

ALINE EDWIGES MAZON DE ALCÂNTARA

**REDES NEURAIS ARTIFICIAIS PARA PROGNÓSE DO  
CRESCIMENTO E DA PRODUÇÃO DE POVOAMENTOS DE  
EUCALIPTO EM MINAS GERAIS**

Tese apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Ciência Florestal, para obtenção do título de *Doctor Scientiae*.

VIÇOSA  
MINAS GERAIS - BRASIL  
2015

**Ficha catalográfica preparada pela Biblioteca Central da Universidade  
Federal de Viçosa - Câmpus Viçosa**

T

A347r  
2015

Alcântara, Aline Edwiges Mazon de, 1984-

Redes neurais artificiais para prognose do crescimento e da  
produção de povoamentos de eucalipto em Minas Gerais / Aline  
Edwiges Mazon de Alcântara. – Viçosa, MG, 2015.

xiii, 43f. : il. ; 29 cm.

Orientador: Helio Garcia Leite.

Tese (doutorado) - Universidade Federal de Viçosa.

Inclui bibliografia.

1. Eucalipto - Crescimento. 2. Eucalipto - Produção.  
3. Redes neurais artificiais. I. Universidade Federal de Viçosa.  
Departamento de Engenharia Florestal. Programa de  
Pós-graduação em Ciência Florestal. II. Título.

CDD 22. ed. 634.973766

Aline Edwiges Mazon de Alcântara

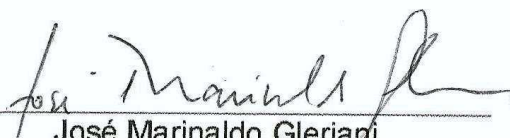
**REDES NEURAIS ARTIFICIAIS PARA PROGNÓSE DO  
CRESCIMENTO E DA PRODUÇÃO DE POVOAMENTOS DE  
EUCALIPTO EM MINAS GERAIS**

Tese apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Ciência Florestal, para obtenção do título de *Doctor Scientiae*.

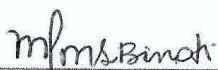
APROVADA: 20 de março de 2015.



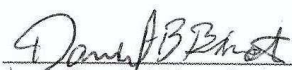
Carlos Pedro Boechat Soares  
(Coorientador)



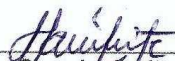
José Marinaldo Gleriani  
(Coorientador)



Mayra Luiza Marques da Silva Binoti



Daniel Henrique Breda Binoti



Helio Garcia Leite  
(Orientador)

*Aos meus pais, Edna e Robério, que me propiciaram uma vida digna onde eu pudesse crescer, acreditando que tudo é possível, desde que sejamos honestos, íntegros de caráter e tendo a convicção de que nunca devemos desistir.*

*“O ideal da vida não é a esperança de chegar a ser perfeito, mas a vontade de ser cada dia melhor”.*

## AGRADECIMENTOS

A Deus, pela vida e por todas as benções.

À Universidade Federal de Viçosa, em especial ao Departamento de Engenharia Florestal, pela oportunidade concedida.

Ao professor e amigo Helio Garcia Leite, pela ótima orientação, amizade, paciência, pela confiança depositada em mim e pelos valiosos ensinamentos, que são muito importantes na minha vida profissional.

Aos professores Carlos Pedro Boechat Soares e José Marinaldo Gleriani, pela coorientação e pelas contribuições.

À professora Mayra Luiza Marques da Silva Binoti, pelo apoio neste trabalho e pelas sugestões apresentadas.

Ao Daniel Henrique Breda Binoti, pelo constante apoio durante todo o trabalho, pela disponibilidade e amizade.

À professora Silvana Lages Garcia, pela torcida e pelo incentivo.

À secretaria de Pós-Graduação do Departamento de Engenharia Florestal, em especial ao Alexandre, pelos favores atendidos e pelas informações.

Ao Chiquinho, da Floresta, pelas belas palavras.

Aos meus pais, Edna e Robério, por todo amor, carinho, apoio e por caminharem ao meu lado em todos os momentos da minha vida, ensinando-me o valor do respeito, da disciplina e da responsabilidade e ensinando-me a ser uma pessoa melhor.

À minha irmã, Ana, ao meu cunhado, Luiz Fernando, e ao pequeno Rafael, pela amizade e pelo carinho e por estarem sempre torcendo por mim e participando da minha vida.

À Gabriela Tonazio, pelo carinho, pelo incentivo e pela torcida.

Aos meus grandes amigos, Ana Santelices, Aline Ramone, Amanda Martins, Camila Brás, Carla Coura, Carlos Tonazio, Cristina Godinho, Daniela Santana, Douglas Luís, Luana Gerçossimo, Marcos Rodrigues, Priscila Barros e Ricardo Neto, pois distantes ou não foram peças fundamentais e responsáveis por momentos inesquecíveis.

Aos meus “tios”, Rubinho e Cida, pela torcida e pelo carinho.

À equipe CENIBRA, pelo apoio e pela compreensão, em especial ao José Márcio Cardoso, Mauro Werneburg e Antonilmar da Silva.

À Kelen Karla, pela amizade e apoio na parte de geoprocessamento.

Às demais pessoas que, de alguma forma, contribuíram para a realização deste trabalho.

Minha gratidão e meu reconhecimento a todos, MUITO OBRIGADA!

## **BIOGRAFIA**

ALINE EDWIGES MAZON DE ALCÂNTARA, filha de Robério José de Alcântara e Edna Mazon de Alcântara, nasceu em 15 de setembro de 1984 na cidade de Viçosa, Minas Gerais.

Em março de 2006, ingressou no curso de Engenharia Florestal da Universidade Federal de Viçosa, Viçosa, MG, graduando-se em janeiro de 2010.

Em agosto de 2010, iniciou o Programa de Pós-Graduação em Ciência Florestal, em nível de mestrado, na área de Manejo Florestal, na Universidade Federal de Viçosa, Viçosa, MG, concluindo-o em 14 de fevereiro de 2012.

Em março de 2012, iniciou o Programa de Pós-Graduação em Ciência Florestal, em nível de doutorado, na área de Manejo Florestal, na Universidade Federal de Viçosa, Viçosa, MG, submetendo-se à defesa de tese em 20 de março de 2015.



## SUMÁRIO

|   | <b>Página</b> |
|---|---------------|
| LISTA DE TABELAS .....  | viii          |
| LISTA DE FIGURAS .....  | ix            |
| RESUMO .....  | xi            |
| ABSTRACT .....  | xiii          |
| 1. INTRODUÇÃO .....   | 1             |
| 2. OBJETIVOS .....  | 4             |
| 3. REVISÃO DE LITERATURA .....                                      | 5             |
| 3.1 Modelagem do crescimento e da produção .....                    | 5             |
| 3.2 Redes neurais artificiais.....                                  | 7             |
| 4. MATERIAL E MÉTODOS.....  | 13            |
| 4.1 Dados .....   | 13            |
| 4.1.1 Dados de Inventário Florestal Contínuo (IFC).....             | 13            |
| 4.1.2 Dados climáticos .....  | 13            |
| 4.2 Construção e aplicação das redes neurais.....                   | 16            |
| 4.2.1 Estudos 1, 2 e 3 .....  | 16            |
| 4.2.2 Estudos 4 e 5 .....   | 18            |
| 4.3 Treinamento e generalização das redes neurais artificiais ..... | 20            |
| 4.4 Avaliação das estimativas .....                                 | 20            |
| 5. RESULTADOS.....  | 22            |
| 5.1 Estudo 1 .....  | 22            |
| 5.2 Estudo 2 .....  | 22            |
| 5.3 Estudo 3 .....  | 25            |
| 5.4 Estudo 4 .....  | 25            |
| 5.5 Estudo 5 .....  | 28            |
| 6. DISCUSSÃO .....  | 37            |
| 7. CONCLUSÕES .....   | 40            |
| 8. REFERÊNCIAS BIBLIOGRÁFICAS .....                                 | 41            |

## LISTA DE TABELAS

|   | Página |
|---|--------|
| Tabela 1 – Valores mínimos, médios e máximos e desvio padrão da idade, altura dominante (m), área basal ( $\text{m}^2 \text{ha}^{-1}$ ) e volume ( $\text{m}^3 \text{ha}^{-1}$ ), em nível de parcela para a área do estado de Minas Gerais contempladas na base dos Estudos 1, 2 e 3 ..... | 14     |
| Tabela 2 – Amplitude e desvio-padrão das variáveis climáticas .....   | 16     |
| Tabela 3 – Variáveis de entrada (qualitativas e quantitativas) e variável de saída para os estudos 1 a 3 .....  | 17     |
| Tabela 4 – Percentual de treinamento e generalização para avaliação das redes neurais artificiais para os estudos 1 a 3 .....   | 17     |
| Tabela 5 – Variáveis de entrada (qualitativas e quantitativas) e variáveis de saída para os Estudos 4 e 5 .....   | 18     |
| Tabela 6 – Percentual de treinamento e generalização para avaliação das redes neurais artificiais para os Estudos 4 e 5 .....   | 20     |
| Tabela 7 – Raiz quadrada do erro quadrático médio (RQME) e correlação entre os volumes observados e estimados ( $\mathbf{r}_{y,\hat{y}}$ ) para o Estudo 1 .....  | 22     |
| Tabela 8 – Raiz quadrada do erro quadrático médio (RQME) e correlação entre os volumes observados e estimados ( $\mathbf{r}_{y,\hat{y}}$ ) para o Estudo 2 .....  | 25     |
| Tabela 9 – Raiz quadrada do erro quadrático médio (RQME) e correlação entre os valores observados e estimados ( $\mathbf{r}_{y,\hat{y}}$ ) para o Estudo 3 .....  | 28     |
| Tabela 10 – Raiz quadrada do erro quadrático médio (RQME) e correlação entre os volumes observados e estimados ( $\mathbf{r}_{y,\hat{y}}$ ) para o Estudo 4 .....   | 31     |

## LISTA DE FIGURAS

|  | <b>Página</b> |
|--|---------------|
| Figura 1 – Estrutura de um exemplo de rede neural artificial.....  | 8             |
| Figura 2 – Estrutura do neurônio biológico. ....   | 8             |
| Figura 3 – Estrutura do neurônio artificial .....  | 9             |
| Figura 4 – Principais funções de ativação nas RNA. ....  | 10            |
| Figura 5 – Representação da primeira e segunda etapa da metodologia do Polígono de Thiessen.....   | 14            |
| Figura 6 – Representação geral da metodologia do Polígono de Thiessen.....   | 15            |
| Figura 7 – Volumes observados <i>versus</i> estimados e correspondentes histogramas de frequência dos erros percentuais, utilizando 100, 50 e 40% dos dados para o treinamento das redes neurais artificiais, para o Estudo 1. ....  | 23            |
| Figura 8 – Volumes observados <i>versus</i> estimados e correspondentes histogramas de frequência dos erros percentuais, utilizando 30, 20 e 10% dos dados para o treinamento das redes neurais artificiais, para o Estudo 1. ....   | 24            |
| Figura 9 – Volumes observados <i>versus</i> estimados e correspondentes histogramas de frequência dos erros percentuais, utilizando 100, 50 e 40% dos dados para o treinamento das redes neurais artificiais, para o Estudo 2. ....  | 26            |
| Figura 10 – Volumes observados <i>versus</i> estimados e correspondentes histogramas de frequência dos erros percentuais, utilizando 30, 20 e 10% dos dados para o treinamento das redes neurais artificiais, para o Estudo 2.....   | 27            |
| Figura 11 – Volumes observados <i>versus</i> estimados e correspondentes histogramas de frequência dos erros percentuais, utilizando 100, 50 e 40% dos dados para o treinamento das redes neurais artificiais, para o Estudo 3. .... | 29            |
| Figura 12 – Volumes observados <i>versus</i> estimados e correspondentes histogramas de frequência dos erros percentuais, utilizando 30, 20 e 10% dos dados para o treinamento das redes neurais artificiais, para o Estudo 3.....   | 30            |
| Figura 13 – Volumes observados <i>versus</i> estimados e correspondentes histogramas de frequência dos erros percentuais, utilizando 100 e 95% dos dados para o treinamento das redes neurais artificiais, para o Estudo 4.....      | 31            |

|  |    |
|--|----|
| Figura 14 – Volumes observados <i>versus</i> estimados e correspondentes histogramas de frequência dos erros percentuais, utilizando 90 e 85% dos dados para o treinamento das redes neurais artificiais, para o Estudo 4..... | 32 |
| Figura 15 – Mapa da produtividade aos 7 anos (IMA7) para o Estado de Minas Gerais, utilizando a rede neural artificial do Estudo 5.....  | 33 |
| Figura 16 – Mapa da produtividade aos 6 anos (IMA6) para o Estado de Minas Gerais, utilizando a rede neural artificial do Estudo 5.....  | 34 |
| Figura 17 – Mapa da produtividade aos 6 anos (IMA6) para o Brasil, utilizando modelos fisiológicos.....  | 35 |
| Figura 18 – Destaque do estado de Minas Gerais no mapa de produtividade aos 6 anos de idade (IMA6), utilizando modelos fisiológicos.....   | 36 |

## RESUMO

ALCÂNTARA, Aline Edwiges Mazon, D.Sc., Universidade Federal de Viçosa, março de 2015. **Redes neurais artificiais para prognose do crescimento e da produção de povoamentos de eucalipto em Minas Gerais**. Orientador: Helio Garcia Leite. Coorientadores: Carlos Pedro Boechat Soares e José Marinaldo Gleriani.

O crescimento de um povoamento de eucalipto depende de vários fatores, como: genótipo, idade, qualidade do local e tratamentos silviculturais. Em relação à capacidade produtiva, os fatores ambientais mais relevantes são: a disponibilidade de água para as plantas ao longo dos anos, a temperatura e a radiação solar. Os modelos mais utilizados no Brasil, para estimar a produção futura de povoamentos florestais, são aqueles em nível de povoamento, que estimam o crescimento e, ou, a produção, fazendo uso de variáveis, como: idade, área basal e índice de local. Ferramentas utilizando inteligência artificial, como as redes neurais artificiais (RNA), vêm sendo utilizadas no setor florestal, em substituição aos modelos de regressão, apresentando superioridade de precisão das estimativas. Outra abordagem é o emprego de modelos processuais (ecofisiológicos), como o 3PG, que descrevem o crescimento das florestas baseando-se em processos que apresentam relações com os meios físicos e biológicos. O objetivo deste estudo foi aplicar e validar redes neurais artificiais e propor uma nova metodologia para prognose do crescimento e da produção, além de gerar mapas de classes de produtividade aos 6 e 7 anos de idade para todo o Estado de Minas Gerais. Os dados utilizados foram provenientes de parcelas permanentes de inventários florestais contínuos (IFC) conduzidos em povoamentos de eucalipto em diferentes regiões de Minas Gerais, e de informações climáticas obtidas de estações distribuídas pelas áreas de plantio. Foram avaliadas três situações. Na primeira, as redes foram avaliadas com a utilização de dados de inventários, informações do tipo de solo e dados de variáveis climáticas; na segunda situação, foram utilizados apenas os dados de inventário; e na terceira, foram utilizados apenas os dados de variáveis climáticas e as informações do tipo de solo. Esta última situação é importante por tornar possível a prognose em locais sem base de dados de IFC e, ou, sem plantios. Para uma grande e abrangente base de dados, empregar

somente *inputs* contidos na base de dados de IFC ou dados de IFC somados aos dados climáticos, resulta em exatidão e consistência satisfatórias, porém, neste último caso é possível considerar efeitos naturais fora do comportamento padrão e das simulações destes efeitos. O emprego de redes neurais resultou em maior detalhamento da produtividade no Estado de Minas Gerais, quando comparado com mapas de produtividade obtidos empregando modelos processuais.

## ABSTRACT

ALCÂNTARA, Aline Edwiges Mazon, D.Sc., Universidade Federal de Viçosa, March of 2015. **Artificial neural networks for prognosis of growth and yield of eucalyptus stands in Minas Gerais.** Adviser: Helio Garcia Leite. Co-advisers: Carlos Pedro Boechat Soares and José Marinaldo Gleriani.

The development of a eucalyptus stand depends on several factors, such as genotype, age, site quality and silvicultural treatments. The most relevant environmental factors related to yielding capacity are: *plant water availability along the years, temperature and solar radiation*. The most used models to estimate the future yield of forest stands in Brazil are those measuring stand growth, and/or yield, using variables such as age, basal area, and site index. Artificial intelligence tools, such as the artificial neural networks (ANNs) have been utilized in the forest sector, as a replacement to regression models, presenting superior estimate precision. Another approach is the use of processual (eco-physiological) models, such as the 3PG, which describe the growth of forests based on physical and biological media processes. This study aimed to apply and validate artificial neural networks and propose a new methodology for prognosis of stand growth and yield, as well as generate maps showing yield classes at 6 and 7 years of age for the state of Minas Gerais. The data used in this study were originated from permanent plots of continuous forest inventories (CFI) conducted in eucalyptus stands in different regions of Minas Gerais, and on climatic information obtained from stations located at the planting areas. Three situations were assessed: in the first, the neural networks were evaluated by using the inventory data, soil type and climatic variables data. In the second, only the inventory data were used, and in the third, only the climatic variable and soil type data. The third situation is important for allowing prognosis in places without CFI data base, and, or, without plantations. In the case of a large and comprehensive data base, only CFI database inputs, combined with the climatic data, should be used; however, in this case, it is possible to consider natural effects outside the standard behavior and simulation of these effects. The use of neural networks has resulted in more precise yield details in the State of Minas Gerais, compared with yield maps obtained through processual models.

# 1. INTRODUÇÃO

A madeira de eucalipto é uma importante matéria-prima para uso em movelaria, com destaque para a produção de celulose e carvão vegetal. No caso de movelaria, grande parte da madeira utilizada ainda é proveniente de florestas naturais (inequiâneas), muitas vezes exploradas de forma predatória, porém recentemente os povoamentos equiâneos têm sido utilizados como fontes alternativas, diminuindo a pressão sobre as florestas inequiâneas.

Para o manejo dessas florestas é necessário conhecer o potencial produtivo de cada compartimento, ou unidade de manejo, e projetar estoques de crescimento e de colheita (prognose), auxiliando o manejador florestal a tomar decisões de quando, quanto, onde e como colher a madeira dos povoamentos florestais.

O crescimento de um povoamento florestal depende do material genético, da idade, da capacidade produtiva, do grau de utilização do potencial produtivo do local e de tratamentos silviculturais (CAMPOS; LEITE, 2013). Em relação à capacidade produtiva, os fatores ambientais mais relevantes são: a disponibilidade de água para as plantas ao longo dos anos, a temperatura e a radiação solar.

A dinâmica desse crescimento pode ser conhecida empregando métodos que envolvam observações feitas no povoamento, ou métodos que utilizam tabelas, equações ou modelos de simulação de crescimento e produção (AVERY; BURKHART, 1994; CAMPOS; LEITE, 2013).

Existem três tipos principais de modelos de crescimento e produção: modelos em nível de povoamento, modelos em nível de árvores individuais (MAI) e modelos de distribuição diamétrica (MDD).

Os modelos mais utilizados no Brasil são aqueles em nível de povoamento, envolvendo relações do tipo:  $V = f(I)$ ,  $V = f(I, S)$  e  $V = f(I, S, B)$ , sendo  $V$  o volume por hectare,  $B$  a área basal por hectare,  $S$  o índice de local e  $I$  a idade do povoamento (CAMPOS; LEITE, 2013).

Em modelos em nível de árvores individuais, cada árvore é estudada separadamente, considerando as suas características individuais, a capacidade



produtiva do local em que se encontra e as condições de competição a que está submetida (HASENAUER, 2000).

Em modelos de distribuição de diâmetros, são empregadas distribuições estatísticas para descrever a distribuição de diâmetro em diferentes locais e idades (CAMPOS; LEITE, 2013). Os parâmetros da distribuição estatística são correlacionados com atributos ou variáveis dos povoamentos, resultando em sistemas de equações. Esses sistemas permitem estimar crescimento e produção por classe de tamanho, quantificar multiprodutos, avaliar economicamente a conversão de árvores em multiprodutos e simular desbastes (BURKHART; CAO; WARE, 1981).

Independentemente do tipo de modelo de crescimento e produção, a modelagem sempre envolve o emprego de modelos de regressão, linear ou não linear (CAMPOS; LEITE, 2013). No entanto ferramentas utilizando inteligência artificial como as redes neurais artificiais (RNA), vêm sendo utilizadas no setor florestal, em substituição aos modelos de regressão, apresentando superioridade de precisão das estimativas (GORGENS, 2006; SILVA; BINOTI, GLERIANI, 2009).

Segundo Bullinaria (2014), RNA são redes de neurônios artificiais distribuídos de forma paralela (em camadas) e conectados entre si de uma maneira específica para executar determinada tarefa.

Uma outra abordagem para estimar a produção futura é o emprego de modelos processuais, em especial, os ecofisiológicos, como o 3PG. Modelos ecofisiológicos descrevem o crescimento das florestas baseando-se em processos que apresentam relações com o meio físico (solo e clima) e biológico (materiais genéticos e fisiologia da planta).

No trabalho de Borges (2012), foi desenvolvido um modulador baseado na análise foliar, incorporando os efeitos do solo sobre a produtividade, para uso em modelos ecofisiológicos de crescimento florestal. A construção desses modelos demanda dados de experimentos dirigidos, enquanto as RNA podem ser treinadas empregando dados de parcelas de inventários florestais contínuos e temporais juntamente com medições climáticas, edáficas e fisiográficas já disponíveis no Brasil.

Os problemas tratáveis através de redes neurais enquadram-se nas tarefas de aprendizagem: aproximação de função, classificação de padrões,

agrupamento de dados, predição (séries temporais), otimização, recuperação de conteúdo e controle (JAIN; MAO; MOHIUDDIN, 1996; HAYKIN, 2001).

Para agrupamento de dados para fins de modelagem do crescimento de povoamentos é necessário considerar características como: tipo de solo, clima, precipitação, dentre outros. Porém, a inclusão de variáveis categóricas, como tipo de solo, em modelos de regressão, além de não ser trivial, muitas vezes é de fato impossível, devido à falta de representatividade para fins de ajuste de regressão, ou seja, deficiência em termos de amostragem. Uma possibilidade seria estratificar a população ao máximo, empregando estas variáveis categóricas como critérios de estratificação, mas isto resulta em alto custo, muitas vezes não sendo factível. Daí resulta a necessidade e possibilidade de uso de modelos de inteligência computacional, como as redes neurais artificiais, onde a estimação é feita com base em variáveis dendrométricas, edáficas, climáticas e fisiográficas, sem a necessidade de grande quantidade de observações por combinações dessas variáveis categóricas.

Como as RNA permitem a utilização de um grande número de variáveis edáficas, climáticas e fisiográficas, em uma mesma rede, este estudo é de alto interesse para prognose do crescimento e da produção e conseqüentemente para tomada de decisões. Dependendo da abrangência da amostragem, este tipo de abordagem permite, também, simular o efeito de déficit hídrico ou secas críticas, sobre o crescimento e produção.

## **2. OBJETIVOS**

Diante do exposto anteriormente, esta tese teve por objetivos:

- Propor uma alternativa para prognose do crescimento e da produção que considere variáveis de povoamento, cadastro, fisiográficas, climáticas e edáficas.
- Gerar e validar modelos de redes neurais artificiais para prognose do crescimento e da produção de povoamentos de eucalipto no Estado de Minas Gerais.
- Gerar mapas de classes de produtividade de povoamentos de eucalipto aos seis e sete anos de idade para todo o Estado de Minas Gerais.

### 3. REVISÃO DE LITERATURA

#### 3.1 Modelagem do crescimento e da produção

A modelagem do crescimento e da produção é um processo dinâmico e os bancos de dados de parcelas permanentes devem ser atualizados e consistidos para este fim e para a classificação da capacidade produtiva. A amostragem para essa modelagem deve ser representativa, abrangendo condições intermediárias e extremas de capacidade produtiva (OLIVEIRA, 2007). Segundo este autor, uma metodologia para construir um modelo de crescimento e produção envolve a definição do objetivo, a obtenção dos dados, a escolha do modelo, a aplicação de testes de validação do modelo e a sua aplicação.

Vários trabalhos no Brasil já foram feitos conduzidos para estimar crescimento e produção de povoamentos equiâneos, como Gordon (1998), Soares (1999), Oliveira (2007), Binoti (2010), Novaes (2009), Silva (2009), Sales (2010), Castro (2011), Martins *et al.* (2011), Alcantara (2012), Binoti *et al.* (2012, 2014).

Os modelos de crescimento e produção podem ser em nível de distribuição de diâmetros, em nível de árvores individuais ou em nível de povoamento, podendo ser de predição ou de projeção. Exemplos de modelos dessas categorias são encontrados em Campos e Leite (2013).

Binoti *et al.* (2014) utilizou redes neurais artificiais para estimar parâmetros da distribuição Weibull, para projeção de distribuição diamétrica de povoamentos equiâneos e comparou com modelos comumente utilizados no setor florestal. As redes neurais apresentaram resultados superiores aos modelos usuais.

Binoti *et al.* (2012) apresentou um modelo de distribuição diamétrica baseado em um modelo de Autômatos Celulares (AC) unidimensionais e redes neurais artificiais (RNA) para a simulação de desbaste. O enfoque de modelagem proposto permitiu estimar distribuições de diâmetro futuras com exatidão.

Estudos sobre modelos de árvore individual são mais escassos no Brasil. Uma abordagem consistente deste tipo de modelagem é encontrada em Martins *et al.* (2011), onde foi ajustado um modelo completo de crescimento para plantios comerciais utilizando dados de inventário florestal contínuo de plantios clonais híbridos não desbastados de *Eucalyptus grandis* x *Eucalyptus urophylla* no estado do Pará.

Castro (2011), também modelou o crescimento e a produção de povoamentos de eucalipto em nível de árvores individuais, utilizando regressão, redes neurais artificiais (RNA) e autômatos celulares (AC). O autor concluiu que RNA e a estrutura de AC forneceram estimativas de maior exatidão em relação às obtidas por modelos de regressão.

A maioria dos estudos desenvolvidos envolve a modelagem em nível de povoamento. O modelo em nível de povoamento mais utilizado no Brasil, nos meios acadêmicos e práticos, é o modelo de Clutter, o qual expressa a produção em função das idades atual e futura, do índice de local na idade atual e das áreas basais atual e futura (CAMPOS; LEITE, 2013).

Alcantara (2012) utilizou dados de parcelas permanentes de eucalipto e propôs algumas abordagens para modelagem em nível de povoamento, além de avaliar algumas já existentes. Os modelos e as abordagens desenvolvidos foram aplicados e os resultados foram comparados com a opção do emprego do modelo de Clutter na sua forma mais usual.

Salles (2010), utilizando dados de clones de eucalipto em um sistema agroflorestal, testou a contribuição de todas as variáveis do modelo de Clutter, sendo definidos sistemas de equações específicas, para cada clone. O autor demonstrou a importância do emprego do modelo de Clutter na sua forma original, testada por Clutter (1963), seguida da análise da contribuição estatística de cada variável do sistema de equações.

No estudo de Novaes (2009), foi demonstrado o emprego de dados de análise de tronco para ajuste dos modelos de Buckman (1962) e de Clutter (1963), além de um modelo em nível de árvores individuais. Esse estudo foi conduzido com dados de povoamentos de teca. Silva (2009) também utilizou dados de teca (parcelas permanentes) para simular alternativas de amostragem visando o ajuste do modelo de Clutter. Este autor demonstrou que a amostragem relativa é eficiente para obter dados para modelagem.

No trabalho de Oliveira (2007), foram propostas e sugeridas alternativas para modelagem do crescimento de povoamentos de clones de eucalipto quando ocorre limitação no número de medições das parcelas permanentes. Também utilizando dados de povoamentos de clones de eucalipto.

Soares (1999) incluiu a variável precipitação defasada no modelo de Clutter, resultando na possibilidade de se fazer prognose otimista, pessimista e mais provável, bem como simular o efeito dessa variável climática no crescimento de povoamentos de eucalipto.

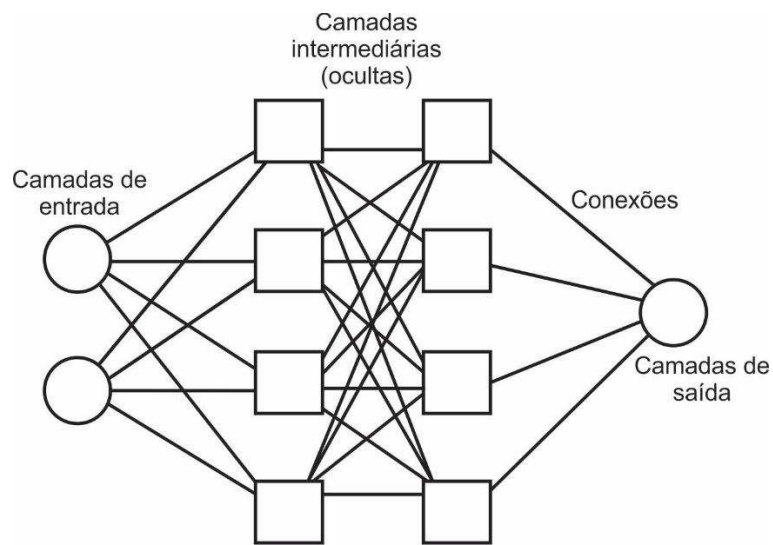
Já no trabalho de Gordon (1998), foi feita a comparação entre a metodologia de redes neurais artificiais bayesianas com modelos tradicionais do crescimento e produção florestal. Neste trabalho, as redes neurais também apresentaram resultados superiores.

No trabalho de Binoti (2010), utilizando redes neurais artificiais com dados de clones de eucalipto do Sul da Bahia, foram utilizadas variáveis numéricas, como idade, área basal, dap, altura total, volume e variáveis categóricas, como classe de solo, textura, tipos de espaçamento, relevo, projeto e clone. As RNA apresentaram resultados satisfatórios em ambos os níveis, povoamento total e árvore individual, comprovando o potencial e aplicabilidade da técnica na solução dos problemas do manejo florestal e processos de tomada de decisão.

### **3.2 Redes neurais artificiais**

O desenvolvimento da área de redes neurais artificiais é motivado pela maneira como o cérebro humano processa informações, sendo capaz de organizar seus neurônios (unidades estruturais) de forma a desempenhar determinados processamentos, como reconhecimento de padrões, muito mais rápido e eficiente que um computador convencional (HAYKIN, 2001).


Uma rede neural artificial (Figura 1) é uma rede de neurônios artificiais. É um sistema computacional paralelo constituído de várias unidades de processamento simples conectadas entre si de uma maneira específica para desempenhar uma determinada tarefa (BULLINARIA, 2014).



Fonte: Binoti (2010).

Figura 1 – Estrutura de um exemplo de rede neural artificial.

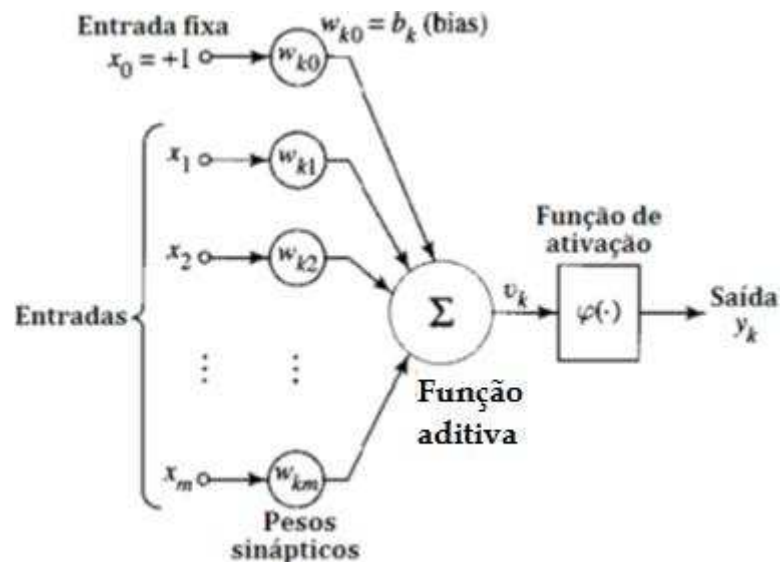
O neurônio biológico (Figura 2) pode ser dividido em três partes: o corpo celular, os dendritos e o axônio. Os dendritos são ramificações que recebem as informações, na forma de impulsos nervosos, oriundas de outros neurônios e as conduzem para o corpo celular. Este processa as informações gerando novos impulsos nervosos que são transmitidos através do axônio aos dendritos de outros neurônios (SILVA; SPATTI; FLAUZINO, 2010).



Fonte: Ferneda (2006).

Figura 2 – Estrutura do neurônio biológico.

Em 1943, o primeiro modelo de neurônio artificial foi proposto pelo psiquiatra e neuroanatomista Warren McCulloch e pelo matemático Walter Pitts (McCULLOCH; PITTS, 1943). Este é uma simplificação do que se sabia a respeito do neurônio biológico na época. Atualmente, a representação para um neurônio básico artificial, conforme Haykin (2001), é ilustrada na Figura 3.



Fonte: adaptada de Haykin (2001).

Figura 3 – Estrutura do neurônio artificial

Segundo Silva, Spatti e Flauzino (2010), o funcionamento deste tipo de neurônio ocorre da seguinte forma:

1. a rede recebe um sinal ( $x_m$ ) vindo do meio externo e que representam os valores assumidos pelas variáveis de uma aplicação específica. Geralmente estes sinais de entrada são normalizados visando incrementar a eficiência computacional dos algoritmos de aprendizagem;

2. cada uma das entradas ( $x_m$ ) do neurônio é executada por meio de suas multiplicações pelos respectivos pesos sinápticos ( $w_{km}$ ), permitindo-se quantificar as suas relevâncias em relação à funcionalidade do respectivo neurônio;

3. todos os sinais de entrada que foram ponderados pelos respectivos pesos sinápticos são agregados pela função aditiva a fim de produzir um valor de potencial de ativação;




4. o limiar de ativação é uma variável que especifica qual será o patamar apropriado para que o resultado produzido pela função aditiva possa gerar um valor de disparo em direção à saída do neurônio;

5. em seguida, é feita a aplicação de uma função de ativação apropriada, tendo-se como objetivo limitar a saída do neurônio; e

6. por último, ocorre a compilação da saída a partir da aplicação da função de ativação neural em relação ao seu potencial de ativação.

Resumindo matematicamente, um neurônio artificial  $k$  pode ser descrito por:  $y_k = \varphi(\vartheta_k)$ ; em que  $y_k$  é a saída do neurônio artificial;  $\varphi(\cdot)$  é a função de ativação; e  $\vartheta_k$  é o resultado da função aditiva.

Conforme Haykin (2001), a função de ativação é uma função matemática que aplicada à combinação linear entre as variáveis de entrada e os pesos que chegam ao neurônio, retorna à variável de saída. A função de ativação limita as entradas a uma amplitude finita, a qual geralmente ocorre dentro do intervalo de 0 a 1. Existem três tipos básicos de função de ativação: função de limiar (a); função linear por partes (b); e função sigmoide (c) (Figura 4).



Fonte: Castro (2011).

Figura 4 – Principais funções de ativação nas RNA.

As redes neurais artificiais podem ser classificadas quanto ao número de camadas: rede de camada única (apresentam apenas uma camada de neurônios de processamento) e rede de múltiplas camadas (apresentam uma ou mais camadas de neurônios intermediárias, ou seja, camadas que se encontram entre a camada de entrada e a camada de saída). Quanto ao tipo

de conexões: rede do tipo *feedforward* (redes acíclicas) ou *feedback* (cíclicas, ou seja, possuem pelo menos uma conexão de realimentação). E quanto à conectividade: rede totalmente conectada (cada neurônio de uma camada está conectado a todos os neurônios da camada seguinte) e rede parcialmente conectada (falta alguma conexão na rede) (BULLINARIA, 2014).

Os principais modelos de RNA utilizados para fins de previsão de variáveis contínuas são as redes MPL (*Multilayer Perceptron*) (HAYKIN, 2001). Um Perceptron de múltiplas camadas (MLP) possui uma ou mais camadas ocultas (intermediárias), além da camada de entrada e de saída. Os sinais de entrada propagam para frente através da rede, camada por camada, ou seja, são classificadas como *feedforward*.

O treinamento é do tipo supervisionado com o algoritmo de retropropagação do erro (*ErrorBackPropagation*), com base na regra de aprendizagem por correção do erro.

Segundo Heaton (2011), o algoritmo de retropropagação (*ErrorBackPropagation*) é o algoritmo mais usado em aprendizagem supervisionada em redes neurais artificiais de múltiplas camadas. A ideia básica do algoritmo de aprendizagem de retropropagação é a repetição da aplicação de uma cadeia de regras para calcular a influência de cada peso da rede com respeito à arbitrariedade da função de erro. Algoritmos tais como o de retropropagação, utilizam a “descida do gradiente” para ajustar os parâmetros das redes para melhor adaptar um conjunto de treinamento de pares entrada e saída.

Vários outros algoritmos de adaptação da aprendizagem foram desenvolvidos para lidar com o problema de calcular o valor apropriado dos pesos, um desses algoritmos é o *Resilient Propagation* (RPROP), o qual efetua a adaptação direta do peso, baseado na informação do gradiente local, não sendo esta adaptação influenciada pelo comportamento do gradiente. Ele apresenta um desempenho melhor do que o algoritmo de retropropagação do erro, pois ele necessita de um número menor de iterações para convergir para uma solução com uma determinada taxa de erro (HEATON, 2011).

Os estudos na área de RNA se justificam por diversas propriedades úteis e capacidades das redes como: não linearidade (propriedade importante, principalmente se o mecanismo físico responsável pela geração do sinal de

entrada for inerentemente não linear), adaptabilidade (uma rede treinada para operar em um ambiente específico pode ser retreinada para lidar com modificações, e atuando em ambiente não estacionário, uma rede pode ser projetada para modificar seus pesos em tempo real), tolerância a falhas e ruídos, aprendizagem e generalização a partir de dados de treinamento, paralelismo que as tornam muito eficientes, uniformidade de análise e projeto e analogia neurobiológica (HAYKIN, 2001; BRAGA; CARVALHO; LUDEMIR, 2007; BULLINARIA, 2014).

## 4. MATERIAL E MÉTODOS

### 4.1 Dados

Os dados utilizados neste estudo foram provenientes de parcelas permanentes de inventários florestais contínuos, conduzidos em povoamentos de eucalipto localizados em diferentes municípios do Estado de Minas Gerais. Esses dados foram cedidos por empresas florestais e os povoamentos contemplados estão localizados ao Norte, Centro e Sul do Estado, num total de 12.293 parcelas.

Os dados em nível de árvore foram processados pelas próprias empresas, sendo geradas estimativas por parcela e ano de medição.

Todas as informações dos cadastros foram padronizadas e foram criados seis níveis hierárquicos de divisão de áreas (Regional, Região, Sub-região, Projeto, Lote e Talhão), sendo o talhão a menor unidade de área. As informações contidas nos cadastros foram: Município, data de plantio, espaçamento, material genético, solo predominante e rotação.

#### 4.1.1 Dados de Inventário Florestal Contínuo (IFC)

Os dados foram processados em nível de parcela, contemplando as seguintes variáveis: idade (meses), média das alturas das árvores dominantes (m), área basal ( $\text{m}^2 \text{ha}^{-1}$ ) e volume comercial com casca ( $\text{m}^3 \text{ha}^{-1}$ ), para um diâmetro superior maior ou igual a 4 cm ( $V_{4cc}$ ) (Tabela 1). Foram utilizadas 12.293 parcelas com aproximadamente 300  $\text{m}^2$  de área, com medições realizadas anualmente.

#### 4.1.2 Dados climáticos

Além dos dados de inventário florestal, foram somadas à base de dados, informações climáticas da área em estudo obtidas de estações climáticas distribuídas na região de estudo.

Tabela 1 – Valores mínimos, médios e máximos e desvio padrão da idade, altura dominante (m), área basal ( $\text{m}^2 \text{ha}^{-1}$ ) e volume ( $\text{m}^3 \text{ha}^{-1}$ ), em nível de parcela para a área do estado de Minas Gerais contempladas na base dos Estudos 1, 2 e 3

| Variáveis                                  | Amplitude |          |        | Desvio-Padrão |
|--|-----------|----------|--------|---------------|
|  | Mínima    | Máxima   | Média  |               |
| Idade (meses)                              | 11,97     | 357,34   | 61,17  | 35,18         |
| Altura dominante (m)                       | 6,00      | 69,93    | 24,44  | 6,59          |
| Área basal ( $\text{m}^2 \text{ha}^{-1}$ ) | 0,70      | 58,91    | 18,37  | 6,92          |
| Volume ( $\text{m}^3 \text{ha}^{-1}$ )     | 3,80      | 1.158,42 | 197,16 | 115,75        |

Neste trabalho foram processadas as médias anuais das informações climáticas no período entre os anos de 2006 a 2013. Os dados das estações climáticas, conectadas por suas respectivas coordenadas geográficas, foram processados no *software* Arcgis® para toda a base do cadastro com o intuito de extrapolar as informações para cada talhão por meio da metodologia do polígono de Thiessen.

A metodologia do polígono de Thiessen define áreas de “domínio” de um ponto de referência. Considera-se que as variáveis são as mesmas no interior dessas áreas de domínio de cada ponto de referência.

Os polígonos são traçados da seguinte forma:

1. dois postos adjacentes são ligados por um segmento de reta;
2. traça-se a mediatriz deste segmento de reta. Esta mediatriz divide para um lado e para outro, as regiões de “domínio”;




Figura 5 – Representação da primeira e segunda etapa da metodologia do Polígono de Thiessen.

3. este procedimento é realizado, inicialmente, para um ponto qualquer o ligando aos adjacentes. Define-se, desta forma, o polígono do primeiro ponto; e
4. repete-se o mesmo procedimento para todos os pontos.




Figura 6 – Representação geral da metodologia do Polígono de Thiessen.

As variáveis climáticas utilizadas no estudo (Tabela 2) foram:

- precipitação (mm): mínima, média, máxima e anual de 2007 a 2013;
- temperatura (C°): mínima, média e máxima;
- umidade relativa (%);
- velocidade do vento (m/s);
- radiação total (MJ/m<sup>2</sup>/dia);
- radiação parcial (mmol/m<sup>2</sup>);
- déficit hídrico (mm); e
- déficit de pressão de vapor (DPV (hPa)).

Foram utilizadas também informações obtidas através da classificação de Köppen-Geiger, conhecida por classificação climática de Köppen, a qual considera a sazonalidade e os valores médios anuais e mensais de temperatura e precipitação (KÖPPEN; GEIGER, 1928).

Tabela 2 – Amplitude e desvio-padrão das variáveis climáticas

| Variáveis                               | Ano  | Mínimo    | Média     | Máximo    | Desvio-Padrão |
|---|------|-----------|-----------|-----------|---------------|
| Temperatura (°C)                        |      | 14,69     | 19,85     | 29,69     | 3,82          |
| Umidade relativa (%)                    |      | 72,77     | 77,83     | 81,83     | 2,74          |
| Médias anuais de precipitação (mm)      | 2007 | 20,08     | 69,68     | 114,61    | 20,50         |
|   | 2008 | 19,86     | 107,23    | 162,56    | 30,10         |
|   | 2009 | 19,98     | 115,68    | 160,86    | 37,62         |
|   | 2010 | 72,77     | 77,83     | 81,83     | 2,74          |
|   | 2011 | 18,52     | 115,73    | 179,84    | 38,68         |
|   | 2012 | 19,78     | 83,01     | 109,55    | 23,10         |
|   | 2013 | 19,32     | 122,26    | 190,50    | 40,99         |
| Velocidade do vento (m/s)               |      | 1,27      | 2,97      | 4,30      | 1,02          |
| Radiação total (MJ/m <sup>2</sup> /dia) |      | 12,88     | 14,81     | 17,23     | 1,53          |
| Radiação parcial (mml/m <sup>2</sup> )  |      | 31.020,52 | 32.979,50 | 34.721,94 | 1.256,72      |
| Déficit hídrico (mm)                    |      | 8,76      | 14,92     | 24,57     | 5,57          |
| DPV (hPA)                               |      | 4,10      | 5,98      | 8,41      | 1,55          |

## 4.2 Construção e aplicação das redes neurais

Para gerar e validar os modelos de redes neurais artificiais para prognose foram realizados cinco estudos conforme descritos abaixo.

### 4.2.1 Estudos 1, 2 e 3

Para uma primeira abordagem de modelagem e prognose, os dados foram organizados com as informações de cada ano de medição pareadas com todos os demais, para cada parcela, ou seja, IFC1-IFC2, IFC1-IFC3,..., IFC2-IFC3, IFC2-IFC4 e assim sucessivamente.

No Estudo 1, foram consideradas as variáveis dos inventários (IFCs), tipo de solo e climáticas. Já no Estudo 2, foram considerados apenas os dados dos IFCs e no estudo 3 foram considerados os dados climáticos e o tipo de solo, conforme a Tabela 3.

Para cada estudo foram avaliadas seis situações variando de forma aleatória a porcentagem dos dados selecionados para o treinamento (aprendizagem) e para generalização das redes (Tabela 4). Aqui, por se tratar de uma base de dados grande e abrangente, a seleção aleatória não afeta a representatividade das amostras selecionadas.

Tabela 3 – Variáveis de entrada (qualitativas e quantitativas) e variável de saída para os estudos 1 a 3

| Estudo | Entrada           |                  | Saída                                      |
|--------|-------------------|------------------|--|
|        | Qualitativas      | Quantitativas    |  |
| 1      | Sub-região        | IFC + Climáticas | Vol (m <sup>3</sup> /ha ha <sup>-1</sup> ) |
|        | Espaçamento       |                  |  |
|        | Material genético |                  |  |
|        | Rotação           |                  |  |
|        | Solo predominante |                  |  |
|        | Clima             |                  |  |
| 2      | Sub-região        | IFC              | Vol (m <sup>3</sup> /ha ha <sup>-1</sup> ) |
|        | Espaçamento       |                  |  |
|        | Material genético |                  |  |
|        | Rotação           |                  |  |
| 3      | Sub-região        | Climáticas       | Vol (m <sup>3</sup> /ha ha <sup>-1</sup> ) |
|        | Espaçamento       |                  |  |
|        | Material genético |                  |  |
|        | Rotação           |                  |  |
|        | Solo predominante |                  |  |
|        | Clima             |                  |  |

Tabela 4 – Percentual de treinamento e generalização para avaliação das redes neurais artificiais para os estudos 1 a 3

| Situação | Porcentagem de Dados Utilizados no Treinamento (%) | Porcentagem de Dados Utilizados na Generalização (%) |
|----------|--|--|
| 1        | 100  | 0  |
| 2        | 50   | 50   |
| 3        | 40   | 60   |
| 4        | 30   | 70   |
| 5        | 20   | 80   |
| 6        | 10   | 90   |

As variáveis do IFC (*Hd*, *B* e *Vol*), apresentam variação em nível de parcela, ou seja, para cada parcela em diferentes medições, existe um determinado valor. Já as variáveis climáticas, apresentam variação em nível de talhão, ou seja, todas as parcelas existentes em um mesmo talhão possuem valores iguais, independentemente da medição. Desta forma, como o estudo 1 e 2 apresentam variáveis de IFC como variáveis de entrada, as análises do



treinamento e de generalização foram feitas em nível de parcela. Já para o estudo 3 as variáveis de IFC não foram utilizadas como variáveis de entrada, apenas o volume foi utilizado no treinamento, por isso a análise de generalização foi feita em nível de talhão e o treinamento em nível de parcela.

#### 4.2.2 Estudos 4 e 5

Em uma segunda abordagem, o objetivo foi avaliar a eficiência da prognose incluindo tipo de solo e variáveis climáticas, além de avaliar a consistência de extrapolações feitas para todo o estado de Minas Gerais.

Foram selecionados da base de IFC somente as parcelas com idade igual a 7 anos (Estudo 4 e 5), com variação entre 78,1 e 90 meses e parcelas com idade igual a 6 anos (Estudo 5), com variação entre 66 e 78 meses. Na Tabela 5 são apresentadas as variáveis utilizadas nos Estudos 4 e 5.

Tabela 5 – Variáveis de entrada (qualitativas e quantitativas) e variáveis de saída para os Estudos 4 e 5

| Estudo | Entrada           |  | Saída   |
|--------|-------------------|--|---|
|        | Qualitativas      | Quantitativas  |   |
| 4      | Sub-região        | Climáticas   | Vol 7 anos<br>(m <sup>3</sup> /ha <sup>-1</sup> )     |
|        | Espaçamento       |  |   |
|        | Material genético |  |   |
|        | Rotação           |  |   |
|        | Solo predominante |  |   |
|        | Clima             |  |   |
| 5      | Clima             | Altitude + Temperaturas<br>(mínima, média e máxima)<br>+ Precipitações (mínima,<br>média e máxima) | Vol 6 e 7 anos<br>(m <sup>3</sup> /ha <sup>-1</sup> ) |

Assumiu-se que o incremento médio anual aos sete anos (IMA7), é a média das produtividades observadas em idades entre 78,1 e 90 meses e o incremento médio anual aos seis anos (IMA6), entre 66 e 78 meses.

O objetivo do Estudo 4 foi gerar redes para estimar o IMA7, sem dados de IFC como variáveis de entrada, para a base incluída na amostragem.

O objetivo do Estudo 5 foi gerar redes para estimar o IMA6 e IMA7 sem dados de IFC como variáveis de entrada, para todos os municípios do estado de Minas Gerais, utilizando as informações de temperatura, precipitação e clima (classificação de Köppen-Geiger), fornecidas em <<http://www.ipef.br/geodatabase/>>, já que a base de amostragem não possui parcelas em todos os municípios do estado. O *software* utilizado para gerar o mapa foi o *software* Arcgis®.

Em um trabalho conduzido por Borges (2012), foi desenvolvido um modulador baseado na análise foliar, incorporando os efeitos do solo sobre a produtividade, para uso em modelos ecofisiológicos de crescimento florestal. Com base nesta metodologia, o autor apresenta em seu trabalho um mapa para todo o Brasil da produtividade de madeira de eucalipto aos 6 anos de idade (IMA6).

Foi feita uma comparação entre os mapas de produtividade (IMA6) gerados a partir da metodologia das redes neurais artificiais (Estudo 5) com mapas de produtividade (IMA6) gerados a partir da metodologia de modelos ecofisiológicos apresentado no trabalho de Borges (2012). Desta forma, para efeito de comparação entre estes dois mapas, a metodologia de definição das classes de produtividades utilizando a metodologia de RNA foi a mesma adotada por Borges (2012). Cabe observar que maiores produtividades aos 6 anos obtidas por Borges (2012) são produtividades potenciais, enquanto as produtividades obtidas no presente estudo são produtividades reais, considerando o nível das práticas silviculturais e manejo utilizados nos últimos anos.

Como em ambos os estudos a base de dados foi reduzida, ou seja, só foram utilizadas variáveis dentro de uma determinada faixa de idade (6 e 7 anos), foram definidas e avaliadas três situações de porcentagens de redução da base dos dados, de forma aleatória, para o treinamento (Tabela 6).

O treinamento das redes para os dois estudos foi feito em nível de parcela, uma vez que a variável de saída volume apresentava variação em nível de parcela. A generalização foi feita em nível de talhão, porque as variáveis climáticas, utilizadas na base de treinamento da rede, apresentam variação apenas em nível de talhão.

Tabela 6 – Percentual de treinamento e generalização para avaliação das redes neurais artificiais para os Estudos 4 e 5

| Situação | Porcentagem de Dados utilizados no Treinamento (%) | Porcentagem de Dados Utilizados na Generalização (%) |
|----------|--|--|
| 1        | 100  | 0  |
| 2        | 95   | 5  |
| 3        | 90   | 10   |
| 4        | 85   | 15   |

### 4.3 Treinamento e generalização das redes neurais artificiais

O *software* utilizado para o treinamento e aplicação das redes foi o Neuroforest<sup>®</sup> (versão 3.3). Foram treinadas redes neurais artificiais para projeção do volume em idades futuras, do tipo *Multilayer Perceptron* (MLP), totalizando três camadas: uma de entrada; uma intermediária; e uma de saída. O algoritmo de treinamento utilizado foi o *Resilient propagation* (RPROP<sup>+</sup>).

Quanto à definição da arquitetura das redes, o número de neurônios da camada de entrada variou de acordo com o número de variáveis consideradas em cada estudo. Foram utilizados 12 neurônios na camada intermediária e um neurônio na camada de saída. A função de ativação utilizada para as camadas oculta e de saída foi do tipo *sigmoidal*.

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

### 4.4 Avaliação das estimativas

A avaliação das estimativas das redes neurais artificiais nas etapas de treinamento e validação foi feita por estatísticas e análises gráficas. As estatísticas utilizadas foram: a correlação entre os volumes estimados e observados; a raiz quadrada do erro quadrático médio (*RQEM*); e o erro médio percentual (*erro%*).

$$r(y_i, \hat{y}_i) = \frac{\text{cov}(y_i, \hat{y}_i)}{\sqrt{V(y_i) \cdot V(\hat{y}_i)}} \quad \text{RQEM} = \frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{n-1} \quad \text{erro}(\%) = \frac{(\hat{y}_i - y_i)}{y_i} \cdot 100$$

em que

$y_i$  e  $\hat{y}_i$  = volumes observado e estimado da variável sob análise;

$n$  = número de casos;

$V$  = variância da amostra; e

$\text{cov}$  = covariância.

A correlação entre os volumes observados e estimados indicam o grau de associação e a direção da relação entre as duas variáveis (CAMPOS; LEITE, 2013). Quanto mais próxima de 1, maior a correlação entre as variáveis.

A raiz quadrada do erro quadrático médio avalia o erro entre os volumes observados e os estimados, quanto menor o RQEM, maior a precisão da estimativa (MEHTÄTALO; MALTAMO; KANGAS, 2006). Quando o número de observações (neste estudo, número de parcelas) tende para o infinito, o RQEM pode ser interpretado como erro padrão residual.

A análise gráfica dos erros (resíduos) também foi utilizada na avaliação dos modelos de redes neurais, sendo construídos histogramas com a frequência de casos por classe de erro percentual e gráficos do volume observado versus volume estimado.

## 5. RESULTADOS

### 5.1 Estudo 1

Na Tabela 7 são apresentadas as estimativas da raiz quadrada do erro quadrático médio (RQEM) e da correlação entre os volumes observados e estimados ( $\hat{r}_{y,y}$ ) com base no percentual de treinamento e generalização para o Estudo 1. Nas Figuras 7 e 8, os gráficos de dispersão dos volumes observados e estimados e os correspondentes histogramas da distribuição de frequência dos resíduos, utilizando 100, 50, 40, 30, 20 e 10% dos dados para treinamento das redes.

Tabela 7 – Raiz quadrada do erro quadrático médio (RQME) e correlação entre os volumes observados e estimados ( $\hat{r}_{y,y}$ ) para o Estudo 1

| Treinamento (%) | Generalização (%) | Análise       | RQEM (%) | $\hat{r}_{y,y}$ |
|-----------------|-------------------|---------------|----------|-----------------|
| 100             | 0                 | Treinamento   | 5,15     | 0,9929          |
| 50              | 50                | Treinamento   | 4,65     | 0,9941          |
|                 |                   | Generalização | 5,13     | 0,9931          |
| 40              | 60                | Treinamento   | 4,64     | 0,9943          |
|                 |                   | Generalização | 4,97     | 0,9934          |
| 30              | 70                | Treinamento   | 4,65     | 0,9943          |
|                 |                   | Generalização | 4,77     | 0,9939          |
| 20              | 80                | Treinamento   | 4,64     | 0,9943          |
|                 |                   | Generalização | 5,65     | 0,9915          |
| 10              | 90                | Treinamento   | 4,65     | 0,9943          |
|                 |                   | Generalização | 6,17     | 0,9898          |

### 5.2 Estudo 2

Na Tabela 8 são apresentadas as estimativas da raiz quadrada do erro quadrático médio (RQEM) e da correlação entre os volumes observados e estimados ( $\hat{r}_{y,y}$ ) com base no percentual de treinamento e generalização para o Estudo 2. Nas Figuras 9 e 10, são apresentados os gráficos de dispersão dos volumes observados e estimados e os correspondentes histogramas da distribuição de frequência dos resíduos, utilizando 100, 50, 40, 30, 20 e 10% dos dados para treinamento das redes.

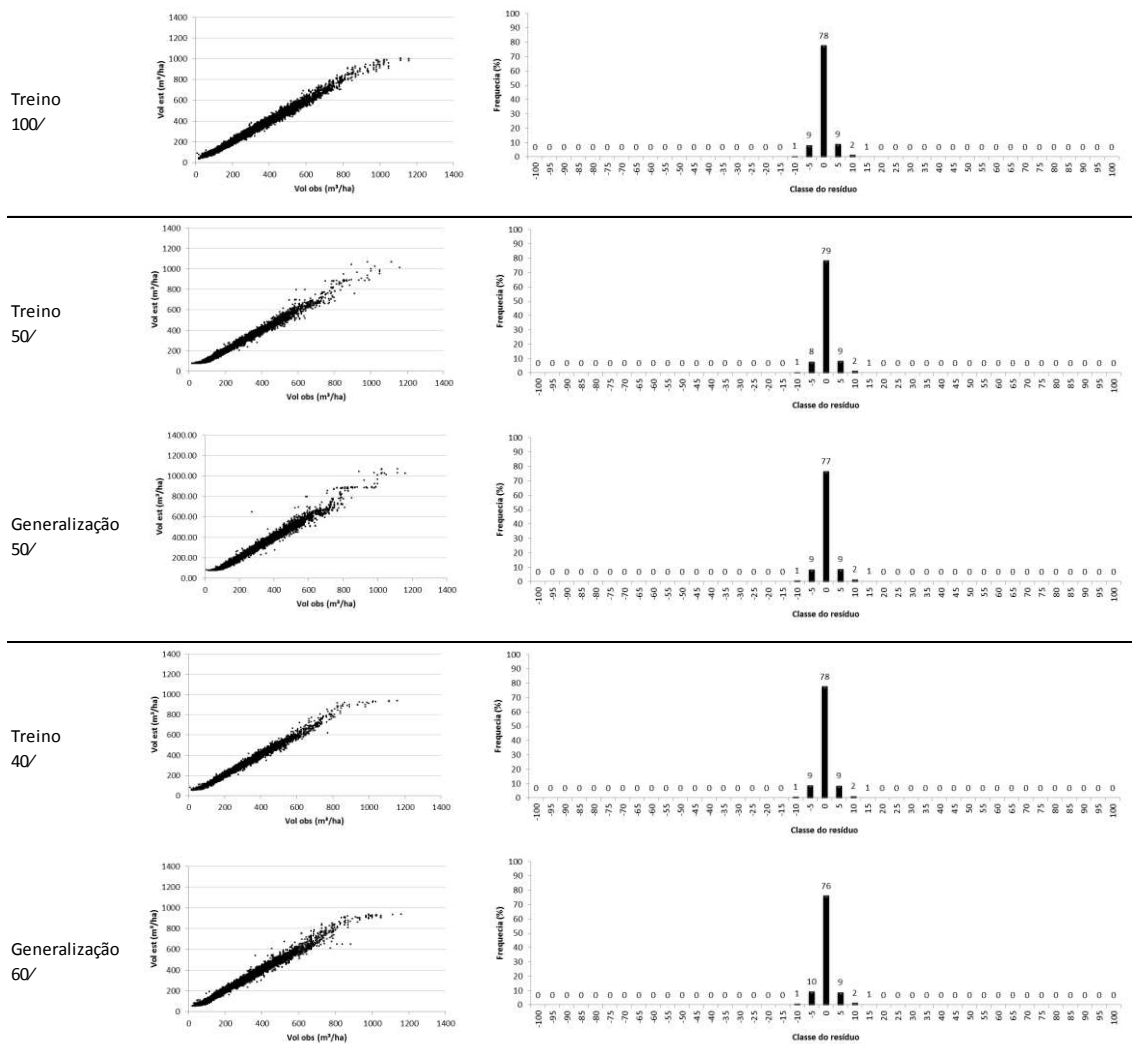


Figura 7 – Volumes observados *versus* estimados e correspondentes histogramas de frequência dos erros percentuais, utilizando 100, 50 e 40% dos dados para o treinamento das redes neurais artificiais, para o Estudo 1.

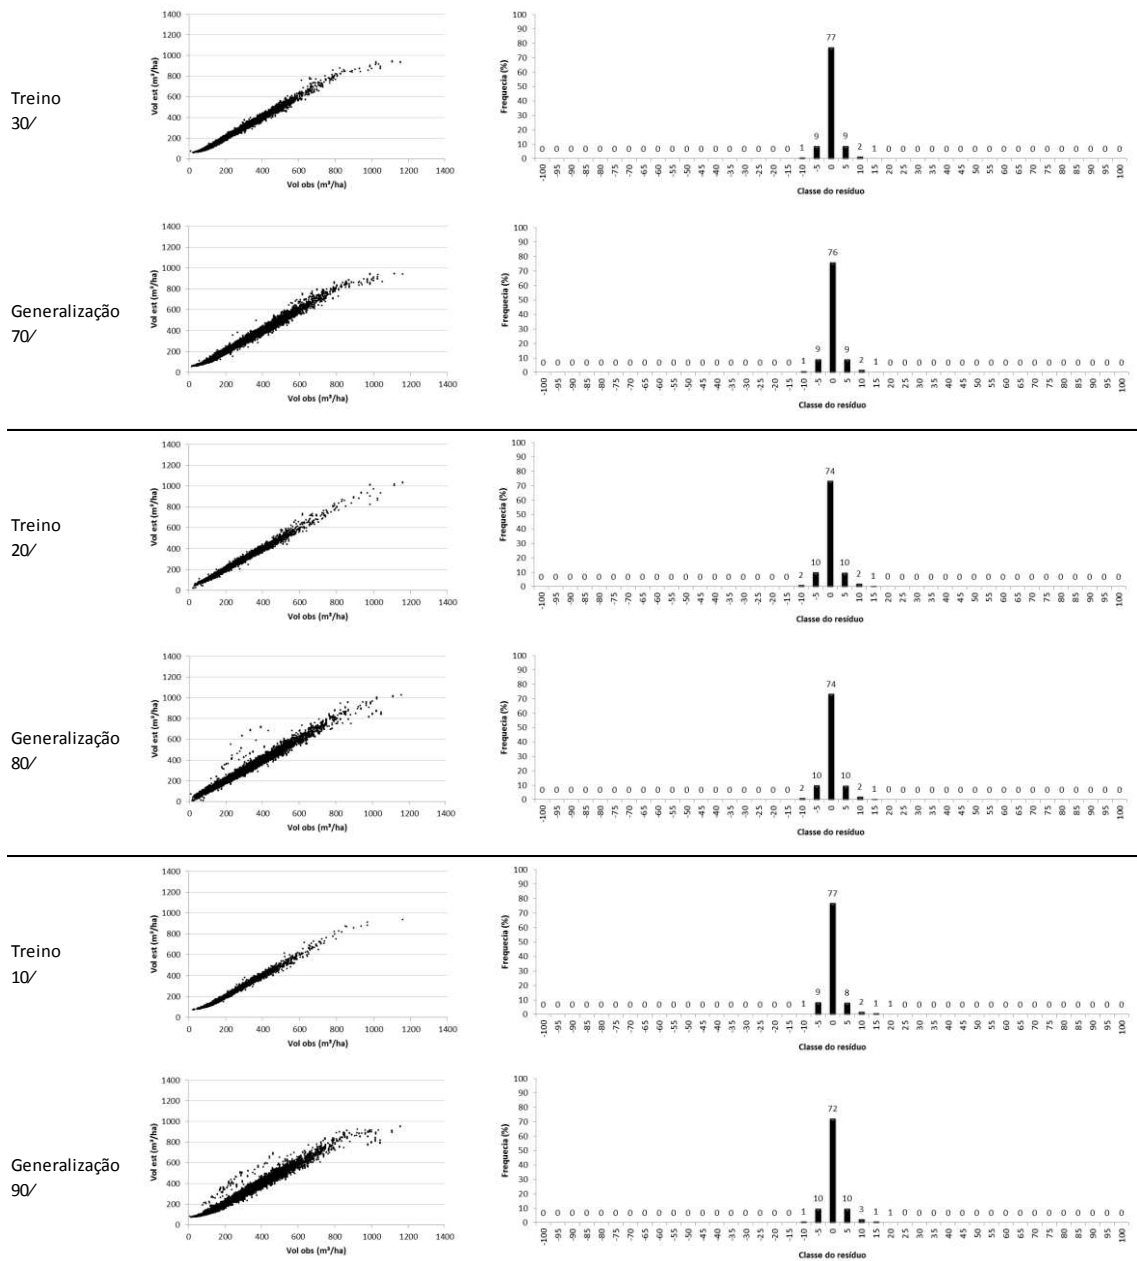


Figura 8 – Volumes observados versus estimados e correspondentes histogramas de frequência dos erros percentuais, utilizando 30, 20 e 10% dos dados para o treinamento das redes neurais artificiais, para o Estudo 1.

Tabela 8 – Raiz quadrada do erro quadrático médio (RQME) e correlação entre os volumes observados e estimados ( $\hat{r}_{y,y}$ ) para o Estudo 2

| Treinamento (%) | Generalização (%) | Análise       | RQEM (%) | $\hat{r}_{y,y}$ |
|-----------------|-------------------|---------------|----------|-----------------|
| 100             | 0                 | Treinamento   | 4,66     | 0,9942          |
| 50              | 50                | Treinamento   | 4,67     | 0,9942          |
|                 |                   | Generalização | 4,82     | 0,9938          |
| 40              | 60                | Treinamento   | 4,67     | 0,9941          |
|                 |                   | Generalização | 4,77     | 0,9940          |
| 30              | 70                | Treinamento   | 4,63     | 0,9943          |
|                 |                   | Generalização | 4,87     | 0,9937          |
| 20              | 80                | Treinamento   | 4,67     | 0,9944          |
|                 |                   | Generalização | 4,88     | 0,9936          |
| 10              | 90                | Treinamento   | 4,67     | 0,9943          |
|                 |                   | Generalização | 5,04     | 0,9932          |

### 5.3 Estudo 3

Na Tabela 9 são apresentadas as estimativas da raiz quadrada do erro quadrático médio (RQEM) e da correlação entre os volumes observados e estimados ( $\hat{r}_{y,y}$ ) com base no percentual de treinamento e generalização para o Estudo 3. Nas Figuras 11 e 12 são apresentados os gráficos de dispersão dos volumes observados e estimados e os correspondentes histogramas da distribuição de frequência dos resíduos, utilizando 100, 50, 40, 30, 20 e 10% dos dados para treinamento das redes.

### 5.4 Estudo 4

Na Tabela 10 são apresentadas as estimativas da raiz quadrada do erro quadrático médio (RQEM) e da correlação entre os volumes observados e estimados ( $\hat{r}_{y,y}$ ) com base no percentual de treinamento e generalização para o Estudo 4. Nas Figuras 13 e 14, são apresentados os gráficos de dispersão dos volumes observados e estimados e os correspondentes histogramas da distribuição de frequência dos resíduos, utilizando 100, 95, 90 e 85% dos dados para treinamento da rede.



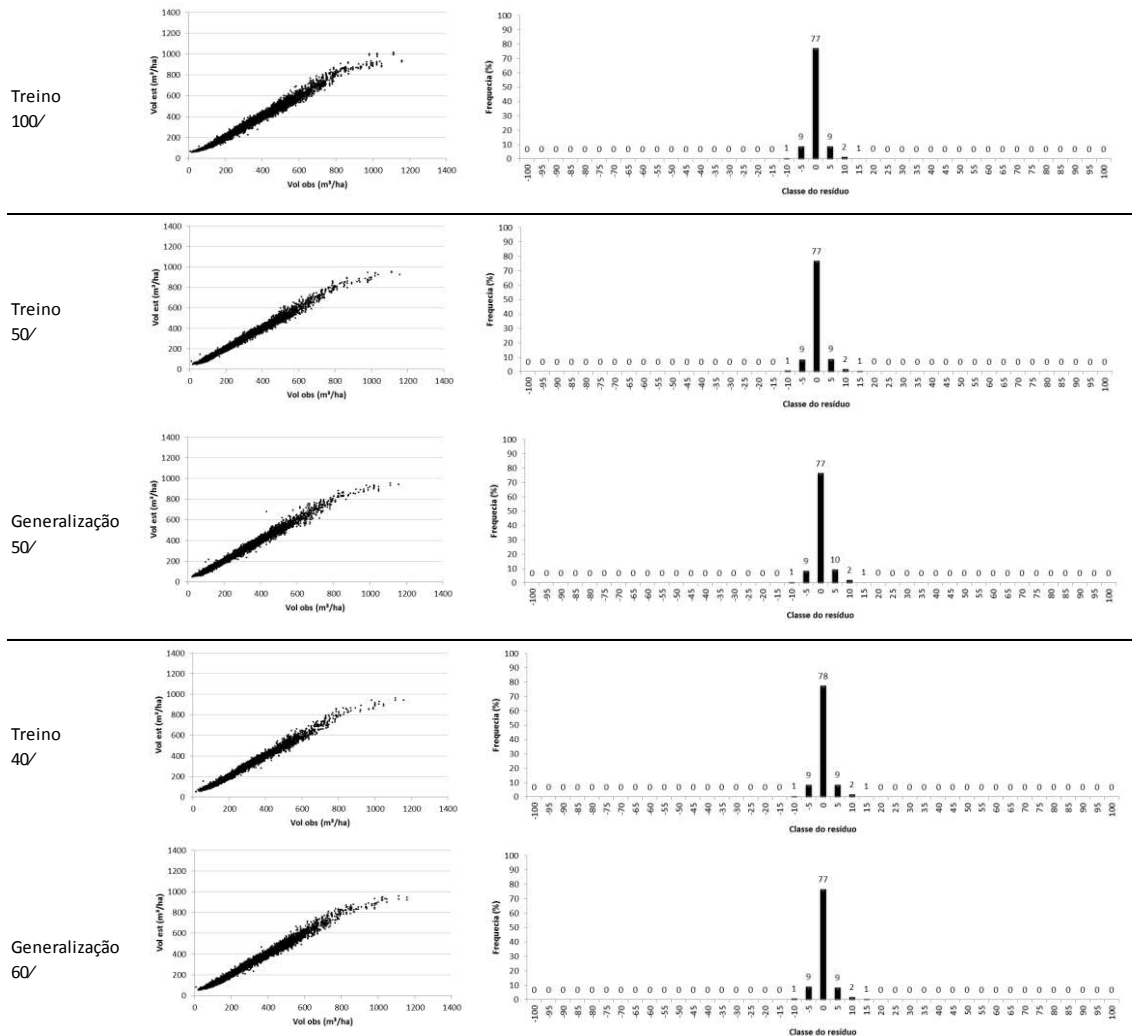


Figura 9 – Volumes observados *versus* estimados e correspondentes histogramas de frequência dos erros percentuais, utilizando 100, 50 e 40% dos dados para o treinamento das redes neurais artificiais, para o Estudo 2.

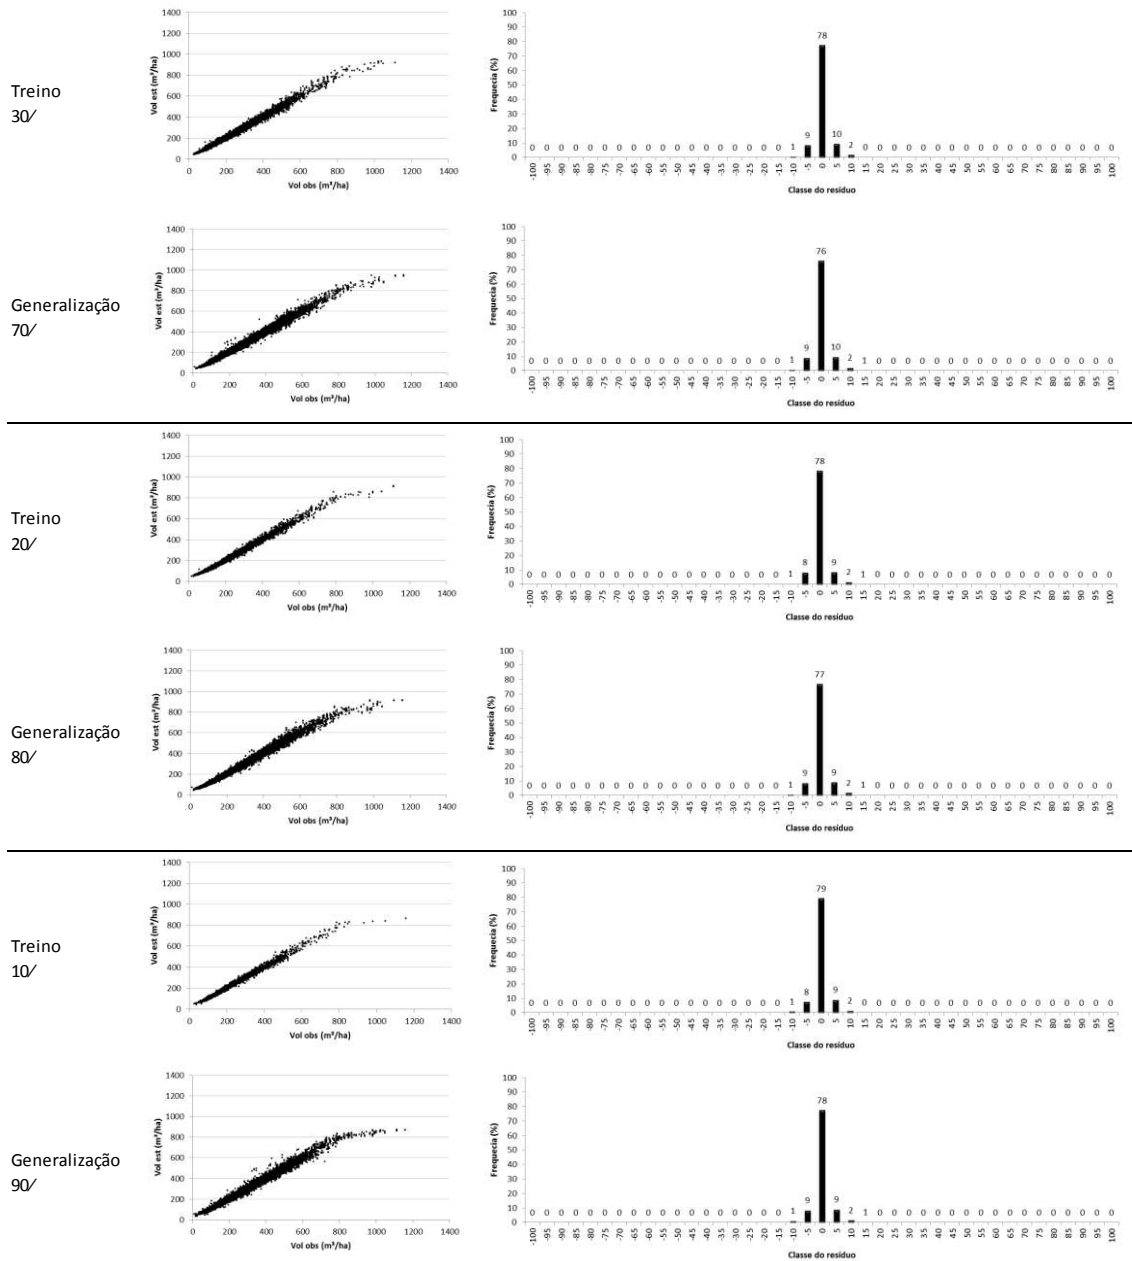


Figura 10 – Volumes observados *versus* estimados e correspondentes histogramas de frequência dos erros percentuais, utilizando 30, 20 e 10% dos dados para o treinamento das redes neurais artificiais, para o Estudo 2.

Tabela 9 – Raiz quadrada do erro quadrático médio (RQME) e correlação entre os valores observados e estimados ( $\hat{r}_{y,y}$ ) para o Estudo 3

| Treinamento (%) | Generalização (%) | Análise       | RQEM (%) | $\hat{r}_{y,y}$ |
|-----------------|-------------------|---------------|----------|-----------------|
| 100             | 0                 | Treinamento   | 21,71    | 0,8935          |
| 50              | 50                | Treinamento   | 18,86    | 0,8938          |
|                 |                   | Generalização | 20,48    | 0,8733          |
| 40              | 60                | Treinamento   | 18,33    | 0,9013          |
|                 |                   | Generalização | 20,93    | 0,8706          |
| 30              | 70                | Treinamento   | 18,11    | 0,9014          |
|                 |                   | Generalização | 21,60    | 0,8628          |
| 20              | 80                | Treinamento   | 17,74    | 0,9017          |
|                 |                   | Generalização | 22,73    | 0,8470          |
| 10              | 90                | Treinamento   | 17,10    | 0,9090          |
|                 |                   | Generalização | 25,93    | 0,8060          |

## 5.5 Estudo 5

Com o objetivo de extrapolar informações de produtividade para todo o estado de Minas Gerais e considerando a exatidão e consistência dos resultados do Estudo 4, a mesma metodologia deste Estudo foi utilizada para extrapolar as estimativas para áreas do Estado de Minas Gerais não contempladas na amostragem. Assim, nas Figuras 15 e 16, são apresentados os mapas da produtividade aos 7 anos (IMA7) e 6 anos (IMA6) do Estado de Minas Gerais, utilizando a rede neural artificial do Estudo 5.

Na Figura 17 é apresentado o mapa da produtividade aos 6 anos (IMA6) para o Brasil, utilizando modelos fisiológicos resultantes do trabalho de Borges (2012). Para melhor efeito de comparação com a metodologia das redes neurais artificiais, foi feito uma aproximação deste mapa visando apenas o estado de Minas Gerais (Figura 18).

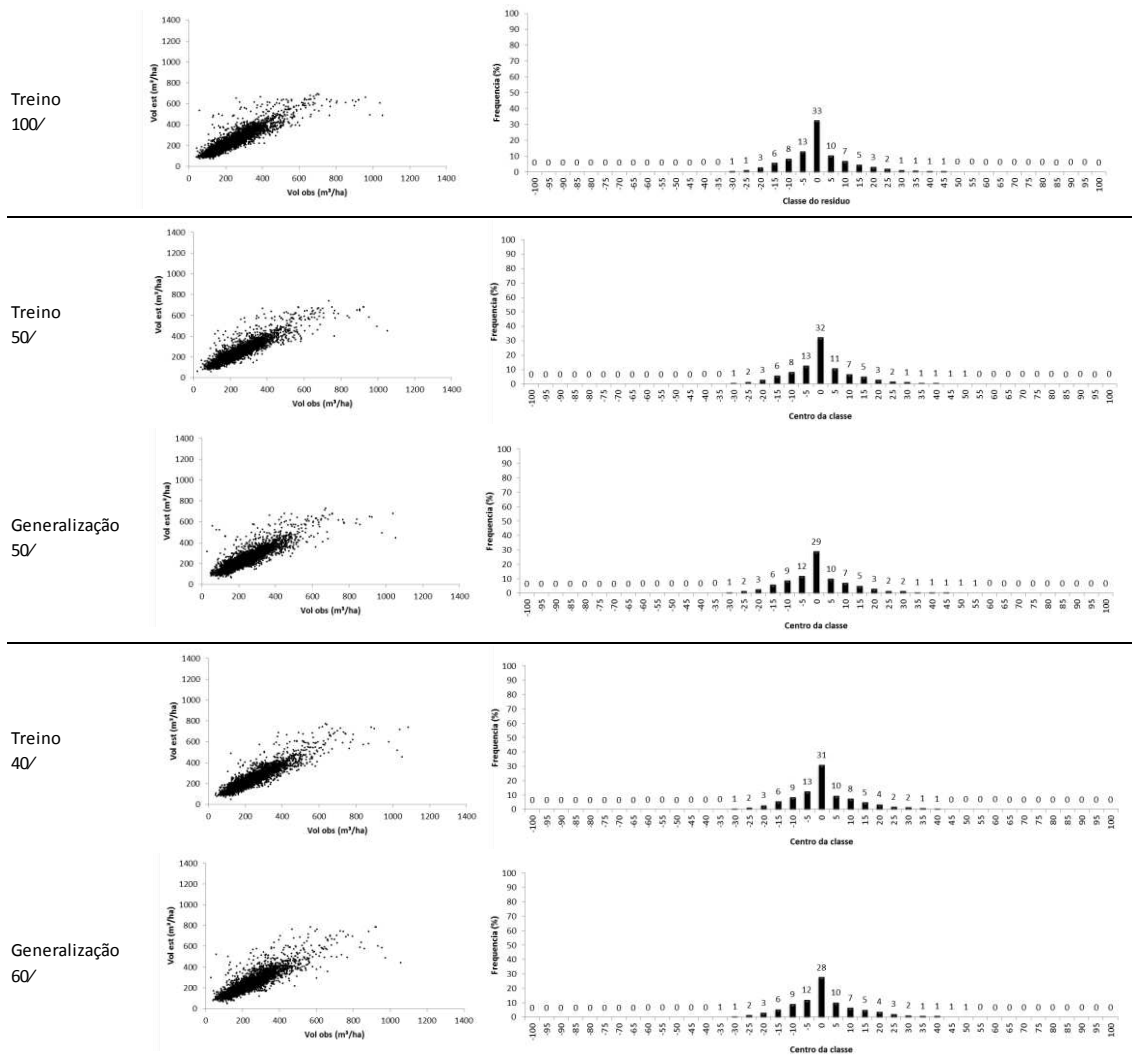


Figura 11 – Volumes observados *versus* estimados e correspondentes histogramas de frequência dos erros percentuais, utilizando 100, 50 e 40% dos dados para o treinamento das redes neurais artificiais, para o Estudo 3.

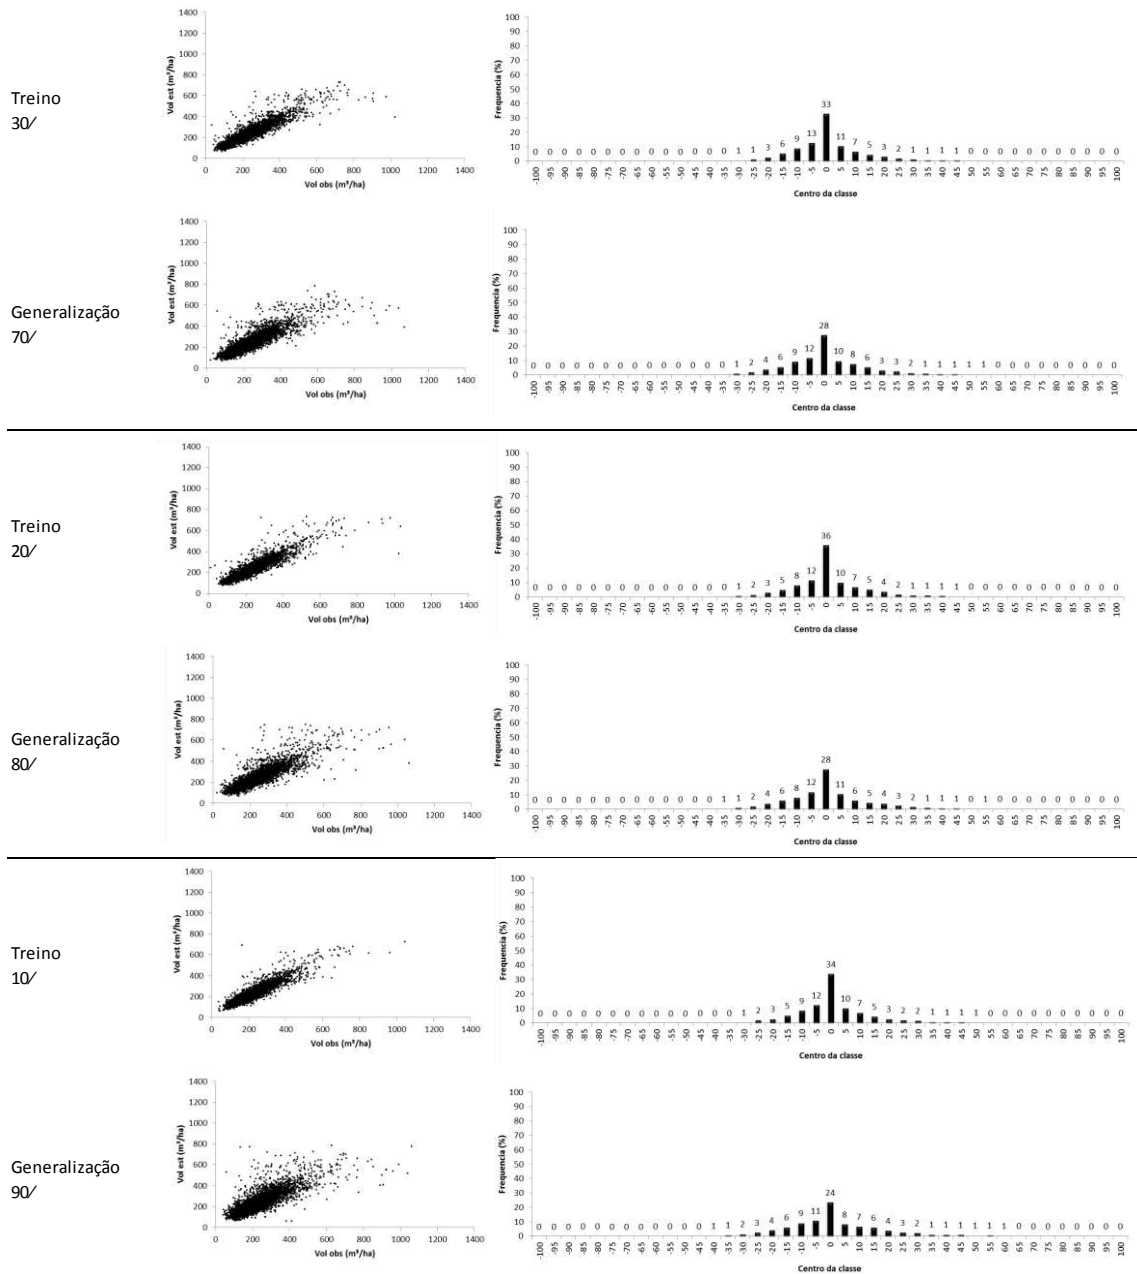


Figura 12 – Volumes observados *versus* estimados e correspondentes histogramas de frequência dos erros percentuais, utilizando 30, 20 e 10% dos dados para o treinamento das redes neurais artificiais, para o Estudo 3.

Tabela 10 – Raiz quadrada do erro quadrático médio (RQME) e correlação entre os volumes observados e estimados ( $\hat{r}_{y,y}$ ) para o Estudo 4

| Treinamento (%) | Generalização (%) | Análise       | RQEM (%) | $\hat{r}_{y,y}$ |
|-----------------|-------------------|---------------|----------|-----------------|
| 100             | 0                 | Treinamento   | 10,36    | 0,8830          |
| 95              | 5                 | Treinamento   | 12,18    | 0,8377          |
|                 |                   | Generalização | 21,83    | 0,5295          |
| 90              | 10                | Treinamento   | 11,63    | 0,8555          |
|                 |                   | Generalização | 22,14    | 0,5387          |
| 85              | 15                | Treinamento   | 11,21    | 0,8640          |
|                 |                   | Generalização | 22,22    | 0,5355          |

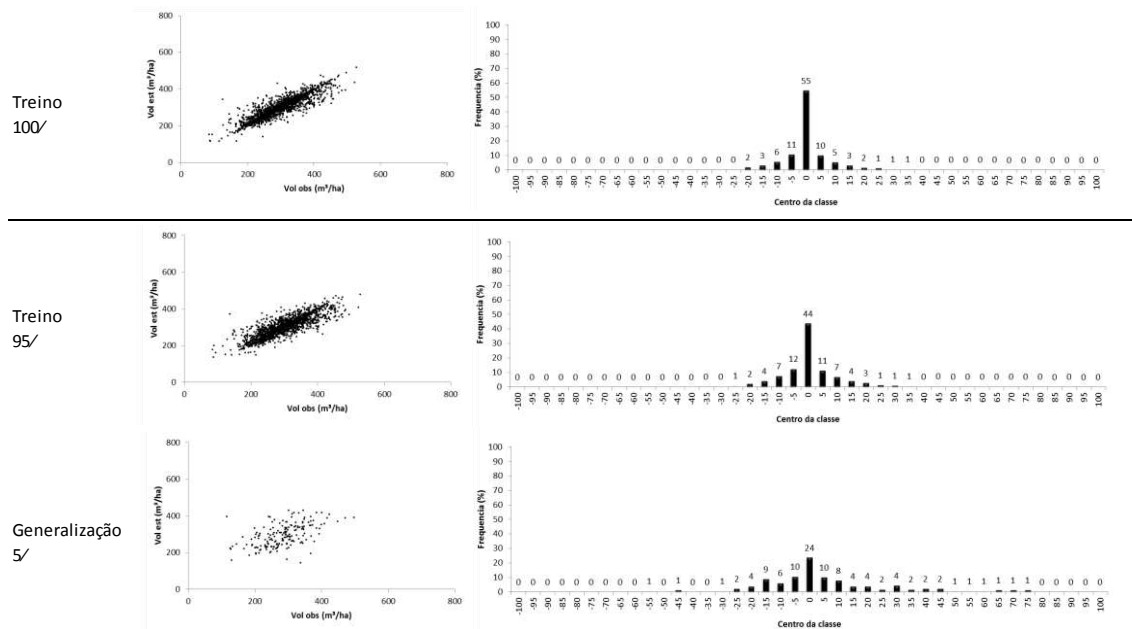


Figura 13 – Volumes observados *versus* estimados e correspondentes histogramas de frequência dos erros percentuais, utilizando 100 e 95% dos dados para o treinamento das redes neurais artificiais, para o Estudo 4.

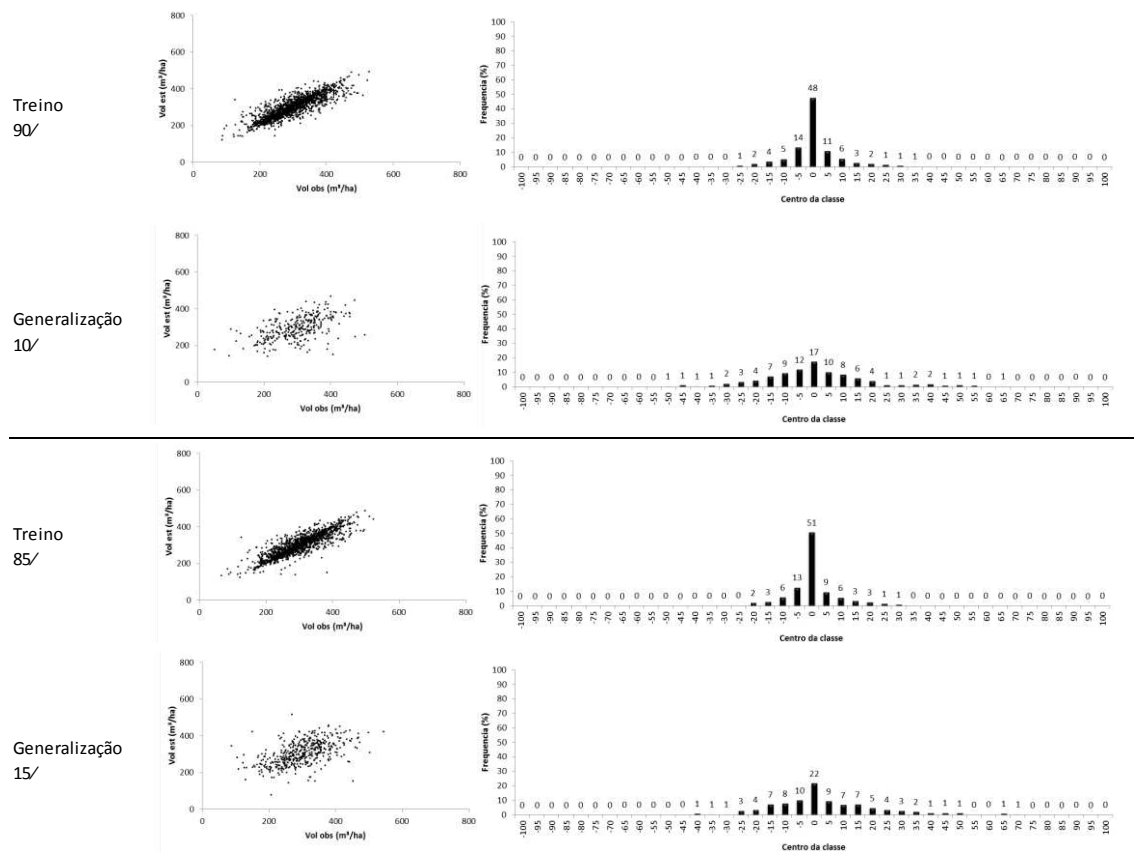


Figura 14 – Volumes observados *versus* estimados e correspondentes histogramas de frequência dos erros percentuais, utilizando 90 e 85% dos dados para o treinamento das redes neurais artificiais, para o Estudo 4.

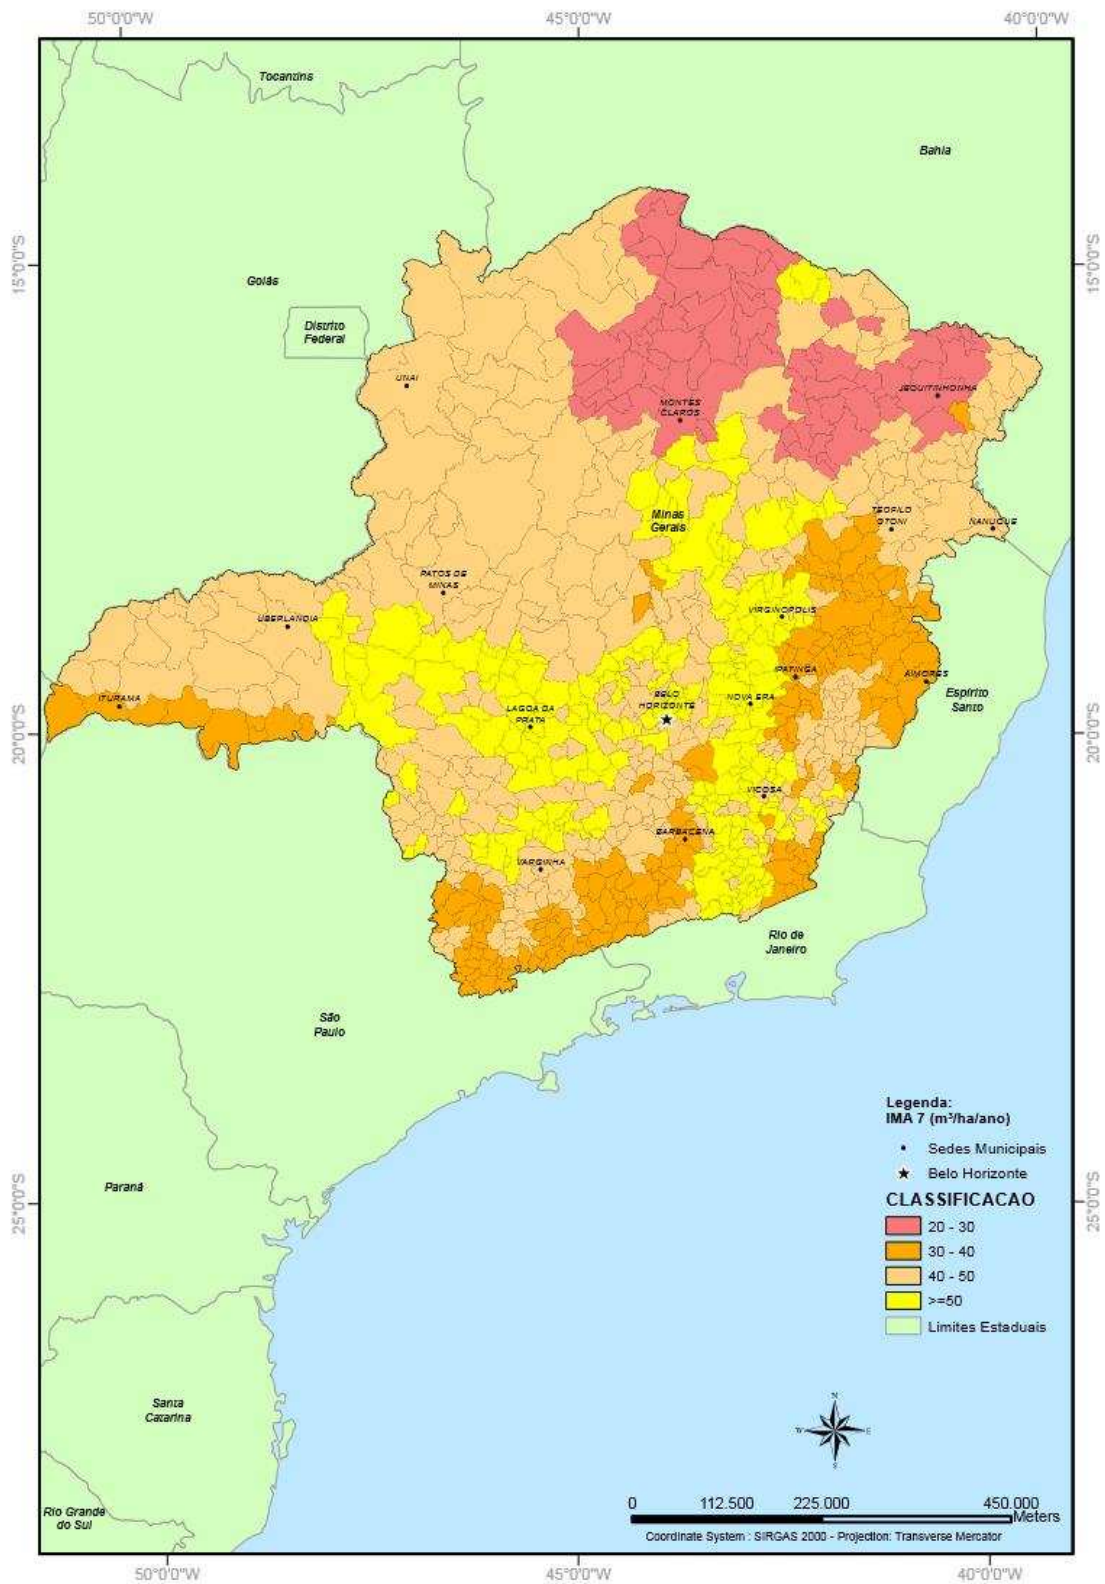


Figura 15 – Mapa da produtividade aos 7 anos (IMA7) para o Estado de Minas Gerais, utilizando a rede neural artificial do Estudo 5.



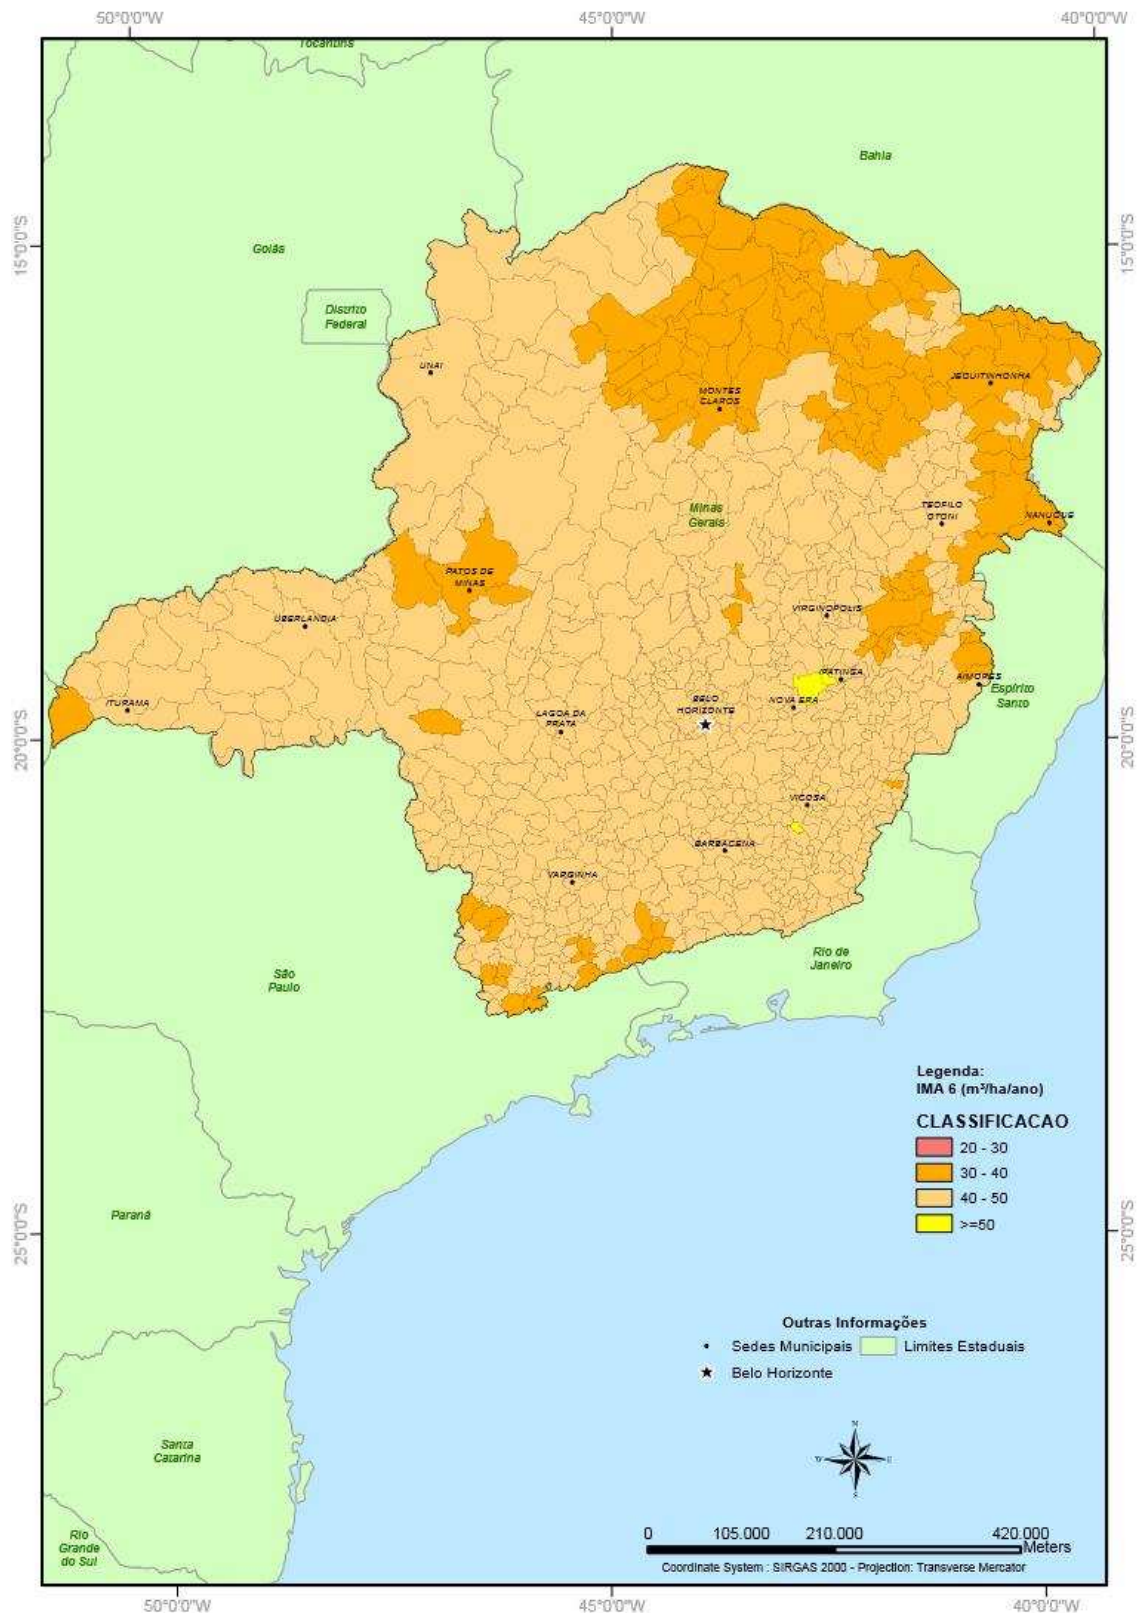
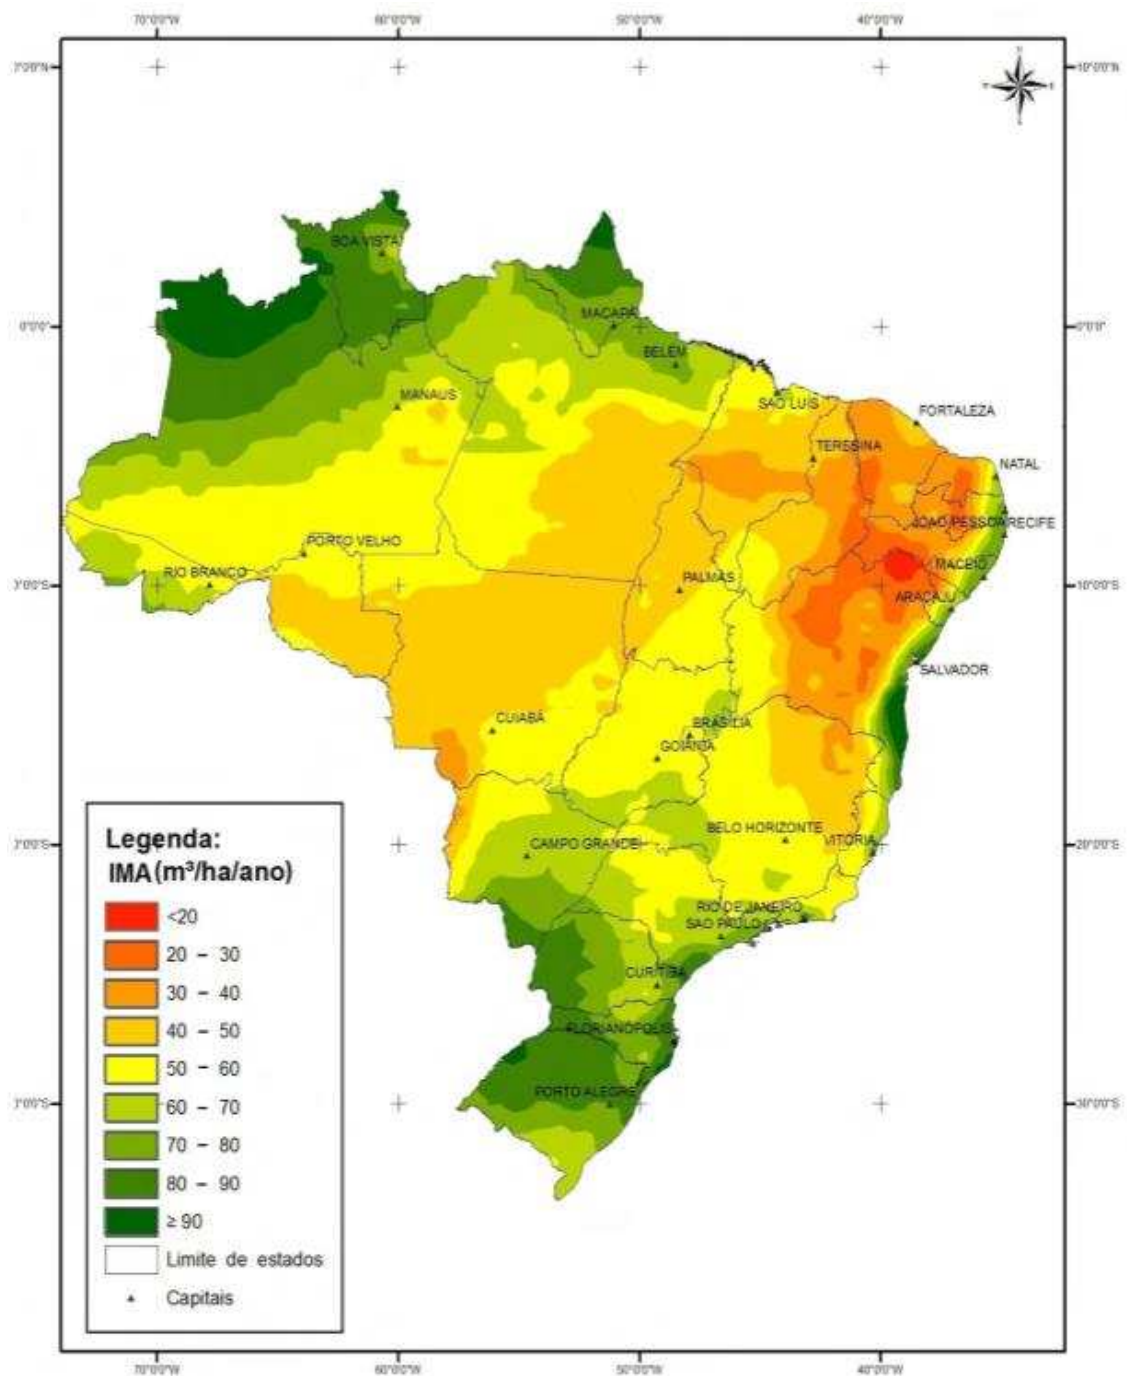
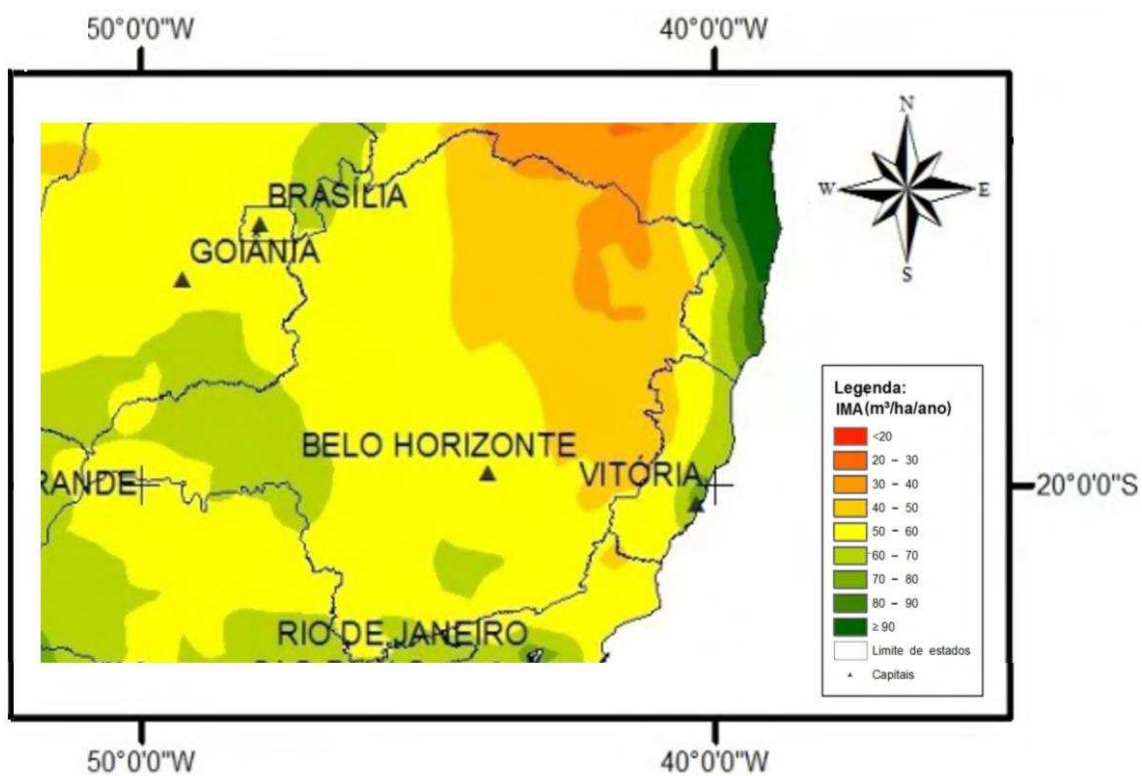


Figura 16 – Mapa da produtividade aos 6 anos (IMA6) para o Estado de Minas Gerais, utilizando a rede neural artificial do Estudo 5.



Fonte: Borges (2012).

Figura 17 – Mapa da produtividade aos 6 anos (IMA6) para o Brasil, utilizando modelos fisiológicos.



Fonte: adaptada de Borges (2012).

Figura 18 – Destaque do estado de Minas Gerais no mapa de produtividade aos 6 anos de idade (IMA6), utilizando modelos fisiológicos.

## 6. DISCUSSÃO

De acordo com as Tabelas 7 e 8, a raiz quadrada do erro quadrático médio (RQEM) e a correlação entre os valores estimados e observados, permaneceram aproximadamente constantes para treinamento com o uso de percentuais de 100 a 10% dos dados nesta etapa. A RQEM variou entre 4,64 a 4,65 (Estudo 1) e 4,63 a 4,67 (Estudo 2), já a correlação variou entre 0,9941 a 0,9943 (Estudo 1) e 0,9941 a 0,9944 (Estudo 2).

Ao utilizar variáveis do IFC e climáticas (Estudo 1 e 2), depreende-se que é possível reduzir a base de dados de modo significativo (Tabelas 7 e 8). Na generalização, o menor valor da RQEM foi obtido ao utilizar 30% (Estudo 1) e 40% (Estudo 2) dos dados no treinamento. Percentuais acima destes valores resultaram em RQEM maiores, em parte, por apresentarem um número menor de observações na generalização, ou seja, os denominadores no cálculo do RQEM são menores em relação aos demais. Por outro lado, os treinamentos com percentuais inferiores a esses valores, indicaram maiores RQEM pelo fato da amostra perder representatividade com a redução da base de treinamento.

A distribuição dos resíduos foi normal em todos os casos do Estudo 1 e do Estudo 2, com mais de 90% dos erros no intervalo de 5 a -5%, resultados estes considerados excelentes para dados em nível de parcela (Figuras 7 a 10).

De acordo com as Tabelas 9 e 10, a raiz quadrada do erro quadrático médio (RQEM) e a correlação, para os Estudos 3 e 4, apresentaram valores muito maiores quando comparados com os Estudos 1 e 2. Isso se deve ao fato desses Estudos não utilizarem as variáveis de IFC na base de treinamento, variáveis estas que apresentam alta correlação com a produtividade.

Apesar da perda de exatidão, com o emprego de variáveis climáticas, sem os dados de IFC (Estudos 3 e 4), ainda são observadas correlações relativamente altas, acima de 80% (Tabelas 9 e 10). Nesse caso, o que aumenta é a dispersão dos erros, ou seja, a variância residual, que, dado o grande número de observações, pode ser interpretada diretamente pela RQEM, que nesse caso é uma excelente aproximação do erro padrão residual. A distribuição dos erros, para diferentes intervalos de projeção, continua

normal, com mais de 90% dos erros, entre 25 a -25%. Considerando que as análises gráficas de resíduos foram feitas em nível de talhão e que a projeção foi feita com diferentes intervalos de idade, na ausência de dados de IFC, as redes neurais dos Estudos 3 e 4, podem ser utilizadas sem risco de viés, com uma margem aceitável de erro (Figuras 11 a 14).

Ainda sobre os Estudos 3 e 4, na análise de treinamento, à medida que a base de treino foi sendo reduzida, a RQEM foi diminuindo e a correlação aumentando. Isso ocorreu porque com a redução da base, a variabilidade diminuiu, provocando uma redução do potencial da rede para gerar estimativas para dados que não participaram do treinamento (generalização). Por este motivo, na análise de generalização, a RQEM foi aumentando e a correlação diminuindo à medida que a base de treino foi sendo reduzida. Desta forma recomenda-se utilizar toda a base para estimativas que não apresentam as variáveis de IFC (Tabelas 9 e 10).

Os resultados do Estudo 4, de fato estão incluídos nos resultados do Estudo 3, ou seja, é uma parte deste. O objetivo do Estudo 4 é de ordem prática, pois, não depende de dados de IFC (áreas sem plantio ou sem medições de IFC), e servem para elaborar planos estratégicos e táticos de manejo nos quais é necessário contar com estimativas de produtividade na idade definida para fins de regulação da produção.

Comparando as estimativas com os correspondentes volumes observados, é possível verificar que a rede neural do Estudo 4 é eficiente e consistente, podendo ser utilizada para fins de manejo florestal.

Em princípio, de acordo os mapas das Figuras de 15 a 18, pode-se observar que a produtividade do mapa utilizando o modelo processual (3PG) está superestimada, quando comparada com a produtividade dos mapas utilizando a metodologia de redes neurais artificiais. Entretanto, cabe observar que a produtividade estimada por Borges (2012) é potencial, enquanto a produtividade estimada no presente estudo é real, ou seja, produtividade que de fato tem ocorrido no Estado de Minas Gerais. Portanto não se trata de superestimação nos resultados de Borges (2012), a comparação aqui serve para mostrar a diferença entre a potencial e a real. No caso de Borges (2012) é assumido não haver restrição por água, o que de fato muitas vezes tem ocorrido no estado.

O mapa de IMA7 (Figura 15) apresenta mais classes de produtividade do que o mapa de IMA6 (Figura 16), isso ocorre pela diferença entre as curvas de crescimento dos clones presentes em diferentes locais do Estado. Até a idade de seis anos as curvas apresentam mais próximas, a partir deste ponto as curvas se diferem evidenciando as diferentes taxas de crescimento e produtividade.

A região Nordeste do estado de Minas Gerais apresenta as menores produtividades do Estado, já a região inferior do triângulo mineiro apresenta uma faixa de menor produtividade quando comparado com o restante desta área. Esses fatos se confirmam nos mapas das duas metodologias aqui comparadas.

Os mapas obtidos utilizando redes neurais artificiais apresentaram uma faixa com menor produtividade do Sul ao Leste do Estado. Essa área não se destaca no mapa utilizando a metodologia de modelos processuais (3PG) do trabalho de Borges (2012), sendo que ela de fato existe.

Ao se comparar os mapas das Figuras 15 e 16, pode-se observar que a área inferior do triângulo mineiro, a parte Nordeste, extremo Sul e Leste do Estado, tem ponto de máximo de IMA abaixo de 6 anos, ao contrário das áreas em amarelo da Figura 15 (classe  $\geq 50$ ), que apresenta ponto de máximo de IMA acima de 6 anos.

## 7. CONCLUSÕES

Para uma grande e abrangente base de dados, empregar somente *inputs* contidos na base de dados do IFC ou dados de IFC somados aos dados climáticos, resulta em grande exatidão e consistência. Entretanto, a inclusão de informações edáficas e climáticas, somadas aos dados de IFC, na base de treinamento de uma rede neural artificial, para prognose do crescimento e da produção, são importantes por considerar efeitos naturais que fogem do comportamento normal como, por exemplo, um ano com alto déficit hídrico. Ou seja, as redes com estes dados irão considerar este fato, o que não ocorreria com a utilização das redes com apenas dados de IFC. Estas também servem para simulações de previsão de comportamentos fora do padrão. Outra grande importância das informações edáficas e climáticas na base de treinamento de uma rede neural artificial é tornar possível a prognose em locais sem base de dados de IFC e, ou, sem plantios, conforme os Estudos 3, 4 e 5.

Para bases de dados de IFC e, ou, IFC somados a informações edáficas e climáticas, com grandes áreas de abrangência de plantios de clones de eucalipto, percentuais entre 30 a 40% da base de treinamento são suficientes para fins de modelagem e prognose da produção.

Uma rede neural artificial consegue detalhar mais e com maior exatidão a produtividade média de grandes áreas do que um modelo processual. Com base na eficiência comprovada neste estudo, da capacidade de generalizações das estimativas de produtividades médias para todo o Estado, é possível inferir que se houvesse disponibilidade de dados de IFC de outras empresas, além daquelas contempladas no Estudo, com maior abrangência, seria possível mapear o Estado de Minas Gerais com uma única RNA, com altíssima exatidão.

## 8. REFERÊNCIAS BIBLIOGRÁFICAS

- ALCANTARA, A. E. M. **Alternativas de modelagem para projeção do crescimento de eucalipto em nível de povoamento**. 2010. 65 f. Dissertação (Mestrado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa, 2012.
- AVERY, T. E.; BURKHART, H. E. **Forest measurements**. 4 ed. New York: McGraw Hill, 1994. 408 p.
- BINOTI, M. L. M. S. **Rede neurais artificiais para prognose da produção de povoamentos não desbastados de eucalipto**. 2010. 54 f. Dissertação (Mestrado) – Universidade Federal de Viçosa, Viçosa, 2010.
- BINOTI, D. H. B.; BINOTI, M. L. M. S.; LEITE, H. G.; SILVA, A.; SANTOS, A. C. A. Modelagem da distribuição diamétrica em povoamentos de eucalipto submetidos a desbaste utilizando autômatos celulares. **Revista Árvore**, v. 36. n. 5, p. 931- 939, 2012.
- BINOTI, M. L. M. S.; BINOTI, D. H. B.; LEITE, H. G.; SILVA, A. L.; PONTES, C. Utilização de redes neurais artificiais para a projeção da distribuição diamétrica de povoamentos equiâneos. **Revista Árvore**, v. 38. n. 4, p 747-754, 2014.
- BORGES, J. S. **Modulador edáfico para uso em modelo ecofisiológico e produtividade potencial de povoamentos de eucalipto**. 2012. 80 f. Tese (Doutorado em Solos e Nutrição de Plantas) – Universidade Federal de Viçosa, Viçosa, 2012.
- BRAGA, A. de P.; CARVALHO, A. P. de L. F. de; LUDEMIR, T. B. **Redes Neurais Artificiais: Teoria e Aplicações**. 2. ed. Rio de Janeiro: LTC, 2007.
- BUCKMAN, R. E. **Growth and yield of red pine in Minnesota**. Washington, D.C.: USDA, 1962. 50 p. (Technical Bulletin, 1272).
- BULLINARIA, J. A. Introduction to neural computation: notas de aula. 2014. Disponível em: <<http://www.cs.bham.ac.uk/~jxb/inc.html>>.2014.
- BURKHART, H. E.; CAO, Q. V.; WARE, Z. d. A. **A comparison of growth and yield prediction models for loblolly pine**. Blacksburg: Virginia Polytechnic Institute and State University, Scholl of Forestr and Wildlife Resources, 1981. 59 p.
- CAMPOS, J. C. C.; LEITE, H. G. **Mensuração florestal: Perguntas e respostas**. 4. ed. Viçosa: UFV, 2013. 605 p.
- CASTRO, R. V. O. **Modelagem do crescimento em nível de árvores individuais utilizando redes neurais e autômatos celulares**. 2011. 80 f. Dissertação (Mestrado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa, 2011.



- CLUTTER, J. L. Compatible growth and yield models for loblolly pine. **Forest Science**, v. 9, n. 3, p. 354-371, 1963.
- FERNEDA, E. Redes neurais e sua aplicação em sistemas de recuperação de informação. **Ciência da Informação**, v. 35, n. 1, p. 25-30, 2006.
- GORDON, C. **Artificial neural network modeling of forest tree growth**. 1998. 76 f. Dissertação (Mestrado) – University of the Witwatersrand, 1998.
- GORGENS, E. **Estimação do volume de árvores utilizando redes neurais artificiais**. 2006. 84f. Dissertação (Mestrado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa, 2006.
- HASENAUER, H. Princípios para a modelagem de ecossistemas florestais. **Ciência e Ambiente**, v. 20, n. 1, p. 53-69, 2000.
- HAYKIN, Simon. **Redes neurais: princípios e prática**. Trad. de Paulo Martins Engel. 2. ed. Porto Alegre, RS: Bookman, 2001. 900 p.
- HEATON, J. **Introduction to the math of neural networks (Beta-1)**. St. Louis, 2011. 92 p.
- JAIN, A. K.; MAO, J.; MOHIUDDIN, K. M. Artificial neural networks. A tutorial. **Computer**, v. 29, n. 3, p. 31-44, 1996.
- KÖPPEN, W.; GEIGER, R. **Klimate der Erde**. Gotha: Verlag Justus Perthes, 1928.
- MARTINS, F. B.; SOARES, C. P. B.; LEITE, H. G.; SOUZA, A. L.; CASTRO, R. V. O. Índices de competição em árvores individuais de eucalipto. **Pesq. Agropec. bras.**, v. 46, n. 9, p. 1089-1098, 2011.
- McCULLOCH, S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **Bulletin of Mathematical Biophysics**, v. 5, p. 115-133, 1943.
- MEHTÄTALO, L.; MALTAMO, M.; KANGAS, A. The use of quantile trees in the prediction of the diameter distribution of a stand. **Silva Fennica**, v. 40, n. 3, p. 501-516, 2006.
- NOVAES, D. M. **Modelagem de crescimento e produção de povoamento de *Tectona grandis* L. f. a partir de análise de tronco**. 2009. 42 f. Dissertação (Mestrado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa, 2009.
- OLIVEIRA, M. L. R. de. **Mensuração e modelagem do crescimento e da produção de povoamentos não-desbastados de clones de eucalipto**. 2007. 119 p. Tese (Doutorado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa, 2007.
- SALLES, T. T. **Modelagem de crescimento e produção de clones de eucalipto em um sistema agroflorestal**. 2010. 87 p. Dissertação (Mestrado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa, 2010.

SILVA, A. B. **Modelagem do crescimento e da produção de povoamentos de *Tectona grandis* submetidos a desbaste.** 2009. 73 f. Tese (Doutorado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa, 2009.

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

SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. **Redes neurais artificiais: para engenharia e ciências aplicadas.** São Paulo: Artiber, 2010. 399 p.

SOARES, C. P. B. **Um modelo para o gerenciamento da produção de madeira em plantios comerciais de eucalipto.** 1999. 71 f. Tese (Doutorado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa, 1999.