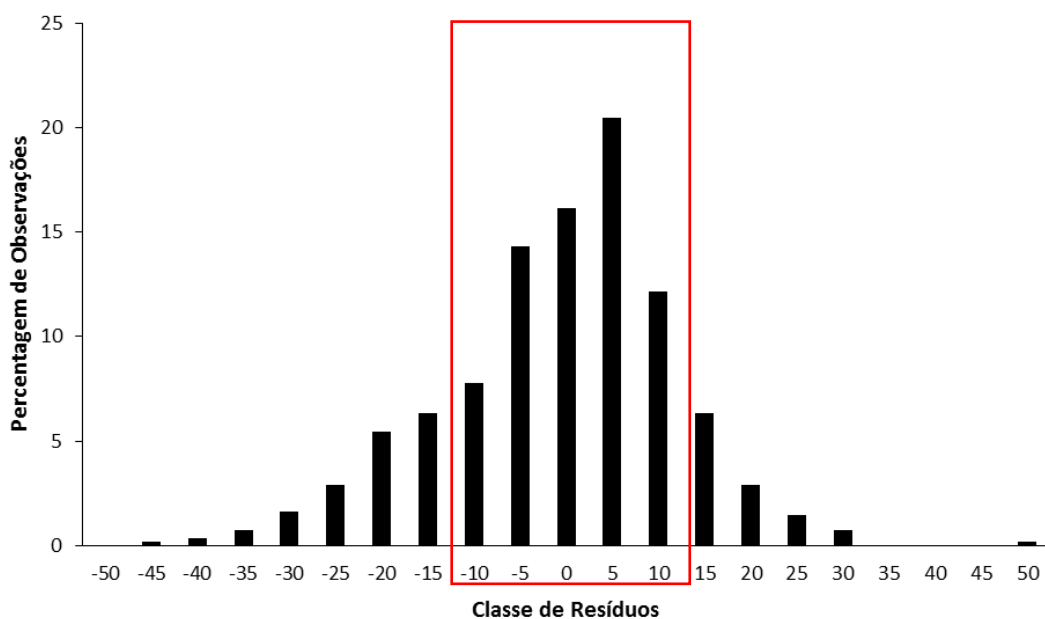
## 5. RESULTADOS E DISCUSSÃO

### 5.1 Modelo de Clutter

Avaliando-se os resultados encontrados no modelo proposto por Clutter (1963), pode-se notar que mais de 70% dos resíduos das estimativas de produção futura estão concentrado em  $\pm 10\%$  podendo ser verificado no gráfico de resíduos (Figura 4) e no histograma do erro (Figura 4).

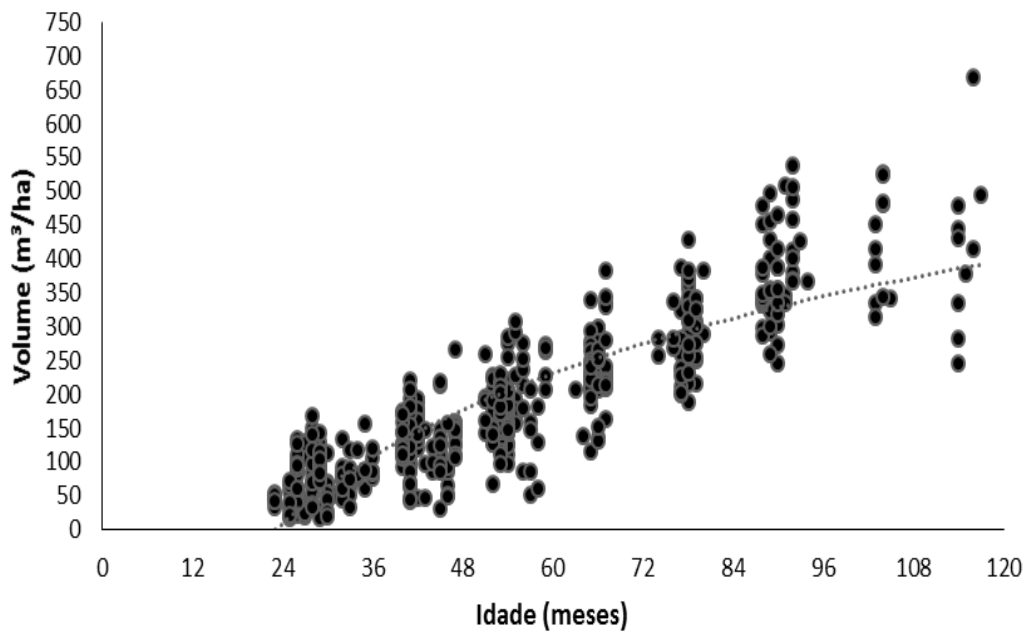


**Figura 4.** Gráfico de resíduos das estimativas geradas através do modelo de Clutter (1963).




**Figura 3.** Histograma dos erros obtidos pelas estimativas geradas através dos modelos de Clutter (1963).

Na Figura 5 podemos observar que o modelo de Clutter se ajustou normalmente aos dados da população em foco.



**Figura 5.** Projeção volumétrica do modelo de Clutter (1963).

O grau de associação e a direção entre duas variáveis é indicado pela correlação entre os volumes observados e estimados que pode ser observado na **Figura 6**.



**Figura 6.** Volume observados e estimados através do modelo de Clutter (1963).

Analisando a correlação entre os volumes estimados em função dos volumes observados, pode-se verificar a exatidão das estimativas da produção volumétrica levando em consideração a tendência apresentada.

## 5.2 Estudo 1

A melhor rede de cada treinamento foi selecionada e utilizada para generalizar aos dados das demais parcelas, que não participaram da fase de treino, sendo realizado assim a prognose.

Na Tabela 4 estão representadas as estimativas da raiz quadrada do erro médio (RMSE%) que variou de 3,91 a 34,52 e da correlação entre os volumes observados e estimados ( $r_{y\hat{y}}$ ) que teve variação entre 0,8156 a 0,9977, levando-se em consideração o percentual para cada treinamento e validação proposta no primeiro estudo.

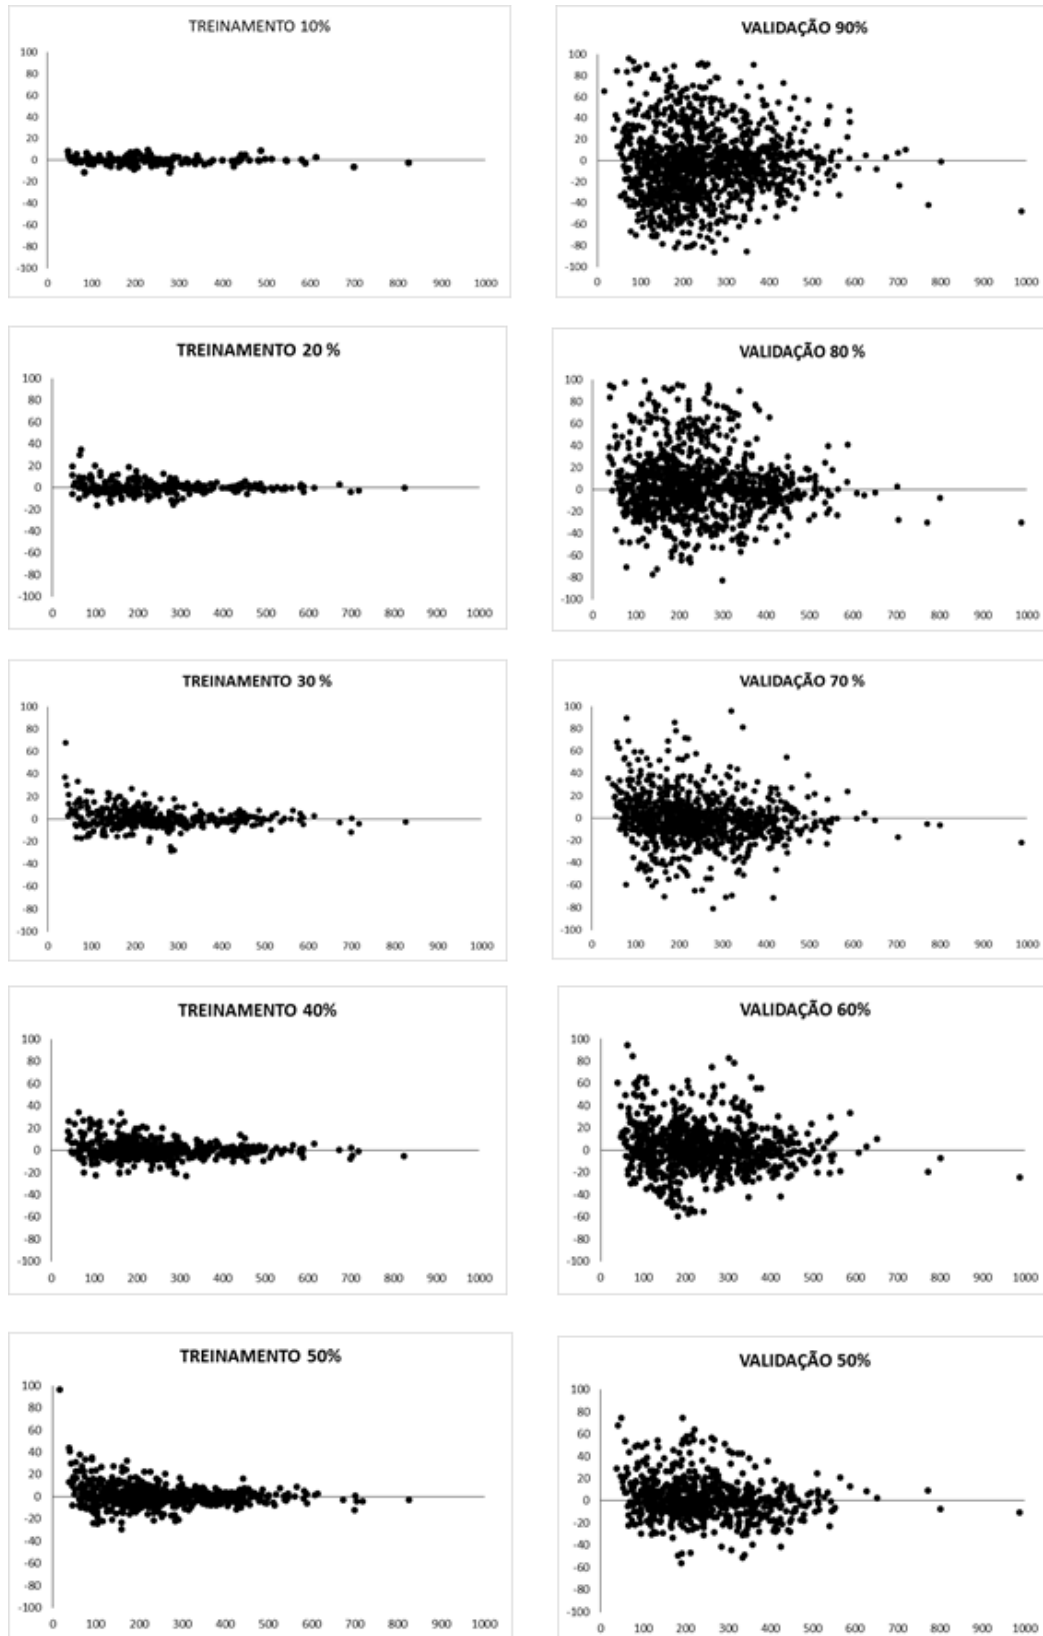
Para o treinamento, o menor valor do erro quadrado médio (3,91%) foi obtido no processamento realizado com a proporção de 10% das parcelas para treinamento e 90% para validação, porém, para a validação esse foi o processamento que apresentou o maior erro quadrado médio (34,52%).

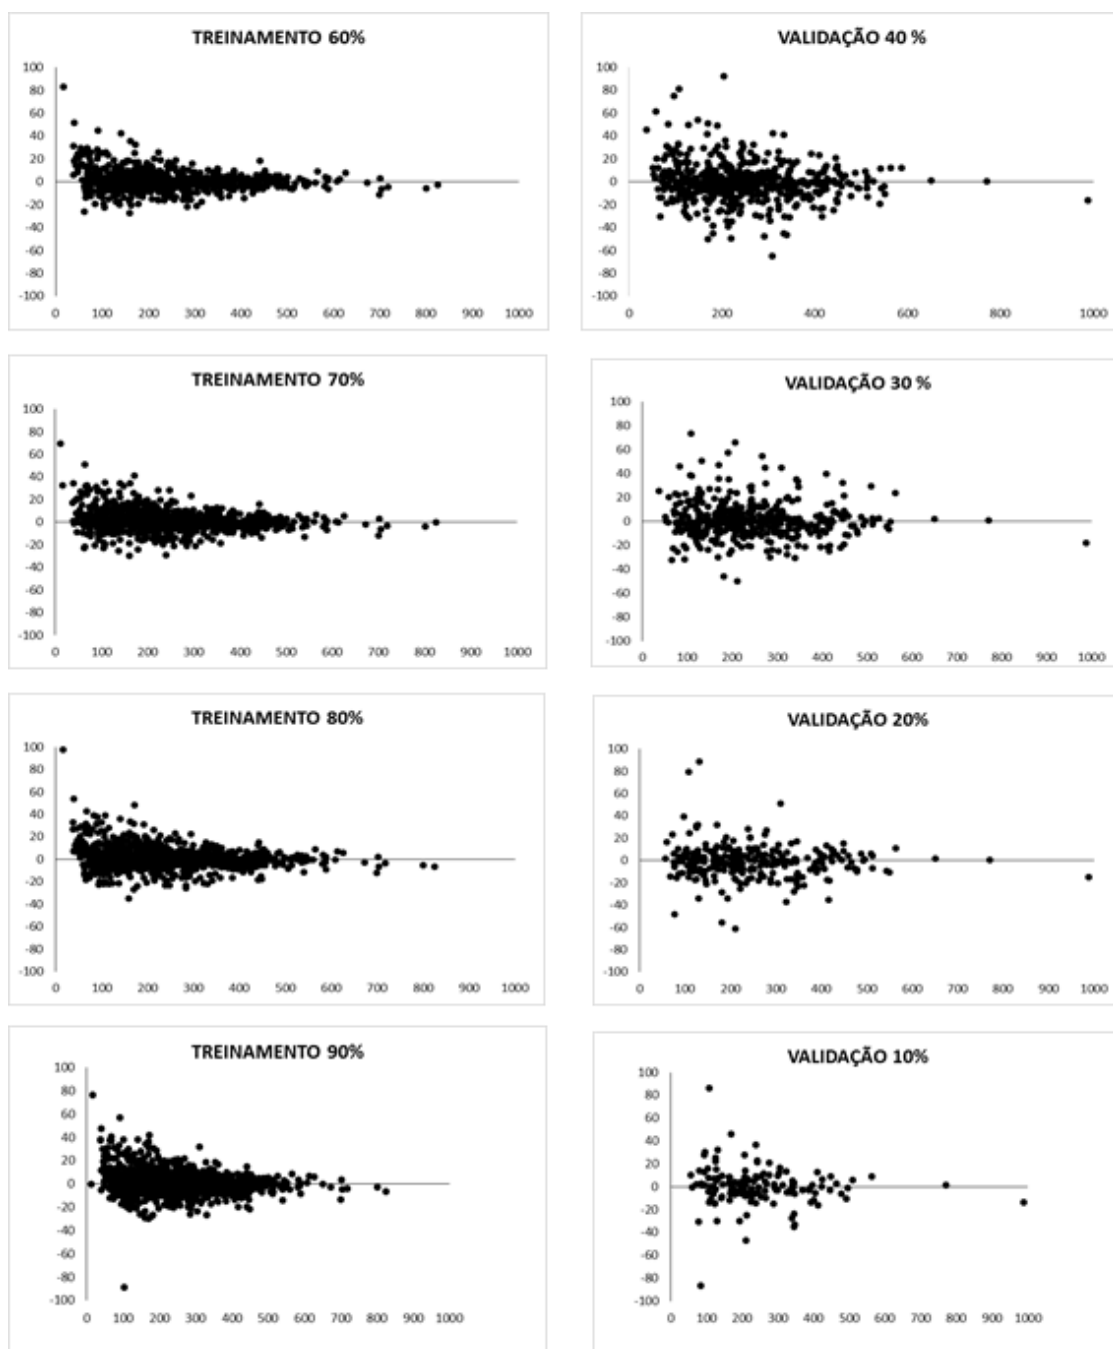
É possível perceber que conforme a base de treino era reduzida, a raiz do erro quadrado médio (RMSE%) também reduzia e a correlação aumentava. Esse fator ocorreu porque com a redução da base, a variabilidade diminuiu o que de acordo com ALCÂNTARA (2015) provoca uma queda no potencial da rede impedindo-a de gerar estimativas para dados que não participaram do treinamento (validação). Devido a isso, analisando a validação, o RMSE foi aumentando e a correlação foi diminuindo conforme era reduzida a base de treino.

**Tabela 4:** Raiz quadrada do erro quadrado médio (RMSE) e correlação entre os valores dos volumes observados e estimados.

TREINAMENTO			VALIDAÇÃO		
%	RMSE%	$r_{y\hat{y}}$	%	RMSE%	$r_{y\hat{y}}$
90%	6,36	0,9867	10%	14,38	0,9658
80%	7,70	0,9883	20%	13,87	0,9634
70%	7,36	0,9890	30%	15,50	0,9363
60%	5,74	0,9915	40%	16,46	0,9433
50%	6,73	0,9916	50%	18,07	0,9330
40%	6,31	0,9916	60%	20,79	0,9166
30%	6,81	0,9921	70%	24,43	0,8822
20%	4,35	0,9969	80%	30,11	0,8282
10%	3,91	0,9977	90%	34,52	0,8158

A Figura 7 apresenta os gráficos de dispersão das diferenças entre os valores observados e estimados pelas RNA. Dessa forma pode-se avaliar se existe tendenciosidade na estimativa da variável dependente ao longo da linha de regressão.











**Figura 7.** Distribuição dos resíduos percentuais dos volumes totais estimados pelas redes neurais artificiais (eixo y) em função dos valores observados (eixo x) no treinamento e validação, para o Estudo1.

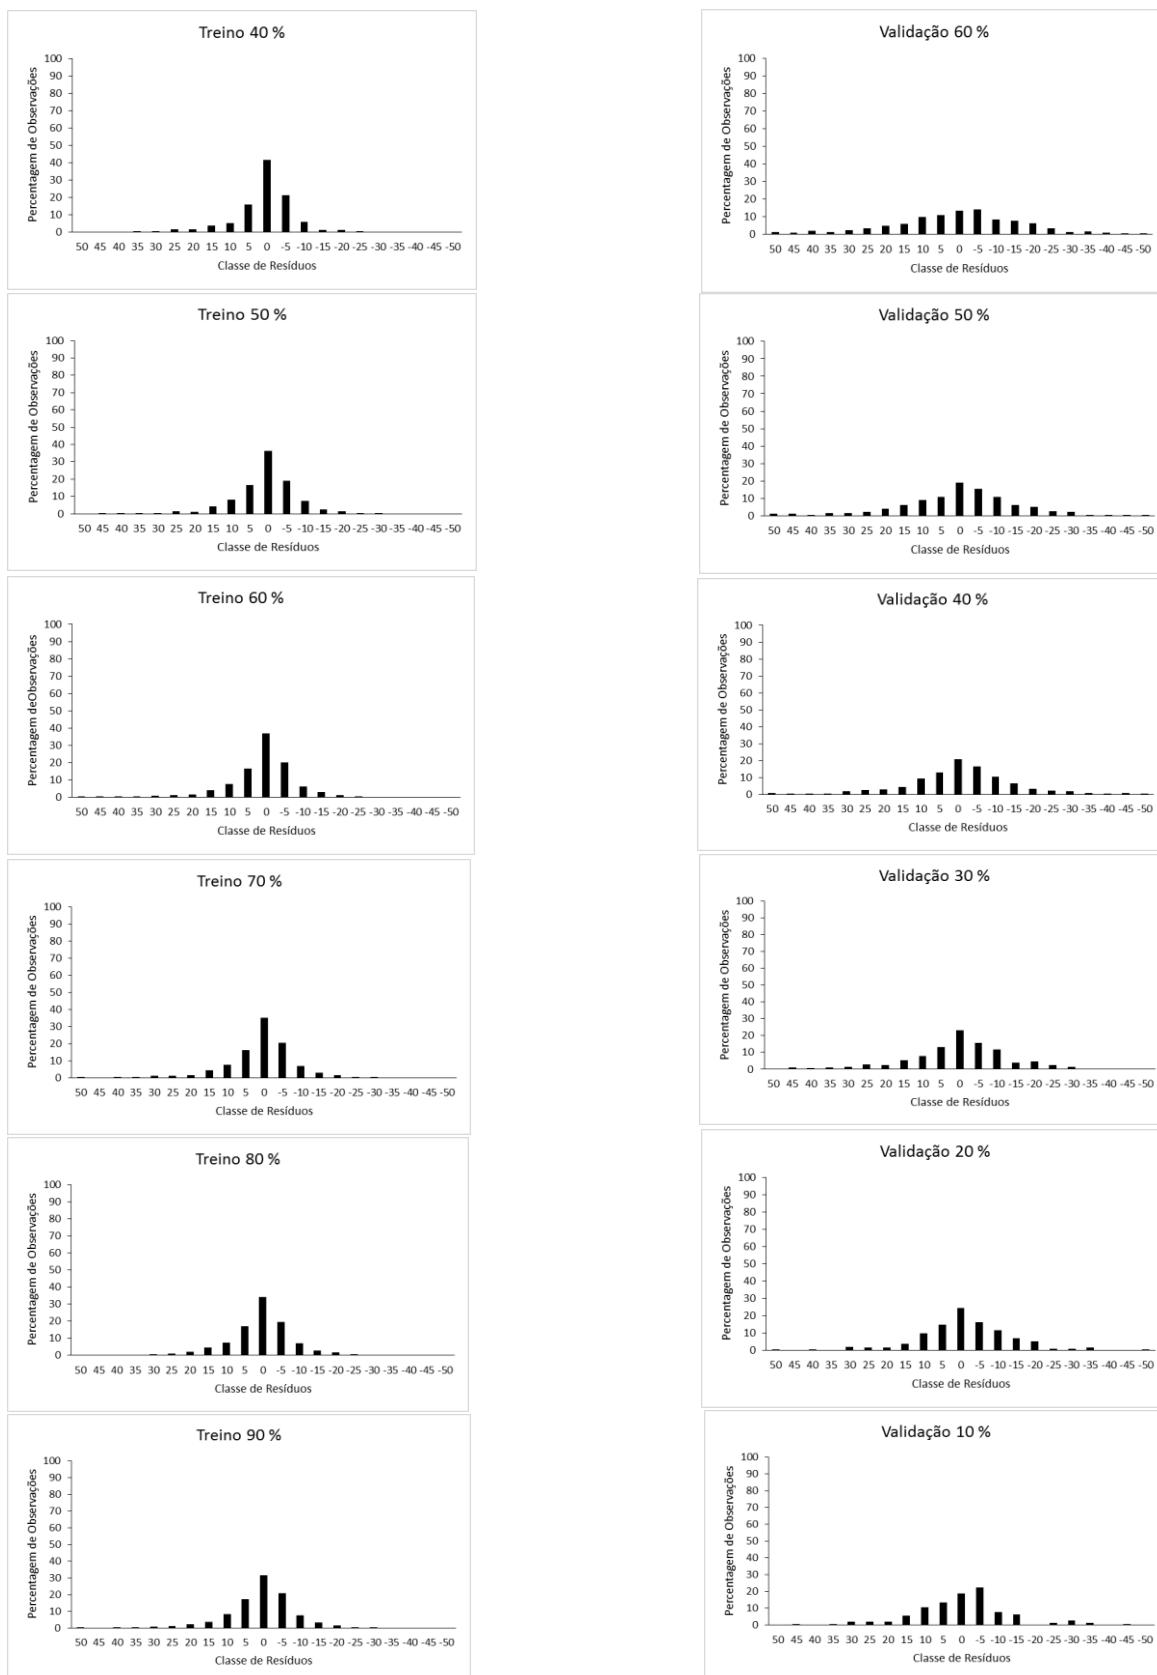
Nota-se que os resíduos apresentaram distribuição uniforme ao longo do eixo x para os treinamentos e validações, garantindo assim estimativas sem tendências.

Na Figura 8 estão representados os gráficos de histograma da distribuição de frequência dos resíduos.

Observando os histogramas de frequência dos erros percentuais obtidos pelas estimativas das RNAs, nota-se que reduzindo de 30 a 50% das parcelas, o erro percentual se concentrou em  $\pm 12\%$  tanto para treino quanto para validação. A partir da proporção de 60% das parcelas para treinamento e 40% para validação, verifica-se que as redes resultaram em processamentos com maior exatidão e melhor distribuição dos erros concentrando-os em  $\pm 10\%$ . Por não haver grandes diferenças a partir desse percentual (60% dos dados para treinamento e 40% para validação), pode-se inferir que os resultados encontrados a partir dessa proporção, são satisfatórios.

Pesquisas com RNA, na área de mensuração florestal, recomendam a utilização de 70% dos dados para treinamento e 30% para validação podendo ser citado como exemplo os trabalhos desenvolvidos por Binoti (2010) e Binoti (2012).





**Figura 8** - Gráfico de histogramas da frequência dos erros percentuais obtidos pelas estimativas geradas através do treinamento e validação efetuado pela RNA para a Estudo 1.



O custo total da mensuração de todas as parcelas do inventário foi de R\$ 58.167,20. A avaliação dos custos gerada pela aplicação da metodologia proposta no estudo 1, pode ser feita utilizando os valores totais para cada redução aleatória das parcelas de acordo com a Tabela 5.

Analisando graficamente e estatisticamente, os processamentos realizados, nota-se a inexistência de tendenciosidade nas estimativas geradas pela metodologia proposta no estudo 1. Para o estudo proposto, o melhor resultado foi encontrado ao realizar a proporção de 90% das parcelas para treinamento e 10% para validação, onde o erro percentual ficou entre  $\pm 7,5\%$ , sendo este um resultado satisfatório se tratando em nível de população. Para esse resultado a economia gerada, no custo total do inventário, foi de R\$ 5.834,40.

Considerando uma proporção de 60% para treino e 40% validação das parcelas, a economia feita no custo total do inventário seria de R\$ 23.249,20.

**Tabela 5.** Valor gasto na remediação utilizando a metodologia do estudo 1.

% Redução aleatória das parcelas	Unidade	Parcelas		Preço/Unidade	Total*
		Treino	Validação		
<b>10</b>	Parcela	66	592	88,4	<b>52.332,80</b>
<b>20</b>	Parcela	132	526	88,4	<b>46.498,40</b>
<b>30</b>	Parcela	198	460	88,4	<b>40.664,00</b>
<b>40</b>	Parcela	263	395	88,4	<b>34.918,00</b>
<b>50</b>	Parcela	329	329	88,4	<b>29.083,60</b>
<b>60</b>	Parcela	395	263	88,4	<b>23.249,20</b>
<b>70</b>	Parcela	460	198	88,4	<b>17.503,20</b>
<b>80</b>	Parcela	526	132	88,4	<b>11.668,80</b>
<b>90</b>	Parcela	592	66	88,4	<b>5.834,40</b>

\*Total em reais que seria reduzido.

### 5.3 Estudo 2

Na Tabela 6 estão representadas as estimativas da raiz quadrada do erro médio (RMSE%) que teve variação entre 3,91 e 42,94 e da correlação entre os volumes observados e estimados ( $ry\hat{y}$ ) que variou entre 0,6456 a 0,9983 levando-se em consideração o percentual para cada treinamento e validação proposta no segundo estudo.

No estudo 2 o menor valor do erro quadrado médio (3,91%) foi obtido com a redução de 10 parcelas para cada classe de sítio (30 parcelas no total), sendo semelhante ao menor valor encontrado para o estudo 1 que também foi de 3,91%. Essa redução também apresentou o pior RMSE para validação (42,44%).

É possível perceber que com a redução da base de treino, o RMSE hora reduzia e hora aumentava, assim como a correlação. Uma possível causa para essa variação, tanto para o treinamento quanto para a validação, é o aumento da variabilidade devido a escolha de uma menor quantidade de parcelas utilizada para treino.

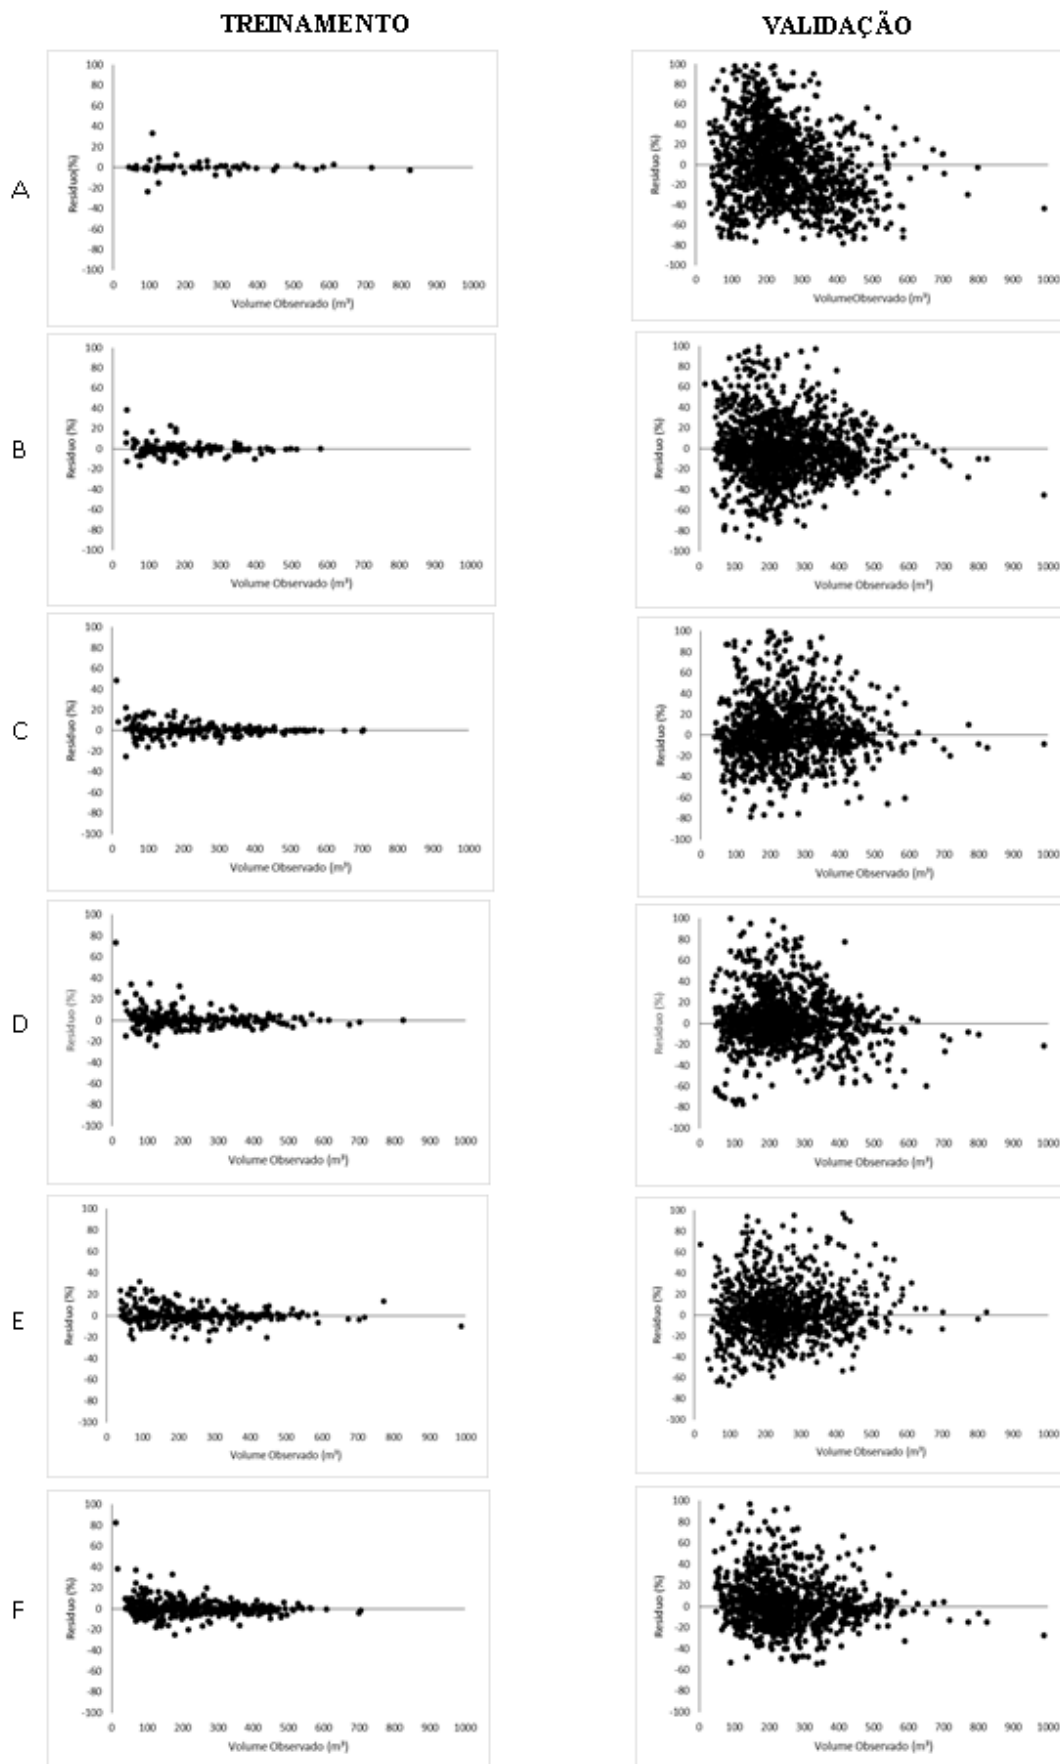
**Tabela 6** - Raiz quadrada do erro quadrado médio (RMSE) e correlação entre os valores dos volumes observados e estimados.

REDUÇÃO DE PARCELAS		TREINAMENTO		VALIDAÇÃO		
Nº PARCELAS*	TOTAL**	RMSE%	$ry\hat{y}$	Nº PARCELAS	RMSE%	$ry\hat{y}$
60	180	5,57	0,9952	478	22,79	0,8965
50	150	7,22	0,9929	508	34,57	0,8646
40	120	5,68	0,9959	538	27,40	0,8476
30	90	4,14	0,9978	568	30,37	0,8481
20	60	4,62	0,9966	598	28,01	0,8604
10	30	3,91	0,9983	628	42,44	0,6456

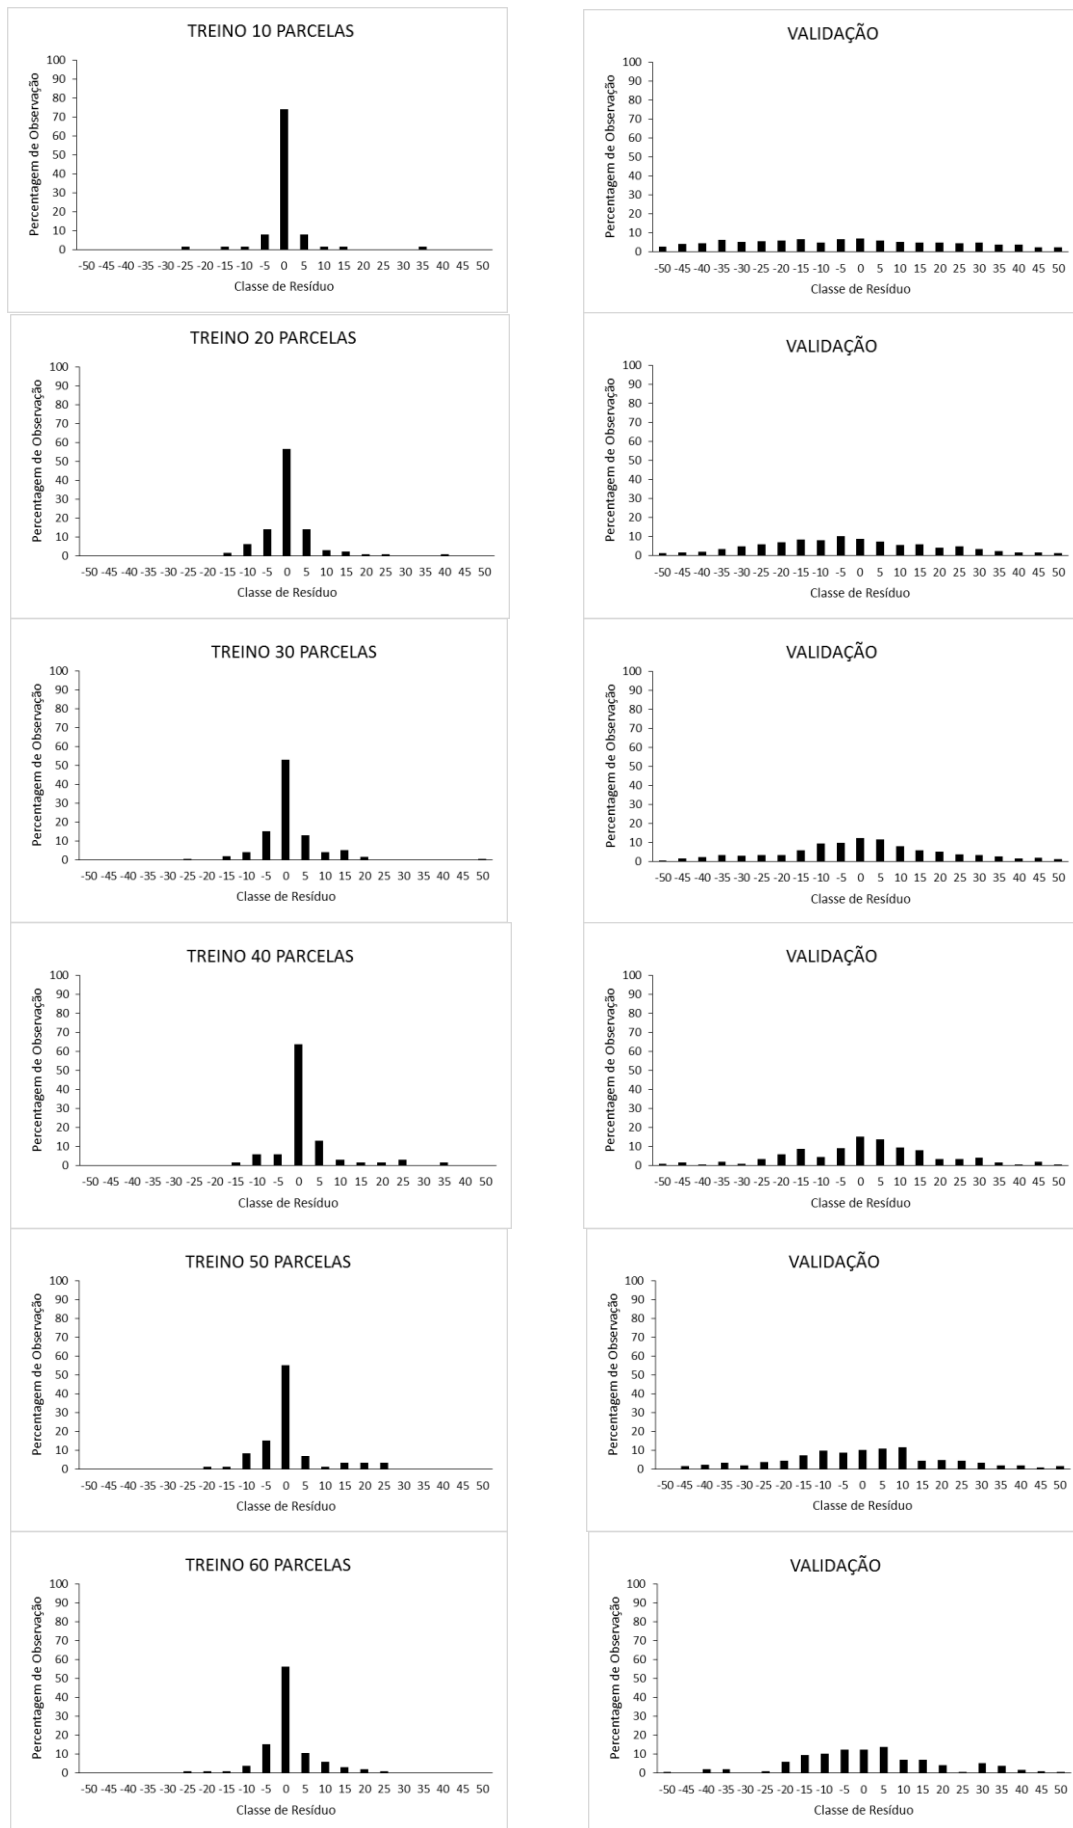
\*Número de parcelas em cada classe de sítio; \*\*Quantidade total de parcela que foram reduzidas.

Na figura 9 estão representados os gráficos de dispersão dos erros percentuais em relação aos valores observados do volume ( $m^3/ha$ ) para o treinamento e validação, onde foram escolhidas aleatoriamente 10 (A), 20 (B), 30 (C), 40 (D), 50 (E) e 60(F) parcelas respectivamente em cada classe de sítio.

Na **Erro! Fonte de referência não encontrada.**, são apresentados os gráficos de esíduos e histogramas de erros obtidos pelas estimativas realizadas através do processamento das redes neurais artificiais (RNA).



**Figura 9:** Distribuição dos resíduos percentuais dos volumes totais estimados pelas redes neurais artificiais (eixo y) em função dos valores observados (eixo x) no treinamento e validação 10 (A), 20 (B), 30 (C), 40 (D), 50 (E) e 60 (F) parcelas respectivamente em cada classe de sítio, para o Estudo 2.



**Figura 10:** Gráfico de resíduos e histogramas de frequência dos erros percentuais obtidos pelas estimativas geradas através do treinamento e validação efetuada pela RNA para o Estudo 2.

Analisando graficamente e estatisticamente, os processamentos realizados, nota-se a inexistência de tendenciosidade nas estimativas geradas pela metodologia proposta no estudo 2. Para o estudo proposto, o resultado satisfatório foi encontrado ao realizar a redução de 60 parcelas para cada classe de sítio (180 parcelas no total), onde o erro percentual ficou entre  $\pm 10\%$ . Para esse resultado a economia gerada, no custo total do inventário, foi de R\$ 42.255,20.

Na Tabela 7 são apresentados os valores totais, que seriam gastos, levando em consideração a quantidade de parcelas a ser mensuradas propostas no estudo dois.

**Tabela 7.** Total gasto na remedição, utilizando o estudo 2.

<b>Redução fixa da mesma quantidade de parcelas em cada classe de sítio</b>	<b>Treino</b>	<b>Unidade</b>	<b>Validação*</b>	<b>Preço/Unidade</b>	<b>Total**</b>
<b>60</b>	<b>180</b>	Parcela	<b>478</b>	88,4	<b>15.912,00</b>
<b>50</b>	<b>150</b>	Parcela	<b>508</b>	88,4	<b>13.260,00</b>
<b>40</b>	<b>120</b>	Parcela	<b>538</b>	88,4	<b>10.608,00</b>
<b>30</b>	<b>90</b>	Parcela	<b>568</b>	88,4	<b>7.956,00</b>
<b>20</b>	<b>60</b>	Parcela	<b>598</b>	88,4	<b>5.304,00</b>
<b>10</b>	<b>30</b>	Parcela	<b>628</b>	88,4	<b>2.652,00</b>

\* Parcelas que não seriam mensuradas; \*\* Total gasto na mensuração das parcelas.

## **6. CONCLUSÕES**

O uso de Redes Neurais Artificiais mostrou eficaz para prognosticar o crescimento florestal de uma floresta equiânea de eucalipto.

A aplicação da metodologia proposta no estudo 1 demonstrou resultados satisfatório ao utilizar a partir de 60% das parcelas para o treinamento e 40% para a validação.

O melhor resultado foi encontrado no estudo 1 ao utilizar 90% das parcelas para treinamento e 10% para generalização.

O estudo 2 apresentou resultado satisfatório com a redução de 60 parcelas por classe de sítio.

Utilizando essa abordagem de redução no número de parcelas é possível utilizar redes neurais artificias para redução de custos do inventário florestal contínuo.

## 7. REFERÊNCIAS BIBLIOGRÁFICAS

ABREU, E. C. R. **Modelagem da prognose precoce do volume por classe diamétrica para *Eucalyptus grandis***. 2000. 70 p. Dissertação (Mestrado em Engenharia Florestal) - Universidade Federal de Lavras, Lavras.

ALCÂNTARA, A. E. M. **Redes neurais artificiais para prognose do crescimento e da produção de povoamentos de eucalipto em Minas Gerais**. Tese (Doutorado em Ciência Florestal) – UFV, Viçosa – MG, 2015.43p.

ARANTES, J. G.; **Diagnóstico de Falhas em Transformadores de Potência pela Análise de Gases Dissolvidos em Óleo Isolante Através de Redes Neurais**. Dissertação (Mestrado em Ciências em Engenharia) - UNIFEI, Itajubá – MG, 2005. 76p.

BARBER, V. A.; SCOTT, G. M. **Dynamic modeling of a paper machine part II: evaluation of wet-end model dynamics**. TAPPI Journal, vol. 6, no. 1, February 2007.

BINOTI, M. L. M. S. **Emprego de Redes Neurais Artificiais em Mensuração e Manejo Florestal**. 2012. 130 f. Tese (Doutorado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa, 2012.

BONDUELLE, G. M. Avaliação e análise dos custos da má qualidade na indústria de painéis de fibras. Florianópolis: Universidade Federal de Santa Catarina, 1997. 288p. Tese Doutorado. <<http://www.eps.ufsc.br/teses97/bonduelle/index.html>>. 05 Abr. 2012.

BUONGIORNO, J.; GILLESS, J. K. Decision Methods for Forest Resource Management. Elsevier, 2003. 458p

BRAGA, A. de P.; CARVALHO, A. P. de L. F. de; LUDEMIR, T. B. Redes Neurais Artificiais: Teoria e Aplicações. 1 ed. Rio de Janeiro: LTC, 2000. 262 p.

BRITO, J. O.; CINTRA, T. C. – Madeira para Energia no Brasil: Realidade, Visão, Estratégia e Demandas de Ações. RENABIO – Biomassa & Energia, v. 1, n. 2, p. 157-163, 2004.

BULLINARIA, J. A. Introduction to Neural Computation. Notas de aula. 2009. Disponível em: <<http://www.cs.bham.ac.uk/~jxb/inc.html>>. Acesso em: 02 de maio 2014;

CAMPOS, J. C. C.; Leite, H. G. **Mensuração Florestal: perguntas e respostas**. 4<sup>a</sup> ed. Atualizada e ampliada. Viçosa: UFV, 2013. 605 p.

CAMPOS, J. C. C.; LEITE, H. G. Mensuração Florestal: perguntas e respostas. 4<sup>a</sup> ed. Atualizada e ampliada. Viçosa: UFV, 2009. 605 p.

CARAZZA F.; As riquezas das fumaças do carvão vegetal. Revista Opiniões, Junho/Agosto.(2008) ;

CASTRO, R. V. O. Modelagem do crescimento em nível de árvores individuais utilizando redes neurais e autômatos celulares. 2011. 80 f. Dissertação (Mestrado) – Universidade Federal de Viçosa, 2011;

CLUTTER, J.C., PIENAAR, L.V., BRISTER, G.H. et al. Timber management: a quantitative approach. 3, ed. New York: John Wiley, 1983. 333p.

DIAMANTOPOULOU, M. J. **Artificial neural networks as an alternative tool in pine bark volume estimation**. Computers and electronics in agriculture, v. 48, n.3, p. 235-244, 2005.

ENCINAS, J. I.; Silva, G. F.; Pinto, J. R. R.; **Idade e crescimento das árvores**. Universidade de Brasília – UNB. Departamento de Engenharia Florestal, 2005. 43p.: il – (Comunicações técnicas florestais; ISSN 1517-1922; v.7, n.1).

FAO – FOOD AND AGRICULTURE ORGANIZATION OF THE UNITED NATIONS. Planted forests in sustainable forest management: a statement of principles – 2010. 2009.\_\_\_\_\_. Global forest resources assessment 2010: key findings. 2010.

HAYKIN, S. Redes Neurais: Princípios e prática. 2. Ed. Porto Alegre: Bookman, 2001. 900p.

IBÁ – INDÚSTRIA BRASILEIRA DE ÁRVORES. Ano Base2015/ IBÁ. 80 p. Brasília, 2015.

FILHO, F. A. C.; **Sistema de prognose do crescimento e produção para *Pinus taeda* L. sujeito a regimes de desbastes e podas**. 2009. 147 p. Dissertação (Mestrado) – Universidade Federal de Lavras, 2009;

GE, S. S.; HANG, C. C.; ZHANG, T. Z. **Nonlinear adaptive control using neural networks and its application to CSTR systems**. Journal of process control 9, p 313-323, 1998.

GORGENS, E. **Estimação do volume de árvores utilizando redes neurais artificiais**. 2006. 84 p. Dissertação (Mestrado) – Universidade Federal de Viçosa, Viçosa, 2006.

IBGE – INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. Produção da extração vegetal e da silvicultura 2012. 2013. Disponível em: <[http://www.ibge.gov.br/home/estatistica/pesquisas/pesquisa\\_resultados.php?id\\_pesquisa=45](http://www.ibge.gov.br/home/estatistica/pesquisas/pesquisa_resultados.php?id_pesquisa=45)>. Acesso em: 06/04/2015.

KOVÁCS, Z. L.; **Redes Neurais Artificiais: fundamentos e aplicações: um texto básico**. 4ª ed. Ver. – São Paulo: Editora Livraria da Física, 2006.

LEMOS, E. P.; **Análise de crédito bancário com o uso de *data mining*: Redes Neurais e Árvores de Decisão**. 2003. 147 p. Dissertação (Mestrado em Ciências) – Universidade Federal do Paraná, Curitiba, PR, 2003.

LEMMETI, A.; LEIVISKÄ, K.; SUTINEN, R. **Kappa number prediction based on cooking liquor measurements**, Report A No 5, May 1998.

LEK, S.; DELACOSTE, M.; BARAN, P.; DIMOPOULOS, I.; LAUGA, J.; AULAGNIER, S. Application of neural networks to modelling nonlinear relationships in ecology. **Ecological Modelling**, v. 90, p. 39-52, 1996.



LIMA, C. R.; LIMA, G. D.; PAES, J. B. – Consumo Residencial de Energéticos para Cocção nas Comunidades Santana e Queimadas, Santa Terezinha, Paraíba, Brasil. **RENABIO – Biomassa & Energia**, v. 3, n. 2, p. 83-96, 2006.

MAGALHÃES, J. G. S.; **Prognose e regulação de florestas de eucalipto utilizando modelo de crescimento e inteligência computacional**. 2014. 66f. Dissertação (Mestrado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa, MG, 2014.

MALMBERG, B.; EDWARDS, L.; LUNDBORG, S.; AHLROTH,; M. WARNQVIST. **B. Prediction of dust composition and amount in kraft recovery boilers**. TAPPI Journal, March 2005.

MIRANDA, M. C.; **Capacidade produtiva e qualidade de sítios cultivados com eucalipto em argissolos de tabuleiro no litoral norte da bahia**. 2012. 121f. Dissertação (Mestrado em solos e qualidade e ecossistemas) – Universidade Federal do Recôncavo da Bahia, Cruz das Almas, BA, 2012.

MONTEIRO, M. A.; **Em busca de carvão vegetal barato: o deslocamento de siderúrgicas para a Amazônia**. Novos Cadernos NAEA, v. 9, n. 2, p. 55-97, dez. 2006, ISSN 1516-6481;

NIEVOLA, J. C.; **Redes Neurais Artificiais**. In: Sociedade Brasileira de Computação. (Org.). **Inteligência Artificial**. 1ed. Porto Alegre: editora da Sociedade Brasileira de Computação - ESBC, 2004, v. 1, p. 1-50.

OLIVEIRA, A. C.; SALLES, T. T.; PEREIRA, B. L. C.; CARNEIRO, A. C. O.; BRAGA, C. S.; SANTOS, R. C. **Viabilidade Econômica da Produção do Carvão Vegetal em dois Sistemas Produtivos**. Floresta, Curitiba, PR, v. 44, n. 1, p. 143 – 152, jan. / mar. 2014.

OLIVEIRA, J. C.; **Modelagem de Crescimento e Produção de Povoamentos de Eucalipto Empregando Mínimos Quadrados Generalizados**. 2012. 75f. Dissertação (Mestrado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa, MG, 2012.

RODRIGUES, R. V.; CAMPOS, A. C. **Desempenho e Competitividade do Setor Siderúrgico Brasileiro na década de 90**. Revista de Economia, UEG, AnápolisGO, Vol. 4, no. 01, Jan-Jun/2008.

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

SEIXAS, F.; COUTO, L.; RUMMER, R. B., Colheita de Plantios Arbóreos de Curta Rotação para Energia, **RENABIO - Biomassa & Energia**, v. 3, n. 1, p. 116, 2006.

SFB – SERVIÇO FLORESTAL BRASILEIRO. **Florestas do Brasil em resumo: 2013**. Brasília: Serviço Florestal Brasileiro, 2013. 188p.

VAN LAAR, A.; AKÇA, A. **Forest Mensuration**. Gottingen, Germany: Cuvillier Verlag, 1997. 418p.

VELLASCO, M. M. B. R. **Redes neurais artificiais (notas de aula)**. Pontifícia Universidade Católica do Rio de Janeiro, 34p, 2007.

SANTOS, F. L.; **Regulação da produção de floresta de eucalipto submetida a desbaste e destinada a multiprodutos.** 2008. 92 f. Dissertação (Mestrado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa – MG, 2008.

SCOLFORO, J. R. **Crescimento e produção das variáveis dendrométricas.** In: \_\_\_\_\_ Biometria florestal: modelos de crescimento e produção florestal. Lavras: UFLA/FAEPE, 2006. p. 13-39.

SAE – Secretaria de Assuntos Estratégicos da Presidência da República. Notas Técnicas – SAE. Brasília, nº 01. 2014. 08p;

SOARES, P.; TOMÉ, M.; SKOVSGAARD, J. P.; VANCLAY, J. K. Evaluating a growth model for forest management using continuous forest inventory data. **Forest Ecology and Management**, Amsterdam, v. 71, n. 3 p. 251-265, Feb. 1995.

VANCLAY, J. K. **Modeling forest growth and yield:** applications to mixed tropical forest. Wallingford: CAB International, 1994. 312 p.