



UNIVERSIDADE FEDERAL DO ESPÍRITO SANTO
CENTRO DE CIÊNCIAS AGRÁRIAS E ENGENHARIAS
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS FLORESTAIS

JEANGELIS SILVA SANTOS

**PREDIÇÃO E PROJEÇÃO DO CRESCIMENTO E DA PRODUÇÃO DE PLANTIOS DE
EUCALIPTO POR MEIO DE IMAGENS MULTIESPECTRAIS DE MÉDIA
RESOLUÇÃO ESPACIAL**

JERÔNIMO MONTEIRO – ES

2020

JEANGELIS SILVA SANTOS

**PREDIÇÃO E PROJEÇÃO DO CRESCIMENTO E DA PRODUÇÃO DE PLANTIOS DE
EUCALIPTO POR MEIO DE IMAGENS MULTIESPECTRAIS DE MÉDIA
RESOLUÇÃO ESPACIAL**

Tese apresentada ao Programa de Pós-Graduação em Ciências Florestais do Centro de Ciências Agrárias e Engenharias da Universidade Federal do Espírito Santo, como parte das exigências para obtenção do Título de Doutor em Ciências Florestais na Área de Concentração Ciências Florestais.

Orientador: Prof. Dr. Adriano Ribeiro de Mendonça

Coorientadores: Dr. Fábio Guimarães Gonçalves e Prof. Dr. Samuel de Pádua Chaves e Carvalho

JERÔNIMO MONTEIRO – ES

2020

**PREDIÇÃO E PROJEÇÃO DO CRESCIMENTO E DA PRODUÇÃO DE
PLANTIOS DE EUCALIPTO POR MEIO DE IMAGENS MULTIESPECTRAIS
DE MÉDIA RESOLUÇÃO ESPACIAL**

Jeangelis Silva Santos

Tese apresentada ao Programa de Pós Graduação em Ciências Florestais do Centro de Ciências Agrárias e Engenharias da Universidade Federal do Espírito Santo, como parte das exigências para obtenção do Título de Doutor em Ciências Florestais na Área de Concentração Ciências Florestais.

Aprovada em 11 de fevereiro de 2020.



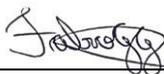
Prof. Dr. André Quintão de Almeida (Examinador externo)
Universidade Federal de Sergipe



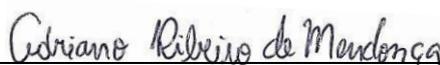
Prof. Dr. Gilson Fernandes da Silva (Examinador interno)
Universidade Federal do Espírito Santo



Prof. Dr. Samuel de Pádua Chaves e Carvalho (Coorientador)
Universidade Federal de Mato Grosso



Dr. Fábio Guimarães Gonçalves (Coorientador)
Canopy Remote Sensing Solutions



Prof. Dr. Adriano Ribeiro de Mendonça (Orientador)
Universidade Federal do Espírito Santo

Ficha catalográfica disponibilizada pelo Sistema Integrado de
Bibliotecas - SIBI/UFES e elaborada pelo autor

S237p Santos, Jeangelis Silva, 1989-
Predição e projeção do crescimento e da produção de plantios de
eucalipto por meio de imagens multiespectrais de média resolução
espacial / Jeangelis Silva Santos. - 2020. 72 f. : il.

Orientador: Adriano Ribeiro de Mendonça.

Coorientadores: Fábio Guimarães Gonçalves, Samuel de
Pádua Chaves e Carvalho.

Tese (Doutorado em Ciências Florestais) - Universidade
Federal do Espírito Santo, Centro de Ciências Agrárias e
Engenharias.

1. Florestas - manejo. 2. Sensoriamento remoto. 3.
Levantamentos florestais. 4. Redes neurais. 5. Árvores
crescimento. I. Mendonça, Adriano Ribeiro de. II. Gonçalves,
Fábio Guimarães. III. Carvalho, Samuel de Pádua Chaves e.
IV. Universidade Federal do Espírito Santo. Centro de Ciências
Agrárias e Engenharias. V. Título.

CDU: 630*38

AGRADECIMENTOS

Agradeço à minha família por toda a motivação e incentivo. Eu não teria chegado até aqui sem o apoio de vocês.

À Universidade Federal do Espírito Santo, em especial ao Programa de Pós-Graduação em Ciências Florestais, pela possibilidade de obter mais um grau acadêmico.

Ao meu orientador Adriano Ribeiro de Mendonça pela amizade, paciência e ensinamentos durante esses anos.

Ao meu coorientador Fabio Guimarães Gonçalves pela amizade, disponibilidade e conhecimentos compartilhados.

Ao meu coorientador Samuel de Pádua Chaves e Carvalho pela disponibilidade e pelas contribuições para esta tese.

Ao prof. Gilson Fernandes da Silva pela motivação, apoio e ensinamentos.

Ao prof. André Quintão de Almeida pela amizade e pelas sugestões para a melhoria desta tese.

Aos amigos do Laboratório de Mensuração e Manejo Florestal pela boa convivência e amizade.

Aos amigos do Laboratório de Dendrocronologia, Evandro Ferreira da Silva, Giovanni Correia Vieira, Luandson Araújo de Souza e Jeferson Pereira Martins Silva, pela parceria, motivação na busca do conhecimento e por tornar a estadia em Jerônimo Monteiro mais leve e divertida.

À Rachel pelo companheirismo, carinho e por sempre me motivar a ser uma pessoa melhor.

Muito obrigado a todos, essa conquista também é de vocês!

RESUMO

SANTOS, J. S. **Predição e projeção do crescimento e da produção de plantios de eucalipto por meio de imagens multiespectrais de média resolução espacial.** 2020. Tese (Doutorado em Ciências Florestais) – Universidade Federal do Espírito Santo, Jerônimo Monteiro, ES. Orientador: Prof. Dr. Adriano Ribeiro de Mendonça. Coorientadores: Dr. Fábio Guimarães Gonçalves e Prof. Dr. Samuel de Pádua Chaves e Carvalho.

O manejo e planejamento eficiente de áreas florestais dependem, diretamente, da aquisição de informações acuradas sobre os povoamentos. Informações sobre o desenvolvimento das florestas podem ser obtidas previamente por modelos de crescimento e produção. Entretanto, para o ajuste desses modelos são necessários dados de inventários florestais contínuos, que são atividades complexas e onerosas. Uma das alternativas que pode reduzir os custos do inventário florestal é a utilização de técnicas de sensoriamento remoto. Diante disso, o objetivo deste trabalho foi propor uma metodologia para a utilização de dados multiespectrais de média resolução espacial para a predição e projeção do crescimento e produção de florestas de eucalipto. Além disso, foi avaliada a possibilidade de redução do número de parcelas mensuradas no inventário florestal. Para tanto, foi utilizada uma base de dados contendo informações de idade e volume por hectare em 40 parcelas permanentes mensuradas anualmente durante os anos de 2006 a 2011, com idades variando de dois a sete anos. Para esse mesmo período, foi obtida uma base de dados contendo séries temporais das métricas do *tasseled cap* extraídas de imagens do sensor ETM+/Landsat 7, suavizadas pelo filtro Savitzky-Golay. Para avaliar a possibilidade de redução no número de parcelas mensuradas no inventário florestal contínuo para estimar a predição e projeção do crescimento por meio de dados de sensoriamento remoto, foram propostos três cenários, com diferentes intensidades amostrais: 1) uma parcela a cada 28 ha; 2) uma parcela a cada 42 ha, e; 3) uma parcela a cada 83 ha. A estimativa da predição e projeção foi realizada por redes neurais artificiais, sendo que na predição as variáveis de entrada foram a idade do povoamento e as métricas do *tasseled cap* (*brightness*, *greenness* e *wetness*). Para a projeção, as variáveis de entrada foram as idades atual e futura e o volume atual, obtido pela predição para o primeiro ano do inventário florestal contínuo. A predição e a projeção foram aplicadas em toda a área dos povoamentos, sendo que os mapas de projeção foram utilizados para cálculo do incremento médio mensal e incremento

corrente mensal. Na predição para toda a área, os valores de *RMSE* foram de 7,92% no cenário 1, 8,86% no cenário 2 e 10,67% no cenário 3. Já para a projeção, o *RMSE* foi de 10,07% no cenário 1, 9,68% no cenário 2 e 11,75% no cenário 3. De modo geral, não houve uma discrepância entre as medidas de acurácia nos três cenários. Além disso, todos os cenários analisados para predição e projeção apresentaram média dos valores estimados dentro do intervalo de confiança do inventário florestal. Os valores de incremento médio e corrente mensais projetados pelos diferentes cenários analisados não se diferiram do obtido pelo IFC, sendo os pontos de inflexão da curva de crescimento e de maturidade da floresta próximos. Assim, pode-se concluir que o uso de dados do sensoriamento remoto permitiu realizar a predição e projeção do crescimento e da produção de florestas de eucalipto com acurácia. Além disso, ao aplicar a metodologia aqui apresentada, é possível reduzir significativamente a intensidade amostral em até uma parcela a cada 83 ha, com acurácia compatível com a metodologia tradicionalmente utilizada no inventário florestal contínuo.

Palavras-chave: Manejo Florestal, *Tasseled Cap*, Redes Neurais Artificiais, Google Earth Engine, Inventário Florestal Aprimorado.

ABSTRACT

SANTOS, J. S. **Growth and yield prediction and projection for eucalyptus plantations using medium spatial resolution multispectral imagery.** 2020. Thesis (Doctorate in Forest Sciences) – Federal University of Espírito Santo, Jerônimo Monteiro, ES. Advisor: Prof. Dr. Adriano Ribeiro de Mendonça. Co-Advisors: Dr. Fábio Guimarães Gonçalves and Prof. Dr. Samuel de Pádua Chaves e Carvalho.

The efficient management and planning of forest areas depends directly on the acquisition of accurate information about the stands. Information about the development of forests can be previously obtained by growth and yield models. However, the adjustment of these models requires data from continuous forest inventories, which are complex and costly activities. One of the alternatives that can reduce the costs of the forest inventory is the use of remote sensing tools. Therefore, the objective of this work was to propose a methodology for using medium spatial resolution multispectral data for the prediction and projection of growth and yield and to determine the technical age of harvesting of eucalyptus forests, aiming at reducing the number of plots measured in the forest inventory. For this purpose, two databases were used: one containing information on age and volume per hectare of 40 permanent plots measured between 2006 and 2011, with ages varying from two to seven years, and other containing time series of Tasseled Cap (TC) metrics extracted from ETM+/Landsat 7 imagery, smoothed by the Savitzky-Golay filter. To assess the possibility of reducing the number of plots measured in the continuous forest inventory when using remote sensing data, three scenarios were proposed, with different sampling intensities: 1) one plot every 28 ha; 2) one plot every 42 ha, and; 3) one plot every 83 ha. The estimation was performed by artificial neural networks and, in the prediction, the input variables were the age of the stand and the metrics of the Tasseled Cap transformation (brightness, greenness and wetness). For the projection, the variables were the current and future age and the current volume, obtained by the prediction for the first year of the continuous forest inventory. The prediction and projection were applied wall-to-wall, and the projection maps were used to calculate the mean and current annual increment and to determine the technical age of harvest. In the wall-to-wall prediction, the *RMSE* values ranged from 7.92% in scenario 1 to 10.67% in scenario 3. As for the projection, the *RMSE* varied from 9.68% in scenario 2 to 11.75% in scenario 3. In general, there was no major discrepancy between the accuracy measures in the three scenarios. In addition, all the scenarios analyzed for

prediction and projection presented estimated values within the confidence interval of the forest inventory. The mean and current monthly increment values projected by the different scenarios analyzed did not differ from that obtained by the continuous forest inventory, with the growth curve inflection and forest maturity points being very close. Therefore, it can be concluded that the use of remotely sensed data allowed to accurately estimate the prediction and projection of growth and production of eucalyptus forests. In addition, by applying the methodology presented here, it is possible to significantly reduce the sampling intensity by up to one plot every 83 ha, with accuracy compatible with the methodology traditionally used in the continuous forest inventory.

Keywords: Forest Management, Tasseled Cap, Artificial Neural Networks, Google Earth Engine, Enhanced Forest Inventory.

SUMÁRIO

| | |
|---|----|
| 1 INTRODUÇÃO | 11 |
| 1.1 Hipótese | 13 |
| 2 OBJETIVOS | 14 |
| 2.1 Objetivo geral | 14 |
| 2.2 Objetivos específicos..... | 14 |
| 3 REVISÃO BIBLIOGRÁFICA | 15 |
| 3.1 Modelagem do crescimento e da produção florestal | 15 |
| 3.2 Princípios básicos de sensoriamento remoto | 18 |
| 3.3 Sensoriamento remoto para estudos da vegetação | 21 |
| 3.3.1 Índices de vegetação..... | 21 |
| 3.3.3 Transformação Tasseled Cap | 23 |
| 3.4 Aplicações de sensoriamento remoto passivo para o inventário florestal | 26 |
| 4 METODOLOGIA..... | 32 |
| 4.1 Descrição da área de estudo e das bases de dados | 32 |
| 4.1.1 Banco de dados do Inventário Florestal Contínuo..... | 34 |
| 4.1.2 Banco de dados de sensoriamento remoto | 34 |
| 4.2 Pré-processamento dos dados..... | 35 |
| 4.2.1 Processamento do inventário florestal contínuo | 35 |
| 4.2.2 Processamento dos dados de sensoriamento remoto..... | 37 |
| 4.3 Definição dos cenários de modelagem para predição e projeção do crescimento e produção de povoamentos de eucalipto..... | 38 |
| 4.4 Predição e projeção do crescimento e produção dos povoamentos de eucalipto | 39 |
| 4.4.1 Predição do volume dos povoamentos de eucalipto | 39 |
| 4.4.2 Projeção do volume dos povoamentos de eucalipto | 40 |
| 4.4.3 Critérios para avaliação da acurácia do treino e validação das RNA nos diferentes cenários | 41 |
| 4.5 Análise do incremento mensal..... | 42 |
| 5 RESULTADOS E DISCUSSÃO..... | 44 |
| 5.1 Parametrização das Redes Neurais Artificiais..... | 44 |
| 5.2 Predição volumétrica dos povoamentos de eucalipto..... | 46 |
| 5.3 Projeção da produção volumétrica dos povoamentos de eucalipto..... | 52 |
| 5.4 Análise do incremento mensal..... | 58 |
| 5.5 Considerações sobre a predição e projeção do crescimento e produção de povoamentos de eucalipto com dados de sensoriamento remoto passivo | 61 |

| | |
|---------------------|----|
| 6 CONCLUSÕES | 66 |
| 7 REFERÊNCIAS | 67 |

1 INTRODUÇÃO

Florestas são ecossistemas dinâmicos cujo manejo e planejamento dependem, diretamente, da aquisição de informações acuradas sobre os povoamentos (TOMPALSKI et al., 2016). Informações sobre o desenvolvimento das florestas podem ser obtidas previamente por modelos de crescimento e produção (MCP). Os MCP são abstrações da dinâmica natural das florestas com finalidade de prognosticar o incremento nas variáveis dendrométricas, mortalidade e alterações na sua estrutura ao longo dos anos (DAVIS et al., 2005; PRETZSCH, 2009; VAN LAAR; AKÇA, 2007; VANCLAY, 1994). Vários autores já utilizaram os MCP com dados de inventário florestal coletados em campo (PUKKALA, LÄHDE, LAIHO, 2009; SCOLFORO et al., 2019a; 2019b).

Para o ajuste dos MCP são necessários, geralmente, dados de inventários realizados com mensuração periódicas das parcelas, chamados de inventários florestais contínuos (IFC). Todavia, inventários florestais são atividades complexas e onerosas, que podem ter seus custos e tempo de execução reduzidos significativamente quando realizados com o auxílio de tecnologias de sensoriamento remoto (BOYD; DANSON, 2005).

Neste contexto, a introdução de tecnologias de sensoriamento remoto no inventário florestal, também chamado de inventário florestal aprimorado (*enhanced forest inventory* - EFI) (WHITE et al. 2016), tem sido fundamental para superar alguns desafios do inventário tradicional, como elevado tempo para execução dos levantamentos, necessidade de planejamento logístico prévio e inviabilidade de execução diante de fatores climáticos adversos. Assim, o inventário florestal com base em dados de sensoriamento remoto fornece uma visão detalhada de áreas com cobertura florestal extensa, inclusive locais que são de difícil acesso durante as visitas de campo (BOYD; DANSON, 2005; LEAL, 2013; SOUZA et al., 2007).

Além das vantagens do EFI citadas, existe a possibilidade da redução de custos pela mensuração de um menor número de parcelas. É importante ressaltar que a utilização de técnicas de sensoriamento remoto não substitui a mensuração de parcelas em campo, uma vez que tais dados são necessários para o ajuste dos modelos que terão como variáveis de entrada os dados de sensoriamento remoto.

As técnicas utilizadas no inventário florestal aprimorado podem ser divididas em sensoriamento remoto bidimensional, que utiliza sensores passivos, por meio de dados multiespectrais, e o sensoriamento remoto tridimensional, que engloba o escaneamento laser aerotransportado (*Airborne Laser Scanning*) e a fotogrametria aérea digital. No entanto, apesar das técnicas de sensoriamento remoto tridimensional apresentarem resultados de alta acurácia (PULITI et al., 2017a, PULITI et al., 2017b; SILVA et al., 2016; SUMNALL; HILL; HINSLEY, 2016), a obtenção de tais dados possui um custo elevado. Diante disso, a grande vantagem da utilização de técnicas de sensoriamento remoto passivo é a facilidade de aquisição das imagens, sendo muitas delas fornecidas gratuitamente, como as imagens geradas pelos satélites do programa Landsat, que são disponibilizadas pelo Serviço Geológico dos Estados Unidos (USGS).

Os dados oriundos de imagens multiespectrais podem ser empregados para estimar parâmetros de florestas nativas e plantadas como área basal, diâmetro médio, altura média, volume e biomassa, bem como atributos relacionados com sua estrutura (ALMEIDA et al., 2014; CHU; GUO; TAKEDA, 2016; DJOMO; CHIMI, 2017; LASSERRE et al., 2011; LU et al., 2004; LUTHER et al., 2006; MASEK et al., 2015; MIGUEL et al., 2015; NEIGH et al., 2016; VAN GUNST et al., 2016). Entretanto, apesar de existirem diversos trabalhos na literatura relatando a estimação de variáveis biofísicas com dados de sensoriamento remoto passivo, poucos trabalhos investigam a estimação do crescimento e produção das florestas.

Com essa abordagem, pode-se citar o trabalho de Reis et al. (2019), que obteve a predição do volume de povoamentos de eucalipto, com idades variando de 2,9 a 6,6 anos, por meio da combinação de bandas e índices de vegetação obtidos do sensor OLI do Landsat 8, dados de radar do Sentinel-1B e também métricas extraídas do modelo digital de elevação do ALOS/PALSAR. Esses autores encontraram elevada acurácia para a predição volumétrica, entretanto neste trabalho não foi abordada a projeção do crescimento florestal por meio de dados de sensoriamento remoto e nem a possibilidade de redução de custos dessa atividade.

Um dos fatores limitantes e que podem explicar a ausência de estudos abordando a modelagem do crescimento de florestas com imagens de sensoriamento remoto é a necessidade da aquisição e análise de extensas séries temporais. Contudo, essa limitação foi superada quando Gorelick et al. (2017) desenvolveram a ferramenta denominada Google Earth Engine (GEE). Segundo os autores, o GEE é

uma plataforma baseada em nuvem para análises geoespaciais em escala planetária, fornecendo resultados em tempo real. Nessa plataforma, todo o processamento dos dados de sensoriamento remoto é feito nos servidores em nuvem da Google, com requisições feitas com interfaces de programação de aplicações (API) para JavaScript e Python, tornando desnecessário o download e processamento local das cenas. Dentre os dados disponíveis nesses servidores, estão toda a série Landsat, Sentinel 1 e 2, MODIS (Terra e Aqua), além dos modelos digitais de elevação do SRTM e ASTER, dentre outros.

Diante desse cenário, é importante avaliar a utilização de dados de sensoriamento remoto passivo para a predição e projeção do crescimento e da produção de florestas. Além disso, é fundamental analisar a possibilidade de redução no número de parcelas mensuradas em campo ao utilizar dados de sensoriamento remoto e os impactos na acurácia das estimativas.

1.1 Hipótese

A hipótese analisada neste trabalho foi de que a utilização de dados multiespectrais do sensor ETM+ do satélite Landsat 7 permitirá uma redução de até 75% no número de parcelas mensuradas para a modelagem da predição e projeção da produção volumétrica de florestas de eucalipto, sem incorrer em perdas de acurácia quando comparada com a metodologia tradicionalmente empregada.

2 OBJETIVOS

2.1 Objetivo geral

Avaliar o potencial do uso de dados multiespectrais de média resolução espacial para predição e projeção do crescimento e da produção de florestas de eucalipto, bem como a possibilidade de redução no número de parcelas mensuradas no inventário florestal.

2.2 Objetivos específicos

- Selecionar a melhor configuração de redes neurais artificiais para a predição e projeção do crescimento e da produção da floresta de eucalipto analisada por meio de métricas obtidas pela transformação *tasseled cap* dos dados do sensor ETM+ do Landsat 7;
- Avaliar diferentes cenários de redução no número de parcelas mensuradas para predição e projeção do volume de povoamentos analisados;
- Analisar a projeção da dinâmica de crescimento da floresta por meio das taxas de incrementos médio mensal e corrente mensal, obtidas a partir dos dados de campo e de sensoriamento remoto.

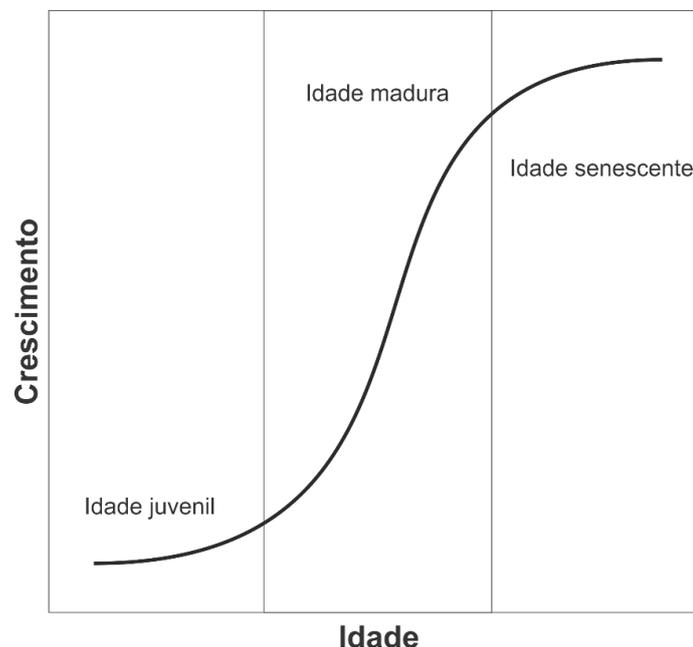
3 REVISÃO BIBLIOGRÁFICA

3.1 Modelagem do crescimento e da produção florestal

O crescimento florestal pode ser definido como o aumento das dimensões de um ou mais indivíduos em determinado período, podendo este incremento ser em diâmetro, altura, volume ou área basal (PRODAN et al., 1997). A produção refere-se ao crescimento acumulado ao final de um período em determinada área (VELOSO, 2013).

Em geral, o crescimento se assemelha a uma curva sigmoidal (Figura 1) com três períodos distintos da vida das árvores: a idade juvenil, onde ocorre o crescimento inicial; a fase do crescimento propriamente dito, que é a idade madura; e a idade de senescência, quando o crescimento é cada vez menor (VELOSO, 2013).

Figura 1 – Representação do crescimento em uma curva sigmoidal.



Fonte: Veloso (2013).

A partir do paradigma de que o crescimento da floresta segue a tendência de uma curva sigmoidal, surgiram os modelos de crescimento e produção florestal, que permitem simular a dinâmica natural de um povoamento e prever a sua produção ao longo do tempo (VANCLAY, 1994). Esses modelos são constituídos por uma ou mais

equações, incluindo variáveis independentes para estimar o crescimento (incremento nas variáveis dendrométricas) e a produção (por exemplo, o volume acumulado ao fim de um determinado período de tempo).

Existe uma grande variedade de modelos que permitem simular diferentes alternativas de manejo e os respectivos impactos sobre a estrutura da floresta (MAGALHÃES, 2014). De forma geral, os modelos podem ser divididos em dois tipos: modelos mecanísticos e empíricos.

Os modelos mecanísticos visam relacionar o processo do crescimento com suas causas, como disponibilidade de luz, temperatura, nutrientes e outros. Por fim, os modelos empíricos utilizam dados observados na floresta, como idade, índice de local e área basal para estimar o crescimento (VANCLAY, 1994). Os modelos empíricos podem ser divididos em: modelos de povoamento total (MPT), modelos de distribuição de diâmetros (MDD) e modelos de árvores individuais (MAI).

Os MPT são utilizados para estimar o crescimento ou a produção por unidade de área, e o volume por área é obtido a partir de variáveis como a idade do povoamento, o índice de local e a área basal (DAVIS et al., 2005). Essa categoria de modelo não fornece estimativas do tamanho das árvores, o que, no entanto, não limita o seu emprego quando o manejo é destinado à produção de um único produto, como celulose ou energia (CAMPOS; LEITE, 2017).

De acordo com Castro et al. (2013), os MPT vêm sendo utilizados amplamente pelas empresas florestais desde a década de 1980, em função de sua menor complexidade. Dentre os principais MPT utilizados, se destaca o de Clutter (1963), composto pelo sistema das Equações 1 e 2. Neste modelo a produção volumétrica (V_2) é expressa em função das idades atual e futura (I_1 e I_2), do índice de local (S) e da área basal atual e futura (G_1 e G_2).

$$\text{Ln}V_2 = \beta_0 + \left(\frac{\beta_1}{I_2}\right) + \beta_2S + \beta_3\text{Ln}G_2 + \text{Ln}\varepsilon \quad (1)$$

$$\text{Ln}G_2 = \text{Ln}G_1\left(\frac{I_1}{I_2}\right) + \alpha_0\left(1 - \frac{I_1}{I_2}\right) + \alpha_1\left(1 - \frac{I_1}{I_2}\right)S + \varepsilon \quad (2)$$

Os MDD representam um híbrido entre os de povoamento total e de árvores individuais (KERSHAW Jr. et al., 2016). Esses modelos têm como base funções

probabilísticas, permitindo descrever as alterações ocorridas na estrutura do povoamento, ou seja, expressam a frequência relativa esperada em cada classe de diâmetro (ABREU et al., 2002). Essa modelagem é realizada em dois estágios: primeiro, uma função densidade de probabilidade (f.d.p.) é ajustada aos dados de diâmetro de cada parcela e em cada medição; e, após isso, os parâmetros da f.d.p. são correlacionados com atributos do povoamento, tais como: idades e número de árvores presentes e futuras e diâmetros máximos (DAVIS et al., 2005; CAMPOS; LEITE, 2017). Esse segundo procedimento é denominado de recuperação dos parâmetros da f.d.p.

Segundo Kershaw Jr. et al. (2016), existem várias funções de densidade de probabilidade que são utilizadas em modelos de distribuição diamétrica no setor florestal, dentre as quais pode-se destacar a Beta, Gama e Weibull. Essas funções normalmente são utilizadas quando se tem assimetria no conjunto de dados.

A função Weibull com três parâmetros (Equação 3) é a mais utilizada nos modelos de distribuição para dados florestais, em função da sua flexibilidade para assumir diferentes formas e assimetrias, sendo assim, uma condição favorável para se aplicar no ajuste de dados provenientes de diferentes locais (WENDLING, 2011; CAMPOS; LEITE, 2017).

$$f(X) = \begin{cases} \frac{\gamma}{\beta} \left(\frac{X-\alpha}{\beta} \right)^{\gamma-1} e^{-\left(\frac{X-\alpha}{\beta}\right)^\gamma}, & \alpha \leq X < \infty, \alpha \geq 0, \beta > 0, \gamma > 0 \\ 0 \rightarrow \text{para outros casos} \end{cases} \quad (3)$$

em que: α = parâmetro de locação, no início da curva; β = parâmetro de escala da curva; γ = parâmetro de forma, que define o tipo de curva; X = variável da distribuição, centro de classe de diâmetro.

Segundo Davis et al. (2005), os MAI são os mais complexos, porém apresentam resultados mais detalhados, considerando a árvore como unidade de modelagem. Desta forma, a produção do povoamento é obtida pela soma da produção estimada de cada árvore. Além das informações das árvores, os MAI utilizam índices de competição para prever se a árvore permanecerá viva ou morrerá de acordo com a probabilidade de mortalidade, estimar crescimento em termos de diâmetro e altura (CAMPOS; LEITE, 2017). Os índices de competição expressam a capacidade da árvore competir com as suas vizinhas, podendo ser classificados como dependentes ou independentes da distância.

Kershaw Jr. et al. (2016) afirmam que os MAI dependentes da distância necessitam de informações sobre a localização de cada árvore (coordenadas x e y), bem como suas características (diâmetro à altura do peito e altura total) e os independentes da distância, apenas das variáveis dendrométricas das árvores. Segundo Scolforo (2006), os MAI independentes da distância apresentam resultados menos detalhados, sendo recomendados para povoamentos equiâneos, enquanto os MAIs dependentes da distância geram resultados que permitem mais análises, como a avaliação de práticas silviculturais, como o desbaste.

3.2 Princípios básicos de sensoriamento remoto

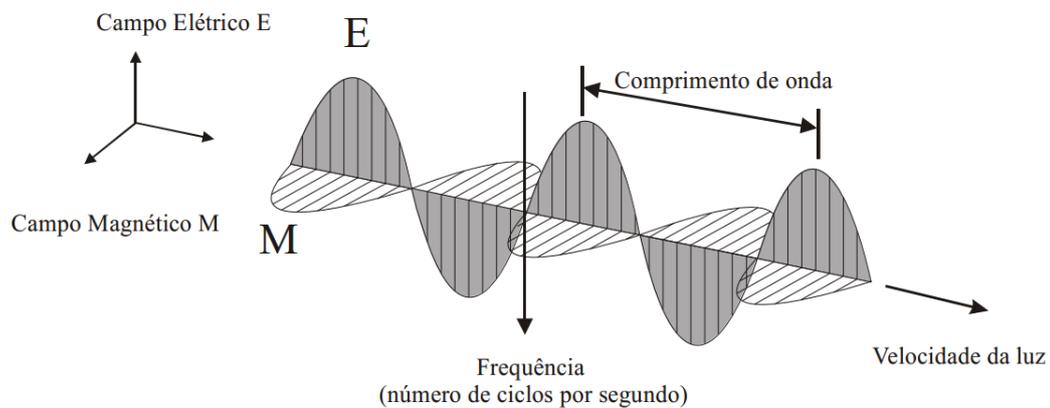
Sensoriamento remoto é o conjunto de atividades que permitem a aquisição de informações sobre objetos que compõem a superfície terrestre, sem que haja contato direto entre eles (MORAES, 2002). A sua origem ocorreu com a invenção dos primeiros sensores: as câmeras fotográficas. Segundo Novo (2010), sensoriamento remoto consiste na utilização conjunta de sensores, equipamentos para processamento e transmissão de dados e plataformas aéreas ou espaciais para carregar tais instrumentos e equipamentos, com o objetivo de estudar o ambiente terrestre por meio do registro e da análise das interações entre a radiação eletromagnética e as substâncias componentes da superfície. De acordo com esta definição, o sensor é o equipamento capaz de coletar energia eletromagnética emitida pela superfície terrestre, convertê-la em sinal passível de registro e apresentá-lo de forma adequada ao seu processamento.

De acordo com Moraes (2002), os sensores remotos podem ser classificados quanto a fonte de radiação eletromagnética (REM) em passivos e ativos. Os sensores passivos dependem de fontes externas de REM. Desta forma, eles operam registrando a energia emitida pelo sol que é refletida pela superfície terrestre. Por outro lado, os ativos possuem fontes próprias de energia eletromagnética, não dependendo de fontes externas de radiação.

Segundo Meneses e Almeida (2012), existem duas teorias que explicam o comportamento da REM: a corpuscular e a ondulatória. De acordo com a teoria

corpúscular, a REM transmite energia de um corpo para o outro de forma fixa e discreta, na forma de partículas (fótons). Na ondulatória, a REM pode ser explicada como uma forma de onda senoidal e harmônica, gerada a partir de perturbações nos campos elétrico e magnético, que é caracterizada por um comprimento de onda e uma frequência (Figura 2).

Figura 2 – Direção de propagação da radiação eletromagnética na forma de uma onda, em função das oscilações ortogonais dos campos magnético (M) e elétrico (E).



Fonte: Meneses e Almeida (2012).

A radiação eletromagnética natural forma um espectro contínuo, que contém diversos comprimentos de onda, que são divididos em faixas, chamadas de bandas espectrais (Tabela 1).

Tabela 1 – Limites de comprimento de onda e frequência das várias regiões do espectro eletromagnético.

| Intervalo espectral | Comprimento de onda (m) | Frequência (Hz) |
|----------------------------|--------------------------------|-----------------------------|
| Raios gama | $< 1.10^{-11}$ | $> 3.10^{19}$ |
| Raios X | 1.10^{-11} a 1.10^{-8} | 3.10^{16} a 3.10^{19} |
| Ultravioleta | 1.10^{-8} a 4.10^{-7} | $7.5.10^{14}$ a 3.10^{16} |
| Visível | 4.10^{-7} a 7.10^{-7} | 4.10^{14} a $7.5.10^{14}$ |
| Infravermelho | 7.10^{-7} a 1.10^{-3} | 3.10^{11} a 4.10^{14} |
| Micro-ondas | 1.10^{-3} a 1.10^{-1} | 3.10^9 a 3.10^{11} |
| Ondas de rádio | $> 1.10^{-1}$ | $< 3.10^9$ |

Fonte: adaptado de NASA (2013)

Quando a REM incide no topo da atmosfera terrestre, parte dela é espalhada ou refletida pelas partículas atmosféricas e outra parte atravessa a atmosfera,

atingindo a superfície. No momento em que a REM atinge o objeto alvo, a energia pode ser refletida, transmitida ou absorvida. Matematicamente, esses fenômenos são descritos da seguinte forma:

a) Reflectância: é o quociente entre o fluxo de radiação refletido pelo alvo dividido pela REM incidente (Equação 4):

$$\rho = \frac{\phi_r}{\phi_i} \quad (4)$$

Em que: ρ = reflectância; ϕ_r = radiação refletida; ϕ_i = radiação incidente.

b) Transmitância: é o fluxo de radiação transmitido pelo alvo dividido pelo fluxo de REM incidente (Equação 5):

$$\tau = \frac{\phi_t}{\phi_i} \quad (5)$$

Em que: τ = transmitância; ϕ_t = energia transmitida.

c) Absortância: é a razão entre a radiação absorvida pelo alvo e a incidente (Equação 6):

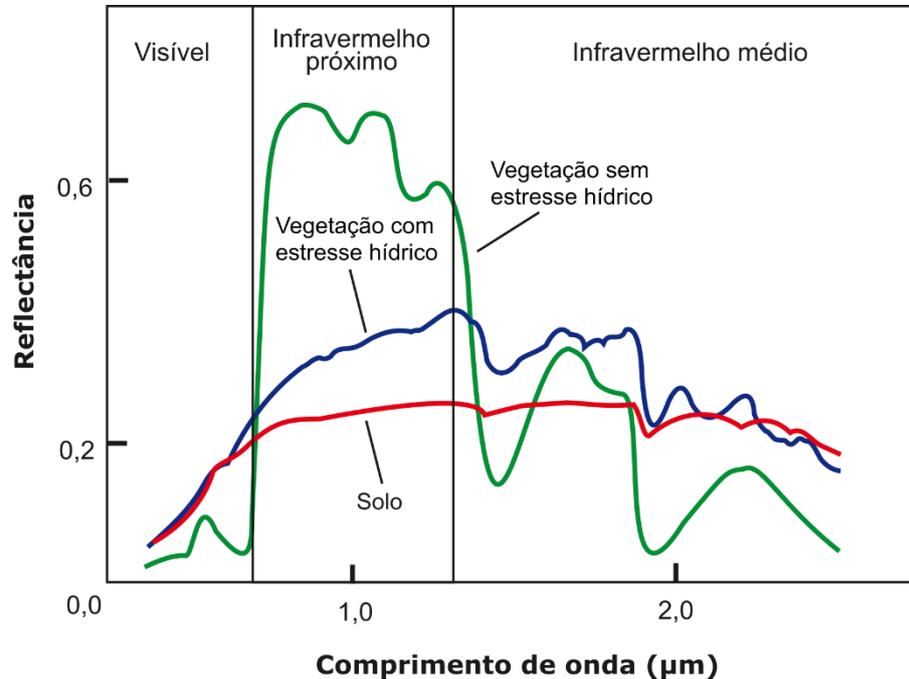
$$\alpha = \frac{\phi_a}{\phi_i} \quad (6)$$

Em que: α = absortância; ϕ_a = energia absorvida.

Os valores de reflectância, transmitância e absortância são adimensionais, variando de 0 a 1, de tal modo que $\rho + \tau + \alpha = 1$. A intensidade da REM refletida, absorvida ou transmitida depende do comprimento de onda, do ângulo de incidência, do tipo de matéria que constitui o corpo e das suas características físicas. Na Figura

3 é possível notar o comportamento da reflectância na vegetação verde, seca e no solo, nas diferentes faixas do espectro eletromagnético.

Figura 3 – Curva espectral da vegetação verde, vegetação seca e solo.



Fonte: Clark et al. (2003), adaptado pelo autor.

Como pode ser observado, na região do infravermelho próximo ocorre maior reflectância da vegetação sem estresse hídrico, o que permite uma melhor diferenciação e análise desse tipo de vegetação. Assim, os sensores remotos são capazes de registrar informações espectrais, espaciais e de textura das áreas florestais, permitindo que uma caracterização da floresta (WULDER, 1998).

3.3 Sensoriamento remoto para estudos da vegetação

3.3.1 Índices de vegetação

Uma das métricas mais utilizadas para análises da vegetação com dados de sensoriamento remoto são os chamados índices de vegetação. Esses índices são

combinações aritméticas de duas ou mais bandas relacionadas com características espectrais da vegetação (MATSUSHITA et al., 2007). Um dos primeiros índices de vegetação desenvolvidos é o índice da razão simples (RATIO) (Equação 7), cuja função é separar o solo da vegetação verde, gerando um forte contraste na imagem (EASTMAN, 1998).

$$RATIO = \frac{\rho_{Nir}}{\rho_{Red}} \quad (7)$$

Em que: ρ_{Nir} e ρ_{Red} = valores de reflectância dos comprimentos de onda do infravermelho próximo e vermelho, respectivamente.

Outros índices de vegetação são utilizados amplamente nas ciências florestais, destacando-se dentre eles o *Normalized Difference Vegetation Index (NDVI)*, o *Soil-Adjusted Vegetation Index (SAVI)* e o *Enhanced Vegetation Index (EVI)* (Equações 8, 9 e 10, respectivamente).

$$NDVI = \frac{\rho_{Nir} - \rho_{Red}}{\rho_{Nir} + \rho_{Red}} \quad (8)$$

$$SAVI = \frac{\rho_{Nir} - \rho_{Red}}{\rho_{Nir} + \rho_{Red} + L} (1 + L) \quad (9)$$

$$EVI = G \frac{\rho_{Nir} - \rho_{Red}}{\rho_{Nir} + (C_1 \rho_{Red} - C_2 \rho_{Blue}) + L} \quad (10)$$

Em que: L = fator de ajuste ao solo, sendo sugerido 1 para vegetação muito baixa, 0,5 para vegetação intermediária e 0,25 para vegetação densa; G = fator de ganho; ρ_{Blue} = valor da reflectância na banda espectral do azul e; C_1 e C_2 = coeficientes para correção de aerossóis.

O *NDVI* é o índice de vegetação mais utilizado e expressa o vigor vegetativo dos alvos, permitindo cancelar uma proporção de ruídos causados por alterações no

ângulo de incidência solar, topografia, nuvens ou sombras e condições atmosféricas (HUETE, 1999). Entretanto, o *NDVI* possui o inconveniente de apresentar saturação em regiões com vegetações densas. O índice *SAVI* visa minimizar os efeitos do solo de fundo na resposta espectral da vegetação ao incluir o fator de ajuste ao solo (*L*), permitindo análises em vegetações mais densas (HUETE, 1988). O *EVI* foi desenvolvido aliando a maior sensibilidade ao obter respostas em vegetações densas, como o *SAVI*, e a possibilidade de reduzir influências atmosféricas pelo espalhamento de aerossóis na banda do vermelho ao utilizar a banda do azul e os fatores C_1 e C_2 (MATSUSHITA et al., 2007).

3.3.3 Transformação Tasseled Cap

Uma alternativa interessante para analisar o desenvolvimento de culturas é utilizar a transformação Tasseled Cap (*TC*), também conhecida como transformação KT, iniciais dos seus desenvolvedores Kauth e Thomas (1976). O *TC* possui diversas vantagens em relação aos índices de vegetação (CRIST; CICONE et al., 1984) e revolucionou o entendimento sobre os padrões de crescimento das plantas no espaço espectral (BAIG et al., 2014).

De modo geral, a transformação *TC* permite reduzir a dimensionalidade dos dados pela transformação ortogonal dos valores nas bandas espectrais. Para sensores com quatro bandas, como o MSS a bordo dos primeiros satélites da série Landsat, é realizada uma ortogonalização Gram-Schmidt (CRIST; CICONE, 1984; HUANG et al., 2002; KAUTH; THOMAS, 1976). Entretanto, para sensores com maior número de bandas, é feita inicialmente uma análise de componentes principais e, em seguida, são rotacionados os eixos relativos aos três primeiros componentes do *TC* a fim de separar diferentes feições da cena em estudo.

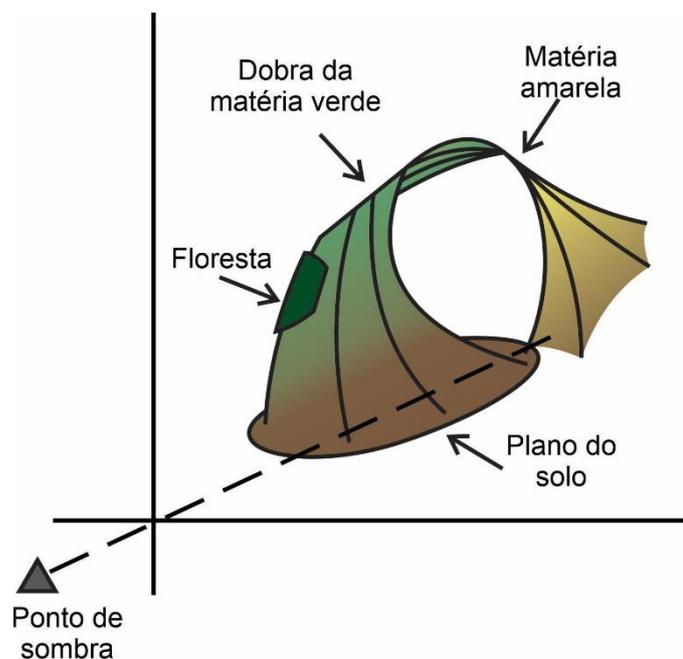
Inicialmente, Kauth e Thomas (1976), em seu trabalho, desenvolveram a transformação *TC* com dados do sensor MSS, que continha bandas na região do verde, vermelho e duas na região do infravermelho próximo. As componentes geradas com os dados desse sensor foram denominadas "*Brightness*", "*Greenness*" e

“*Yellowness*”, que se relacionam fisicamente com a variação espectral do solo, o vigor da vegetação verde e a vegetação senescente, mais amarelada, respectivamente.

Na Figura 4 é apresentada a estrutura básica do *TC*, criada pela combinação da reflectância do solo e da matéria verde, adicionando a matéria amarela. Esse gráfico demonstra a trajetória temporal dos pixels ao longo de todo o ciclo de vida de uma cultura (KAUTH; THOMAS, 1976). De acordo com estes autores, uma cultura inicia o seu crescimento com resposta espectral no plano do solo e, à medida que cresce, progride normal a esse plano, em trajetória curva em direção à região da matéria verde. Em seguida, as trajetórias se dobram e convergem para a região da matéria amarela, representando a senescência das culturas. Por fim, após a colheita, a resposta espectral retorna novamente ao solo.

Após o lançamento do Landsat 4, com o sensor TM e mais bandas espectrais, Crist e Cicone (1984) adaptaram o *TC* para esses novos dados, em espaço hexadimensional. Os dois primeiros componentes são “*Brightness*” e “*Greenness*”, assim como o *TC* com dados MSS se relacionam com o solo e a vegetação. Entretanto, o terceiro componente é denominado “*Wetness*” e descreve o teor de água dos alvos. Os demais componentes são ruídos e não possuíam relação física com os alvos.

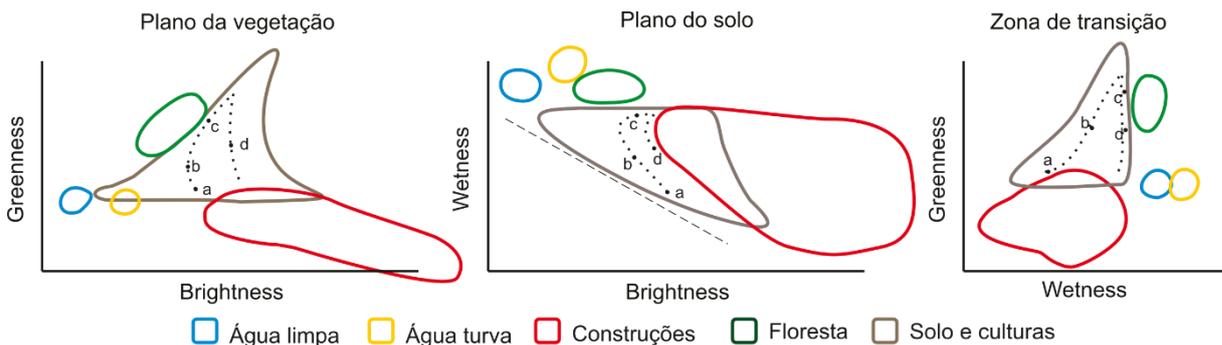
Figura 4 – Representação gráfica da transformação Tasseled Cap.



Fonte: Kauth e Thomas (1976), adaptado pelo autor.

De acordo com Crist e Cicone (1984), esses três componentes do TC podem ser combinados para definir três diferentes planos de visão permitindo uma melhor análise da cena: o plano da vegetação, o plano do solo e a zona de transição (Figura 5).

Figura 5 – Desenvolvimento espectral de culturas nos planos da vegetação, solo e zona de transição.



Fonte: Crist e Cicone (1984), adaptado pelo autor.

O desenvolvimento do ciclo de uma cultura pode ser observado na sequência da linha pontilhada, sendo (a) solo exposto, (b) vegetação emergente, (c) fechamento completo do dossel e (d) senescência. No plano da vegetação é possível observar que, à medida que as plantas começam a emergir, suas características espectrais causam um aumento no *Greenness*, enquanto a sombra que projetam diminui levemente o *Brightness* (ponto b). Com o desenvolvimento da cultura, a quantidade de solo exposto e área sombreada diminui, gerando um aumento no *Greenness* e *Brightness* (ponto c). Com a senescência, ocorre uma diminuição no *Greenness* e a variação no *Brightness* pode variar de acordo com a espécie analisada.

No plano do solo, a trajetória da cultura é semelhante ao plano da vegetação, também havendo uma diminuição do *Brightness* à medida que a cultura se desenvolve. Vale ressaltar que, nesse plano, floresta e água aparecem com valores próximos de *Wetness*, o que pode ser explicado pelo sombreamento do dossel. Outra característica importante desse plano é a possibilidade de análise da transição em relação à umidade. Ao seguir a seta tracejada é possível observar a água, solo úmido, solo seco e concreto. Por fim, o plano da zona de transição possui esse nome pois permite avaliar claramente a transição das culturas desde o plantio (ponto a), vegetação emergente (ponto b) e fechamento do dossel (ponto c), havendo aumento tanto nos valores de *Greenness* quanto de *Wetness*.

Com o lançamento de novos satélites com melhores instrumentos sensores, novas adaptações da transformação *TC* foram desenvolvidas, podendo-se citar os trabalhos de Huang et al. (2002) com o sensor ETM+ do Landsat 7, Baig et al. (2014) com o sensor OLI do Landsat 8 e Shi e Xu (2019) com o sensor MSI do Sentinel-2.

3.4 Aplicações de sensoriamento remoto passivo para o inventário florestal

O inventário florestal é uma técnica importante para a obtenção de informações sobre a quantidade e qualidade dos estoques florestais e sua predição, sendo fundamental para embasar a tomada de decisão do manejador (KERSHAW JR. et al., 2016).

O processo de coleta de dados varia de acordo com a finalidade de manejo, podendo ser realizada a medição de todos os indivíduos, chamado de censo, ou realizada uma amostragem, na qual são delimitadas frações representativas da floresta a serem medidas (CAMPOS; LEITE, 2017). Geralmente as empresas utilizam o processo de amostragem, em que as unidades amostrais, chamadas de parcelas, são distribuídas de acordo com o nível de detalhamento e acurácia desejada.

Para o acompanhamento do crescimento da floresta, são realizados os inventários florestais contínuos (*IFC*), no qual usualmente são distribuídas uma parcela a cada dez hectares, que são mensuradas todos os anos, de forma a fornecer informações de crescimento e produção do povoamento possibilitando análises de longo prazo. Para a obtenção de informações mais detalhadas sobre o real estoque da floresta a ser colhida, normalmente realiza-se um inventário próximo a data de colheita da floresta, chamado de inventário florestal pré-corte (*IPC*), com uma intensidade amostral maior, em torno de uma parcela a cada três hectares (CAMPOS; LEITE, 2017).

Tanto no *IFC* quanto no *IPC*, são mensurados os diâmetros a 1,30 m do solo (*DAP*) de todas as árvores das parcelas. Como a mensuração das alturas totais das árvores é um processo demorado que aumenta os custos do inventário florestal, normalmente são mensuradas as alturas de apenas algumas árvores. Posteriormente, é ajustado um modelo hipsométrico para estimar a altura das demais árvores tendo

como variável preditora o *DAP*. Para a obtenção do volume individual das árvores é realizado um processo denominado cubagem rigorosa, pelo qual algumas árvores são abatidas e têm seu fuste seccionado em partes menores. É calculado o volume de cada parte, sendo o somatório das partes o volume total da árvore. Semelhantemente às relações hipsométricas, o volume das demais árvores em geral é estimado por um modelo de dupla entrada, tendo como variáveis preditoras o *DAP* e a altura total. De posse do *DAP*, altura e volume individual de cada árvore, posteriormente os dados são processados e extrapolados para a área total (KERSHAW JR. et al., 2016).

Entretanto, apesar de serem mensuradas apenas algumas parcelas nos povoamentos, os esforços em campo possuem uma demanda elevada de tempo e alto custo de execução, principalmente na medição da altura e cubagem rigorosa das árvores, além de ser uma atividade que pode ser limitada por fatores climáticos (KERSHAW JR. et al., 2016; SANQUETTA et al., 2014). Diante disso, novas técnicas para obtenção de informações sobre os estoques florestais vêm sendo estudadas, a fim de reduzir as atividades em campo e seus custos de execução, mantendo a acurácia desejada. Dentre elas destaca-se o uso de ferramentas de sensoriamento remoto, que além de diminuir significativamente os esforços em campo, permitem o recobrimento total da área (BOYD; DANSON, 2005).

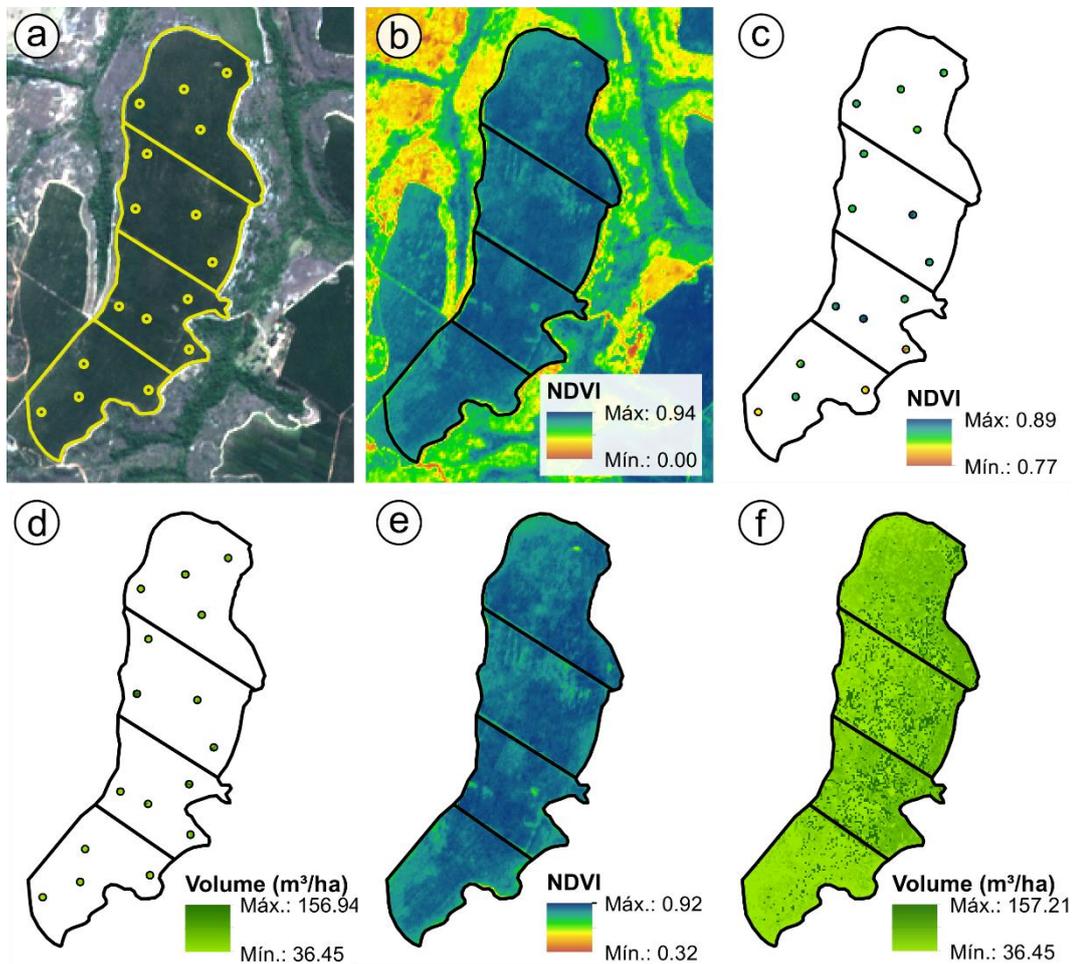
Nos últimos anos, há uma forte tendência de aplicação de diferentes técnicas de sensoriamento remoto no inventário florestal. O termo utilizado para descrever essa nova forma de obtenção de informações é inventário florestal aprimorado ou *enhanced forest inventory* (EFI) (WHITE et al., 2016). Nesse caso, o termo “aprimorado” se deve ao fato destas tecnologias utilizarem diversas fontes de dados para obter informações mais detalhadas sobre os povoamentos florestais. Dentre as principais técnicas utilizadas no inventário florestal aprimorado, pode-se citar o escaneamento laser aerotransportado (*Airborne Laser Scanning – ALS*), a fotogrametria aérea digital (FAD) e o sensoriamento remoto passivo, por meio de dados multiespectrais.

A seguir será apresentado um exemplo de utilização de dados de sensoriamento remoto passivo para a estimação do volume de madeira em um povoamento florestal. Para isso, os seguintes passos devem ser seguidos:

1. Obtenção dos arquivos vetoriais contendo os limites dos talhões e parcelas inventariados (Figura 6a);

2. Definição dos instrumentos sensores dos quais serão obtidos os dados e as métricas a serem calculadas. Neste exemplo, foi escolhido o sensor MSI do satélite Sentinel-2 e a métrica calculada foi o *NDVI* (Figura 6b). Vale ressaltar que podem ser utilizadas diferentes métricas, obtidas por vários sensores;
3. Extração das métricas para a área das parcelas inventariadas (Figura 6c). Isso pode ser feito em sistemas de informações geográficas (SIG) por meio de um recorte do arquivo matricial contendo o *NDVI* tendo como máscara de corte o arquivo vetorial dos limites das parcelas;
4. Uma vez de posse do valor médio de *NDVI* por parcela, os mesmos devem ser associados aos respectivos dados coletados em campo. Desta forma, deve ser elaborada uma planilha contendo o volume de cada parcela, obtido no inventário florestal, e o respectivo valor médio do *NDVI* da parcela;
5. Aplicação de métodos de estimação para modelar o volume de madeira do povoamento em função do *NDVI*. Diversas técnicas podem ser utilizadas, como modelos lineares, não lineares, redes neurais artificiais (*RNA*), random forest, dentre outros;
6. Estimação do volume por parcela (Figura 6d) e cálculo das estatísticas de acurácia, como medidas de erro, viés e outros. Caso o desempenho do método de estimação não seja satisfatório, é necessário analisar a aplicação de outros métodos ou obtenção de diferentes métricas;
7. Obtenção dos valores de *NDVI* para todos os talhões inventariados (Figura 6e). Essa etapa é semelhante à etapa 3, sendo que dessa vez, a máscara de recorte utilizada será o arquivo vetorial contendo os limites dos talhões;
8. Aplicação dos modelos ajustados para estimar o volume para toda a área, em nível de pixel (Figura 6f).

Figura 6 – Representação gráfica das etapas para aplicação de dados de sensoriamento remoto passivo para estimação do volume de madeira em povoamentos florestais.



Nos últimos anos, diversos estudos têm sido desenvolvidos na área florestal com o objetivo de utilizar técnicas de sensoriamento remoto para obter informações sobre as florestas plantadas e nativas. Lu et al. (2004) exploraram as relações entre a resposta espectral do Landsat TM 5 e a biomassa da parte aérea, área basal, diâmetro médio e altura média em uma floresta da região amazônica. Foi observado que os índices de vegetação que utilizaram as bandas espectrais TM4 e TM3 (infravermelho próximo e vermelho, respectivamente) possuem baixa correlação com tais parâmetros. As maiores correlações ocorreram quando foram utilizados índices de vegetação com a banda TM5 (infravermelho médio).

Na Caatinga brasileira, Almeida et al. (2014) utilizaram seis bandas espectrais oriundas do sensor Landsat TM 5, além de diferentes índices de vegetação, para estimar variáveis dendrométricas. Os autores concluíram que a técnica utilizada tem

potencial para explicar variações de altura média das árvores, com valor de coeficiente de determinação (R^2) de 0,40 e raiz quadrada do erro quadrático médio ($RMSE$) de 13%; e o volume de madeira por hectare ($R^2 = 0,60$; $RMSE = 42\%$). Neste estudo, as principais variáveis independentes foram a banda espectral do vermelho, o $NDVI$ e o índice de vegetação ajustado ao solo $SAVI$.

Em uma floresta plantada de *Pinus elliottii*, Berra (2013) concluiu que os sensores LISS-III/ResourceSat-1 e Landsat TM 5 apresentaram desempenho satisfatório para estimar o volume de madeira. Além disso, foi constatado que a metodologia empregada pode ser utilizada para auxiliar no inventário florestal, uma vez que as estimativas obtidas pelas imagens cobrem todo o talhão, enquanto a amostragem do inventário florestal utilizada contemplava menos de 2% da área.

Em povoamentos de *Eucalyptus urophylla*, Leal (2013) utilizou imagens do satélite Landsat TM 5 para estimar o volume a partir de índices de vegetação e comparar estimativas do interpolador geoespacial em relação ao inventário florestal tradicional. Esse autor obteve estimativas de volume de $245 \text{ m}^3\text{ha}^{-1}$ ao utilizar o interpolador geoestatístico e de $235 \text{ m}^3\text{ha}^{-1}$ no inventário florestal, não havendo diferença significativa pelo teste t ($\alpha < 0,05$). Além disso, obteve um erro amostral de 8,3% para o método proposto, enquanto no inventário foi de 8,4%.

Para prever a produção volumétrica de plantios de eucalipto aos cinco anos, Reis et al. (2018) utilizaram regressão linear múltipla, *Random Forest (RF)*, *Support Vector Machine (SVM)* e *RNA*, tendo como variáveis de entrada o $NDVI$, $SAVI$, EVI e outros cinco índices de vegetação. Considerando o conjunto de validação igual a 30% dos dados, esses autores encontraram valores de $RMSE$ variando de 13,58 a 16,72%.

Entretanto, apesar de serem bons para realizar análises da vegetação em estudos transversais, os índices de vegetação podem apresentar alguns inconvenientes ao serem utilizados para análises temporais durante todo o ciclo de uma cultura, como saturação a partir de determinada idade, especialmente no caso das florestas (GU et al., 2013). Para superar essa limitação, alguns pesquisadores utilizam as métricas extraídas do TC , citadas no item 3.3.3, por se correlacionarem bem com a idade das culturas e serem indicadas para análises de séries temporais.

Alguns estudos na área florestal utilizaram dados do TC com as mais variadas abordagens. Healey et al. (2005) utilizaram TC para detecção de distúrbios em áreas florestais pela sua habilidade de destacar mudanças relevantes na cobertura vegetal. Também com esse propósito, Jin e Sader (2005) compararam séries temporais de

Wetness e o índice de umidade da diferença normalizada, obtendo-se altos valores de coeficiente de determinação ($R^2 > 0,95$), não havendo diferença entre elas.

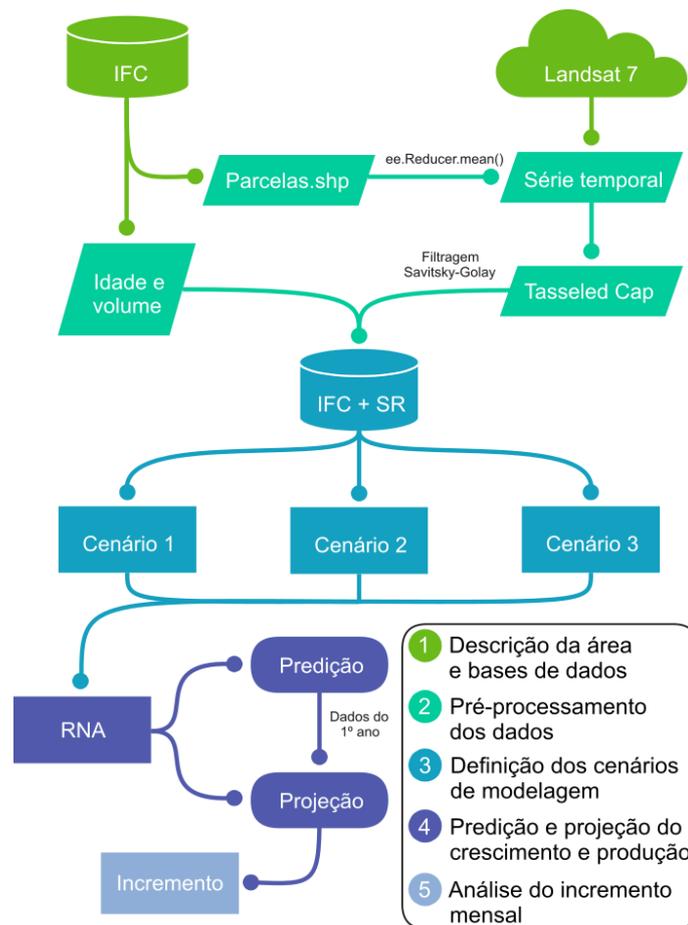
Chen et al. (2018) utilizaram as bandas do sensor TM, *NDVI*, *RATIO* e *TC* para estimar a idade de povoamentos de seringueira em áreas afetadas por furacões e danos por frio na China. Os autores observaram que a inclusão das métricas do *TC* nos modelos melhorou a acurácia das estimativas. Heo et al. (2006) também utilizaram o *TC*, aliado ao *NDVI* para estimar a idade de povoamentos nos estados de Oregon e Washington, nos Estados Unidos. Com o mesmo objetivo, Sivanpillai et al. (2006) também aplicaram métricas do *TC* para estimar a idade de povoamentos de *Pinus taeda* L.

O fato das métricas do *TC* se correlacionarem bem com a idade dos povoamentos pode ser um forte indicativo do potencial dessa métrica em estudos sobre o crescimento de florestas.

4 METODOLOGIA

A metodologia utilizada para execução das análises deste estudo é apresentada na Figura 7 e explicada detalhadamente a seguir.

Figura 7 – Fluxograma metodológico para prognose do crescimento e da produção de florestas de eucalipto com dados de sensoriamento remoto.

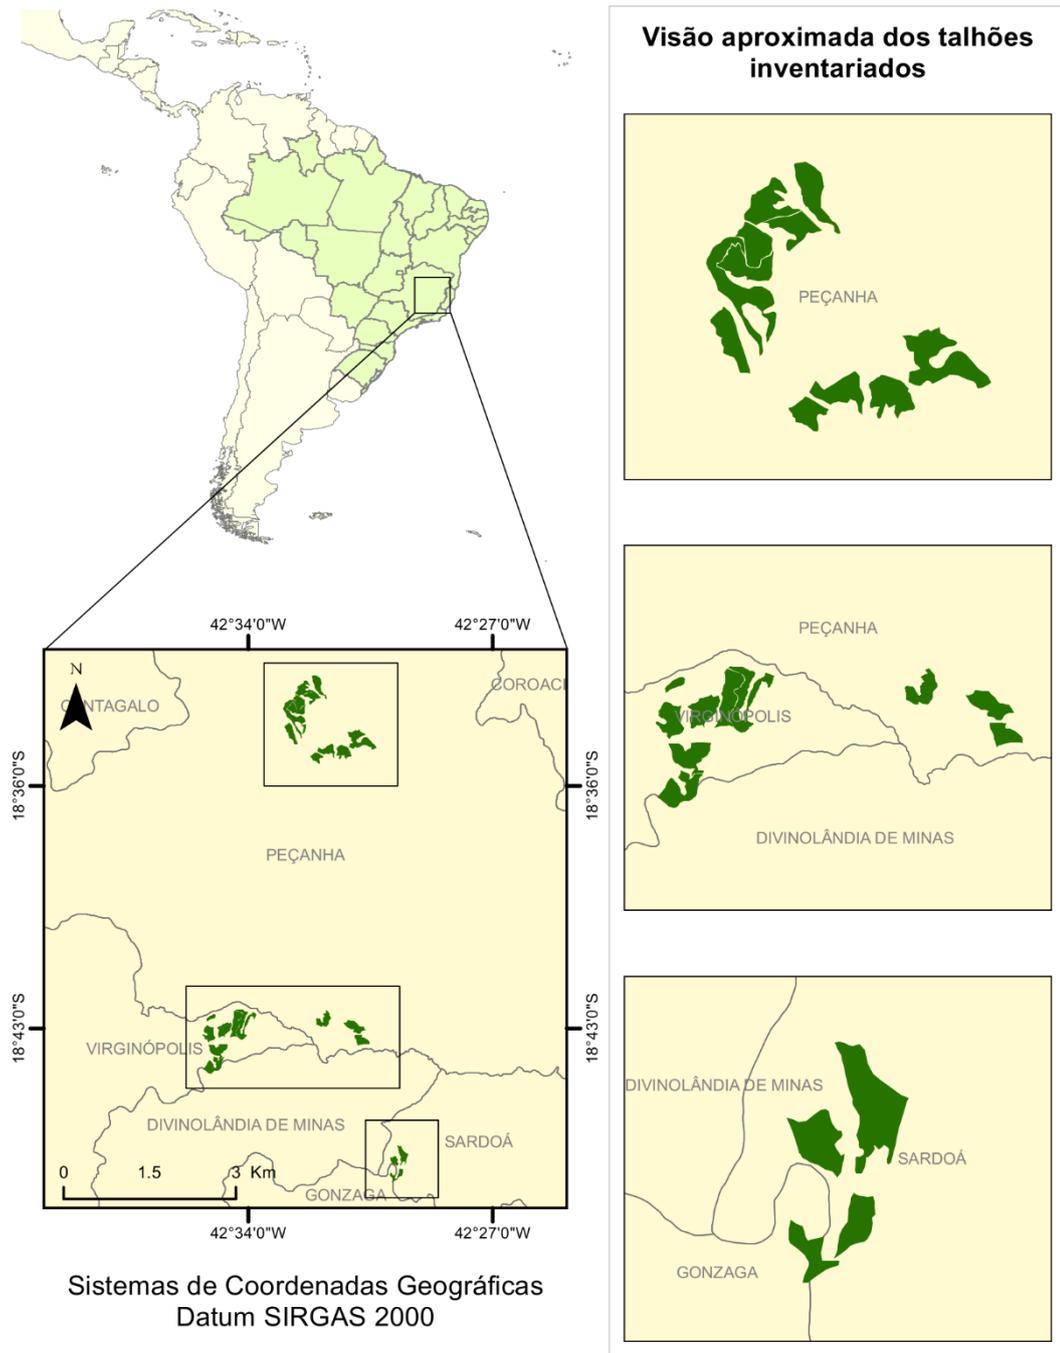


4.1 Descrição da área de estudo e das bases de dados

Este estudo foi realizado em uma área com aproximadamente 833 ha, constituída por diferentes materiais genéticos do híbrido *Eucalyptus grandis* x *Eucalyptus urophylla*, em espaçamento 3 x 3 m, localizados na mesorregião do Vale

do Rio Doce, no estado de Minas Gerais, Brasil (Figura 8). O clima da região é caracterizado como subtropical úmido, com invernos secos e verões quentes (Cwa). A precipitação média anual é de 1364 mm, com temperatura média anual de 20,5° C. O relevo da região é considerado acidentado, com altitude variando de 750 a 1.000 metros acima do nível do mar.

Figura 8 – Localização da área de estudo.



4.1.1 Banco de dados do Inventário Florestal Contínuo

Os dados de campo foram obtidos em 40 parcelas permanentes, com forma circular e área de aproximadamente 300 m², distribuídas de forma aleatória nos talhões. A intensidade amostral utilizada no *IFC* foi de uma parcela para 21 ha, aproximadamente. As parcelas foram mensuradas anualmente, nos meses de junho a agosto, durante os anos de 2006 a 2011. As idades variaram de 20,44 meses no primeiro ano a 93,50 meses na última medição. Nos inventários, foram coletados dados de diâmetro à 1,30 m do solo (*DAP*) de todas as árvores. A altura das árvores foi estimada por meio de Redes Neurais Artificiais (*RNA*) e o volume individual foi estimado por meio de um modelo de regressão não linear ajustado previamente (Equação 11). Maiores informações sobre o processo de estimação da altura e do volume podem ser encontradas em Fraga Filho (2016). Assim, a base de dados de inventário florestal utilizada na modelagem consistiu em informações em nível de parcela, com valores de idade em meses e volume em metros cúbicos de madeira por hectare (m³ha⁻¹).

$$V = e^{-10,1399+1,8684\ln(DAP)+1,0778\ln(Ht)} \quad (11)$$

Em que: V = volume individual (m³); DAP = diâmetro à 1,30 m do solo (cm) e; Ht = altura total da árvore (m).

4.1.2 Banco de dados de sensoriamento remoto

Todo o processamento dos dados de sensoriamento remoto foi realizado em nuvem, na plataforma Google Earth Engine (*GEE*) (GORELICK et al., 2017). No processamento foi utilizada a coleção de imagens do sensor ETM+ do Landsat 7, considerado de média resolução espacial, em que cada pixel da imagem corresponde a 900 m² (30 x 30 m). A coleção escolhida no GEE foi a LANDSAT/LE07/C01/T1_TOA, que contém dados de reflectância corrigidos para o topo de atmosfera, com cenas consideradas de alta qualidade e adequadas para análises de séries temporais, com

radiometria bem caracterizada e que são intercalibradas entre os diferentes sensores Landsat, corrigidas espacialmente.

4.2 Pré-processamento dos dados

4.2.1 Processamento do inventário florestal contínuo

O delineamento adotado no inventário florestal foi de amostragem estratificada. Essa estratificação foi realizada a nível de projeto, que é um tipo de estratificação administrativa feito por empresas florestais. Neste caso, cada projeto corresponde a uma fazenda da empresa. Informações detalhadas sobre a composição dos estratos são apresentadas na Tabela 2.

Tabela 2 – Detalhamento dos estratos de amostragem.

| Estrato | Mês de plantio* | Nº de materiais genéticos | Nº de parcelas | Área (ha) |
|----------------|------------------------|----------------------------------|-----------------------|------------------|
| 1 | Abril | 2 | 3 | 66,39 |
| 2 | Janeiro e agosto | 4 | 5 | 191,24 |
| 3 | Maio a junho | 5 | 12 | 270,33 |
| 4 | Novembro a dezembro | 5 | 12 | 215,41 |
| 5 | Agosto | 4 | 5 | 55,92 |
| 6 | Maio | 1 | 3 | 33,97 |

*Todos os plantios foram realizados no ano de 2004.

Além disso, também foi realizado o cálculo da média estratificada (Equação 12), o erro relativo de amostragem (Equação 13) e o intervalo de confiança para o inventário florestal estratificado (Equação 15) para cada ano do *IFC* (KERSHAW Jr. et al., 2016).

$$\bar{X}_{st} = \sum_{h=1}^L W_h \bar{X}_h \quad (12)$$

$$E_r = \pm \frac{ts_{\bar{x}_{st}}}{\bar{x}_{st}} 100 \quad (13)$$

$$s_{\bar{x}_{st}} = \sqrt{\sum_{h=1}^L W_h^2 \frac{s_h^2}{n_h}} \quad (14)$$

$$IC_{(1-\alpha)} = \bar{x}_{st} \pm ts_{\bar{x}_{st}} \quad (15)$$

Em que: \bar{x}_{st} = média estratificada da variável de interesse; L = número de estratos; W_h = proporção da área do estrato h em relação à população; \bar{x}_h = média da variável de interesse no estrato h ; $IC_{(1-\alpha)}$ = intervalo de confiança a $1-\alpha$ de probabilidade ($\alpha = 0,05$); t = valor da estatística t de Student (2,4469); $s_{\bar{x}_{st}}$ = erro padrão da média estratificada; s_h^2 = variância do estrato h e; n_h = número de parcelas no estrato h .

O resultado dos cálculos do inventário florestal estratificado está apresentado na Tabela 3. As médias populacionais obtidas nos inventários florestais, incluindo os respectivos intervalos de confiança, foram utilizados como parâmetro de comparação da acurácia das estimativas de predição e projeção do crescimento e produção em volume, obtidas a partir dos dados de sensoriamento remoto.

Tabela 3 – Resultado dos estimadores populacionais do inventário florestal estratificado para os povoamentos de eucalipto da área de estudo.

| Ano | Idade média (meses) | \bar{x}_{st} | $S_{\bar{x}_{st}}$ | E_r | Intervalo de confiança da média estratificada | |
|------|---------------------|----------------|--------------------|-------|---|----------|
| | | | | | LI | LS |
| 2006 | 24,79 | 59,5535 | 3,9253 | 16,13 | 49,9486 | 69,1585 |
| 2007 | 34,25 | 133,8389 | 5,4029 | 9,88 | 120,6184 | 147,0595 |
| 2008 | 48,17 | 199,8599 | 7,0382 | 8,62 | 182,6381 | 217,0816 |
| 2009 | 59,33 | 249,9566 | 7,2999 | 7,15 | 232,0944 | 267,8187 |
| 2010 | 71,49 | 296,9985 | 8,6875 | 7,16 | 275,7409 | 318,2561 |
| 2011 | 85,88 | 333,3848 | 10,9556 | 8,04 | 306,5773 | 360,1922 |

Em que: \bar{x}_{st} = média estratificada (m^3ha^{-1}); $S_{\bar{x}_{st}}$ = erro padrão da média estratificada (m^3ha^{-1}); E_r = erro relativo de amostragem (%); LI e LS = limite inferior e limite superior do intervalo de confiança para a média estratificada a 95% de probabilidade.

4.2.2 Processamento dos dados de sensoriamento remoto

A primeira etapa consistiu na aquisição da coleção de imagens do Landsat 7 (LANDSAT/LE07/C01/T1_TOA) e realização da transformação *TC*. Não foram utilizados os índices de vegetação tradicionais, pois as métricas do *TC* são mais adequadas para avaliar o crescimento de plantas, como explicado no item 3.3.3. Foram selecionados apenas os três primeiros índices do *TC* (*Brightness*, *Greenness* e *Wetness*), por serem os que possuem relação teórica com o crescimento vegetal. Os valores para a transformação estão na Tabela 4, conforme Huang et al. (2002). Essa transformação foi feita com a função “*image.expression()*” do GEE, para multiplicar o valor dos pixels de cada banda pelos respectivos coeficientes.

Tabela 4 – Coeficientes da transformação *Tasseled Cap* para dados do sensor ETM+ do Landsat 7.

| Índice | Bandas espectrais | | | | | |
|-------------------|-------------------|---------|----------|--------|---------|---------|
| | Azul | Verde | Vermelho | NIR | Swir1 | Swir2 |
| <i>Brightness</i> | 0,3561 | 0,3972 | 0,3904 | 0,6966 | 0,2286 | 0,1596 |
| <i>Greenness</i> | -0,3344 | -0,3544 | -0,4556 | 0,6966 | -0,0242 | -0,2630 |
| <i>Wetness</i> | 0,2626 | 0,2141 | 0,0926 | 0,0656 | -0,7629 | -0,5388 |

Em que, NIR = infravermelho próximo; Swir1 = infravermelho de ondas curtas 1 e; Swir2 = infravermelho de ondas curtas 2. Fonte: Huang et al. (2002).

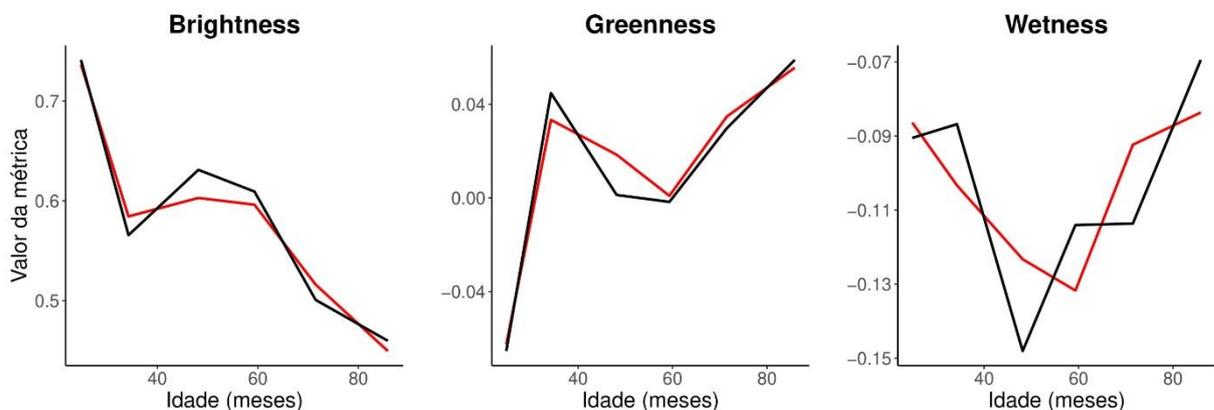
Após a transformação *TC*, foram selecionadas as imagens dos meses de junho a agosto para representar os dados anuais. Essa escolha se deu pelo fato de esses meses apresentarem menor cobertura de nuvens na região e por coincidir com a data de realização dos levantamentos em campo do *IFC*. Desta forma, foi feita uma filtragem no GEE para aquisição das imagens no período de 2006 a 2011. Em seguida, foi aplicado um filtro de mediana para os valores dos pixels entre os meses de junho e agosto de cada ano, a fim de se obter o melhor pixel. Assim, foram geradas seis imagens, uma para cada ano do *IFC* (2006 a 2011), com os valores medianos do *Tasseled Cap* entre os meses de junho a agosto.

De posse das imagens, foi utilizada a função “*ui.Chart.image.seriesByRegion()*”, que permite extrair e plotar um gráfico com o valor da banda especificada para cada região e para cada uma das imagens da coleção

(2006 a 2011). Para definir as regiões nas quais seriam extraídas as métricas, foi utilizado um shapefile indicando os limites das parcelas do *IFC* e foi aplicada a função “*ee.Reducer.mean()*”, que permite uma redução dos valores dos pixels da imagem para uma área de um polígono vetorial. Após a geração dos gráficos de evolução temporal do *Brightness*, *Greenness* e *Wetness*, foi realizado o download dos dados em planilha no formato “*csv*”, contendo os valores dessas métricas durante os anos de 2006 a 2011 para todas as 40 parcelas.

Por fim, foi realizada a filtragem Savitzky-Golay para a suavização e redução de ruídos nos dados das séries temporais (CAO et al., 2018; CHEN et al., 2004; SAVITZKY; GOLAY, 1964). Para tanto, foi utilizado a função “*sgolayfilt*” do pacote “*signal*” do software R versão 3.6.2 (LIGGES et al., 2015; R CORE TEAM, 2019). Na Figura 9 encontram-se os valores médios originais das métricas *brightness*, *greenness* e *wetness* em preto e após a aplicação do filtro, em vermelho.

Figura 9 – Valores médios de *brightness*, *greenness* e *wetness* originais, em preto, e após a filtragem Savitzky-Golay, em vermelho.



4.3 Definição dos cenários de modelagem para predição e projeção do crescimento e produção de povoamentos de eucalipto

A base de dados utilizada no ajuste e validação dos modelos de crescimento e produção foi composta por dados de idade e volume das parcelas, obtidas no *IFC*, e

os respectivos valores das métricas *Brightness*, *Greenness* e *Wetness*, com a filtragem Savitzky-Golay.

Adicionalmente, foram estabelecidos três diferentes cenários de modelagem para verificar a possibilidade de redução no número de parcelas mensuradas para o treinamento dos modelos. Desta forma, o cenário 1 consistiu na utilização dos dados de inventário na intensidade amostral de uma parcela para cada 28 ha, totalizando 30 parcelas; no cenário 2, a intensidade foi de uma parcela para cada 42 ha, totalizando 20 parcelas; e no cenário 3, a intensidade amostral foi de uma parcela para cada 83 ha, totalizando 10 parcelas. A seleção das parcelas que iriam compreender o conjunto de treino, segundo a intensidade amostral de cada cenário, foi feita de forma aleatória, sendo que as parcelas não selecionadas para o conjunto de treino foram utilizadas para a validação.

4.4 Predição e projeção do crescimento e produção dos povoamentos de eucalipto

A predição e projeção do crescimento e produção foi feita com Redes Neurais Artificiais (RNA) *multilayer perceptron* do tipo *feedforward* com algoritmo de treinamento Levenberg-Marquardt. Os critérios de parada foram o número de épocas igual a 1.000 e a parada antecipada (*early stopping*). Os parâmetros a serem definidos foram o número de neurônios na camada oculta e a função de ativação. Para tanto, foi utilizado o toolbox *Neural Network software* Matlab R2016a (MATHWORKS, 2016).

4.4.1 Predição do volume dos povoamentos de eucalipto

A predição da produção volumétrica foi realizada considerando-se como variáveis de entrada a idade do povoamento, obtida com os dados de cadastro do inventário florestal, e os valores do *TC* (*Brightness*, *Greenness* e *Wetness*) referentes

às parcelas do inventário. A variável de saída foi o volume por hectare. Dessa forma, não foi utilizada nenhuma variável dendrométrica para estimar o volume, o que permite a aplicação desse modelo em áreas nas quais não foram realizados levantamentos de inventários florestais.

Inicialmente, foram parametrizados o número de neurônios na camada oculta da *RNA* e a função de ativação. O número de neurônios variou de 1 a 20 e as funções de ativação testadas foram a logística e a tangente hiperbólica. Foram treinadas 50 *RNA* para cada configuração, gerando um total de 2.000 redes. A parametrização das *RNA* para a predição foi realizada com toda a base de dados, dividida em 70% para treino e 30% para validação. Foi selecionada como melhor estrutura de rede aquela que apresentou menor raiz quadrada do erro quadrático médio (*RMSE* – Equação 18) na validação.

Uma vez selecionada a melhor estrutura de rede para a predição, foram treinadas 1.000 *RNA* para cada um dos cenários para análise da distribuição dos valores de *RMSE* e Viés (Equação 17). Após confirmação da normalidade da distribuição do *RMSE* e Viés, foi treinada apenas uma rede para cada cenário, das quais foram obtidas as estimativas de volume do povoamento em nível de parcela e para toda a área de estudo, em nível de pixel.

4.4.2 Projeção do volume dos povoamentos de eucalipto

A projeção do crescimento e produção florestal permite a estimação do volume em momento futuro, tendo como base o valor atual. Para estimar o volume do povoamento em idade futura (V_2) foram consideradas as variáveis de entrada: idade atual (I_1), idade futura (I_2) e o volume referente à idade atual (V_1). Com isso, foi possível modelar o crescimento e a produção volumétrica sem utilizar variáveis medidas em campo, apenas a idade do povoamento e o volume inicial, estimado com os dados de sensoriamento remoto. O processo de parametrização das *RNA* para a projeção foi idêntico ao utilizado na predição.

Nesta modelagem, foi utilizado todo o conjunto de dados (treino e validação) no cálculo dos critérios para avaliar a acurácia da validação, sendo o V_1 aquele obtido na etapa de predição. O volume do segundo ano (V_2) foi projetado a partir do V_1 , já o

volume do terceiro ano (V_3) foi projetado a partir do V_2 estimado e assim por diante até o sexto ano.

Inicialmente foi realizada a projeção em nível de parcela e, em seguida, para toda a área, considerando como V_1 as informações de volume (mapa) para o primeiro ano do *IFC* (2006), obtidas na etapa de predição para toda a área e as idades futuras correspondentes às datas de realização dos inventários nos anos seguintes.

4.4.3 Critérios para avaliação da acurácia do treino e validação das RNA nos diferentes cenários

A acurácia da predição e projeção do crescimento e produção em volume dos povoamentos, para dados de treinamento e validação, foi avaliada por meio das estatísticas coeficiente de correlação linear entre os valores observados e estimados (r), viés (V) e *RMSE*, apresentados na Tabela 5.

Tabela 5 – Estatísticas utilizadas para avaliar o desempenho das estimativas.

| Estatísticas | Fórmulas | |
|--|--|---|
| Coeficiente de correlação | $r_{yy} = \frac{\sum_{i=1}^n (y_i - \bar{y})(\hat{y}_i - \hat{y}_m)}{\sqrt{\left[\sum_{i=1}^n (y_i - \bar{y})^2 \right] \left[\sum_{i=1}^n (\hat{y}_i - \hat{y}_m)^2 \right]}} \quad (16)$ | |
| Viés | $V(\%) = \frac{V}{y} 100$ | $V = \frac{\sum_{i=1}^n y_i - \sum_{i=1}^n \hat{y}_i}{n} \quad (17)$ |
| Raiz quadrada do erro quadrático médio | $RMSE(\%) = \frac{RMSE}{y} 100$ | $RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad (18)$ |

Em que: y_i = variável dependente observada; \hat{y}_i = variável dependente estimada; \bar{y} = média da variável dependente observada; \hat{y}_m = média da variável dependente estimada; n = número de observações.

De forma complementar, foi realizada uma análise nos gráficos dos valores de volume estimados em função da idade, valores observados versus estimados e do

histograma dos erros percentuais. O erro percentual de cada estimativa foi calculado de acordo com a Equação 19:

$$E_i(\%) = \frac{\hat{y}_i - y_i}{y_i} 100 \quad (19)$$

No gráfico dos valores estimados em função da idade foram adicionadas linhas referentes a média dos valores estimados e a média estratificada obtida com os dados de inventário florestal. Além disso, também foi apresentado de forma gráfica o intervalo de confiança do inventário florestal.

Em nível de parcela, as estatísticas da Tabela 4 foram calculadas considerando como valores de volume observado aqueles mensurados nas parcelas. Já na estimação para toda a área, essas estatísticas foram calculadas considerando como o valor de volume observado de cada pixel a média do estrato em que o pixel se localiza.

Por fim, foi realizada uma comparação entre a média estratificada obtida pelo *IFC* e a média estimada para toda a área (média dos pixels) para cada ano. Com isso, foi possível comparar a diferença percentual entre a média estimada pela amostragem em campo e pelos três diferentes cenários analisados, para predição e projeção.

4.5 Análise do incremento mensal

O conhecimento do incremento médio mensal (*IMM*) e incremento corrente mensal (*ICM*) de uma floresta pode gerar informações importantes sobre a dinâmica de crescimento dos povoamentos (KERSHAW Jr. et al., 2016). O *IMM* representa o quanto a floresta cresceu por mês, em média, até a idade atual, e foi calculado pela produção volumétrica atual (Y_i) dividida pela idade da floresta (I), em meses. O *ICM* representa o quanto a floresta cresceu do mês anterior até o atual, sendo calculado pela diferença entre a produção volumétrica atual (Y_i) e a produção do ano anterior (Y_{i-1}).

A modelagem do crescimento realizada nesse estudo, tanto para predição, quanto para a projeção, foi realizada anualmente, de acordo com a periodicidade de mensuração das parcelas no *IFC*. Para a obtenção das informações de incremento em escala mensal, foi ajustado o modelo de Gompertz a partir dos dados de *IFC*, adotados como referência, e dos mapas anuais de projeção volumétrica dos três cenários analisados. Este modelo foi escolhido após uma análise preliminar entre os modelos de Gompertz, Logístico e de Chapman-Richards. Na Tabela 6 encontra-se o modelo de Gompertz com os parâmetros estimados para os dados de *IFC* e dos três cenários.

Tabela 6 – Modelo de Gompertz ajustado para obtenção dos dados de produção volumétrica em escala mensal.

| Fonte de dados | Modelo Ajustado* | RMSE (%) | Viés (%) |
|----------------|---------------------------------------|----------|----------|
| <i>IFC</i> | $V = 409,108 e^{-1.330} e^{-0.034} I$ | 0,80 | -0,005 |
| Cenário 1 | $V = 398,009 e^{-1.416} e^{-0.037} I$ | 0,83 | -0,006 |
| Cenário 2 | $V = 401,562 e^{-1.408} e^{-0.036} I$ | 1,24 | -0,009 |
| Cenário 3 | $V = 416,203 e^{-1.420} e^{-0.035} I$ | 1,28 | -0,010 |

Em que: V = produção volumétrica (m^3ha^{-1}) e I = idade (meses). * Em todos os casos, os parâmetros foram significativos (p -valor < 0,01).

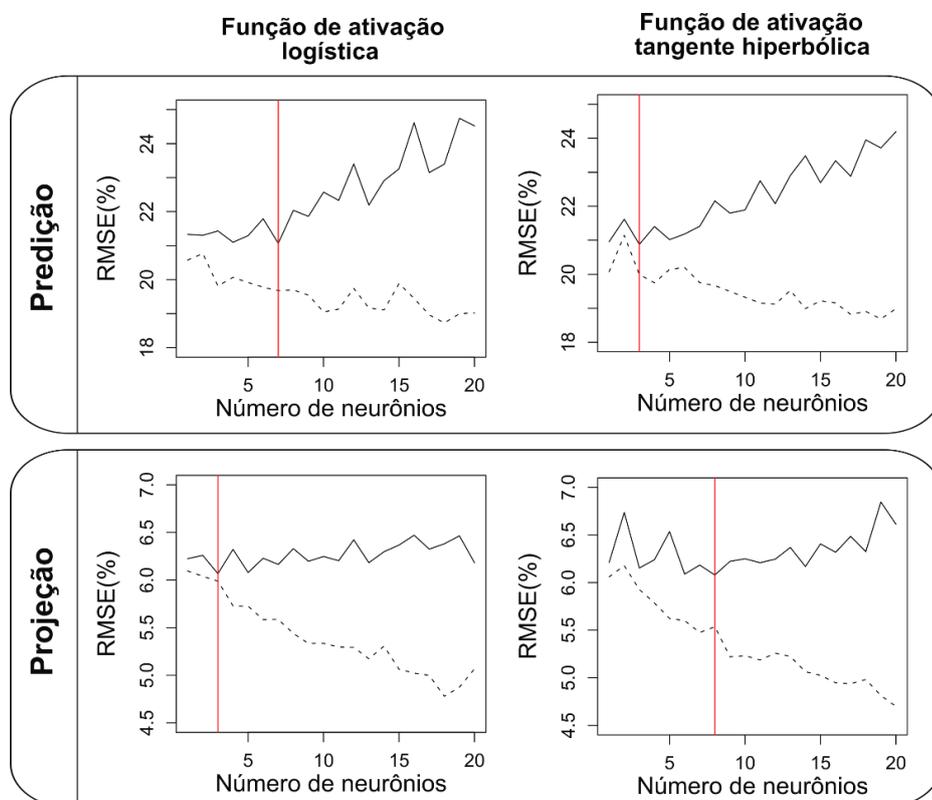
A partir dos dados mensais de incremento foram determinados o ponto de máximo *IMM*, que define o ponto de inflexão da curva de crescimento, e o máximo *IMM*, que representa o estágio final de maturidade da floresta e a idade técnica de colheita (*ITC*).

5 RESULTADOS E DISCUSSÃO

5.1 Parametrização das Redes Neurais Artificiais

O resultado da parametrização das *RNA* para a predição e projeção do volume de povoamentos de eucalipto para os diferentes cenários encontra-se na Figura 10. Tanto para a predição quanto para a projeção, com ambas as funções de ativação, é possível notar que à medida que se aumenta o número de neurônios, o *RMSE* do treino diminui e o da validação aumenta, indicando ocorrência de *overfitting*. Isso indica que não se faz necessário o uso de muitos neurônios para a predição e projeção do volume a partir de dados de sensoriamento remoto, o que pode ser explicado pelo número reduzido de variáveis de entrada para a predição (quatro) e projeção (três).

Figura 10 – Seleção da função de ativação e número de neurônios da *RNA* para a predição e projeção do volume de povoamentos de eucalipto.



Em que: - - - = treino; — = validação; e | = ponto no qual ocorre menor *RMSE* na validação.

Para a predição, a melhor configuração foi com a função de ativação tangente hiperbólica e três neurônios na camada oculta, enquanto para a projeção, foi selecionada a função de ativação logística com três neurônios na camada oculta. O número de neurônios foi o fator que mais influenciou no *RMSE* da validação, sendo apenas três neurônios necessários para prever e projetar o volume de madeira dos povoamentos de eucalipto. Quanto às funções de ativação analisadas, não houve muita variação no *RMSE*, ficando as diferenças na ordem de casas decimais.

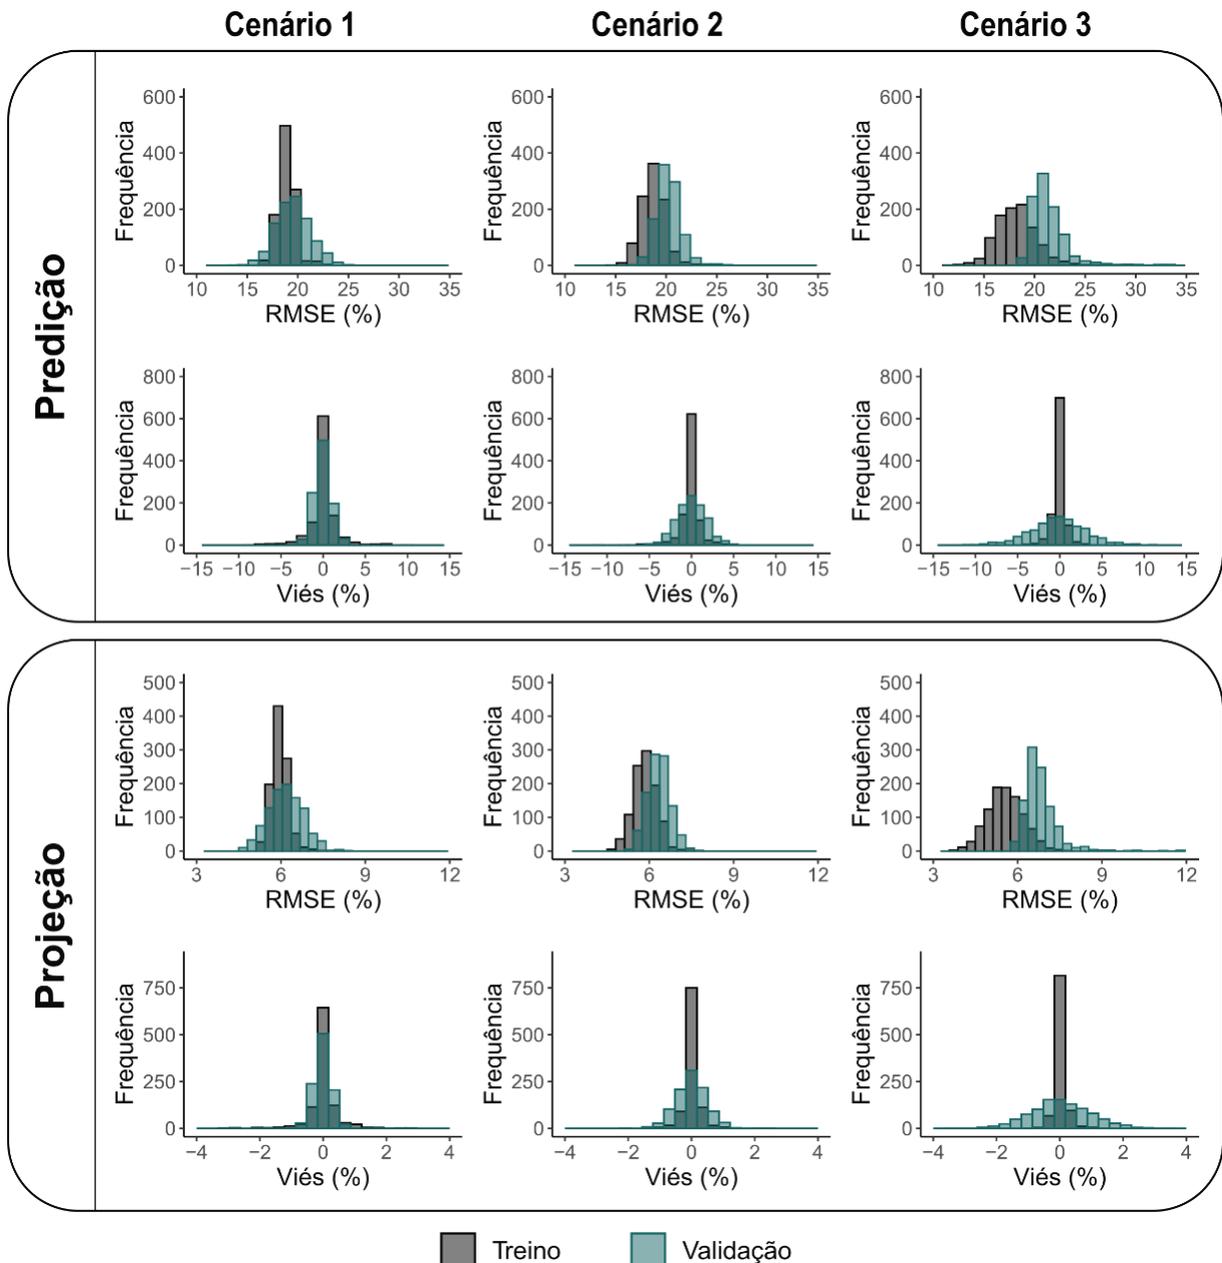
Na Figura 11 encontram-se os histogramas dos valores de *RMSE* e viés gerados a partir do treinamento de 1.000 *RNA*, com as melhores configurações selecionadas, para predição e projeção, para os cenários 1, 2 e 3. Ao analisar os histogramas do *RMSE* e do viés para a predição e projeção, é possível notar que houve uma distribuição normal dos valores em todos os cenários, tanto para o treino quanto para a validação. Apesar dos valores de *RMSE* e viés para a projeção serem menores que os obtidos na predição, o comportamento dos histogramas em relação aos cenários foi semelhante, tanto para o treino quanto para a validação.

Ao observar os valores de *RMSE* para o treino, pode-se notar uma tendência de achatamento da distribuição dos dados, com características leptocúrtica no cenário 1 e platicúrtica no cenário 3. Isso ocorre porque, com mais dados disponíveis para o treino (cenário 1), o desempenho das *RNA* tende a ser mais estável, não havendo muita variação no *RMSE* das 1.000 redes treinadas. Em relação ao *RMSE* da validação, pode-se notar uma tendência de aumento dos valores à medida que se diminuiu o número de parcelas utilizadas para o treinamento das *RNA*.

Em relação ao viés, tanto da predição quanto da projeção, as médias ficaram centradas no valor zero em todos os cenários. Na validação, é possível observar que a distribuição teve uma tendência de ser leptocúrtica no cenário 1, mesocúrtica no cenário 2 e platicúrtica no cenário 3. Isso indica maior chance de haver uma tendência nas estimativas geradas pelos cenários 2 e 3. Entretanto, como em todos os casos a média foi zero, a maior probabilidade é que essa tendência seja baixa ou nula.

Diante disso, fica evidente a importância de se realizar a parametrização adequada antes do treinamento efetivo das *RNA*, sobretudo em relação ao número de neurônios, a fim de se evitar problemas como *overfitting* e incapacidade de generalização das *RNA*.

Figura 11 – Histogramas com valores de *RMSE* e viés para predição e projeção do volume dos povoamentos de eucalipto.



5.2 Predição volumétrica dos povoamentos de eucalipto

Na Tabela 7 é possível observar as estatísticas utilizadas para avaliar o desempenho da predição do volume nos três cenários analisados em nível de parcela e para toda a área.

Tabela 7 – Resultado das estatísticas para avaliar a acurácia da predição volumétrica de povoamentos de eucalipto com dados de sensoriamento remoto.

| Estatísticas | Cenário 1 | | Cenário 2 | | Cenário 3 | |
|--|-----------|-----------|-----------|-----------|-----------|-----------|
| | Treino | Validação | Treino | Validação | Treino | Validação |
| Em nível de parcela | | | | | | |
| <i>r</i> | 0,9348 | 0,8864 | 0,9292 | 0,9161 | 0,9342 | 0,9039 |
| <i>V</i> (%) | -3,00 | 0,34 | 1,09 | 1,02 | -0,03 | 4,53 |
| <i>RMSE</i> (%) | 18,91 | 19,43 | 18,60 | 19,97 | 18,57 | 21,57 |
| Para toda a área (nível de pixel) | | | | | | |
| <i>r</i> | 0,9853 | | 0,9817 | | 0,9752 | |
| <i>V</i> (%) | -1,18 | | 1,92 | | 3,67 | |
| <i>RMSE</i> (%) | 7,92 | | 8,86 | | 10,67 | |

Em que, *r* = coeficiente de correlação entre valores observados e estimados; *V* = viés e; *RMSE* = raiz quadrada do erro quadrático médio.

Em nível de parcela, o *r* foi alto tanto para o treino quanto para a validação ($r > 0,88$), havendo uma pequena redução desses valores para o conjunto de validação. Não houve grande diferença entre os valores do *r* entre os três cenários analisados. É possível notar que à medida que o conjunto de treino foi reduzido, ocorreu uma redução do viés para o treino e um aumento dessa estatística para a validação.

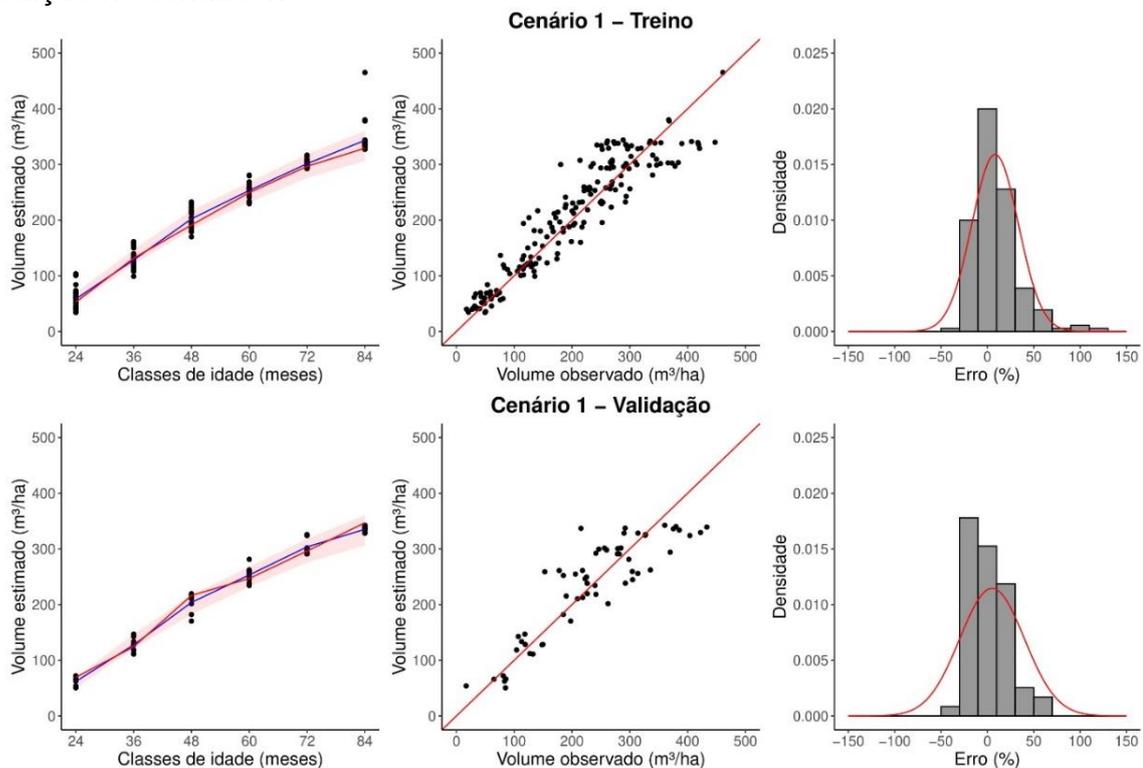
Ao observar os valores de *RMSE*, nota-se a mesma tendência de redução no valor dessa estatística no treino e aumento na validação à medida que o conjunto de treino foi reduzido. Considerando apenas os dados de validação, o maior *RMSE* ocorreu no cenário 3. Entretanto, essa diferença foi de apenas 2,04 pontos percentuais se comparado com o melhor cenário (cenário 1). A tendência de diminuir a acurácia da validação à medida que diminui o conjunto de treino era esperada, pois com menos dados para o treino existe a tendência de piorar a capacidade de generalização das RNA.

Analisando o resultado da Tabela 5 para toda a área, é possível notar maior acurácia em relação aos valores obtidos em nível de parcela, com exceção do viés para os cenários 1 e 2. O cenário que apresentou melhor acurácia na estimação para toda a área foi o cenário 1. Entretanto, a diferença das estatísticas dos cenários 2 e 3 não foi considerável.

Nas Figuras 12, 13 e 14 encontram-se os gráficos do volume estimado em função da idade, relação entre volume observado e volume estimado e dispersão dos erros percentuais para os cenários 1, 2 e 3, respectivamente, em nível de parcela.

Ao observar o desempenho da *RNA* para a predição do volume no cenário 1 (Figura 12), é possível notar que não houve discrepância considerável entre as médias do inventário florestal e dos valores estimados no treino e validação. Os valores estimados, para treino e validação, ficaram dentro do intervalo de confiança do inventário florestal. No gráfico dos valores observados versus estimados, pode-se conferir que os valores acompanharam a linha 1:1, estando mais dispersos nos maiores volumes. Nos histogramas dos erros percentuais, nota-se que a maior parte ficou entre $\pm 30\%$, tanto no treino, quanto na validação, não havendo indícios de tendenciosidade.

Figura 12 – Dispersão dos valores estimados em função da idade, valores estimados versus observados e histograma dos erros percentuais, em nível de parcela, para predição no cenário 1.

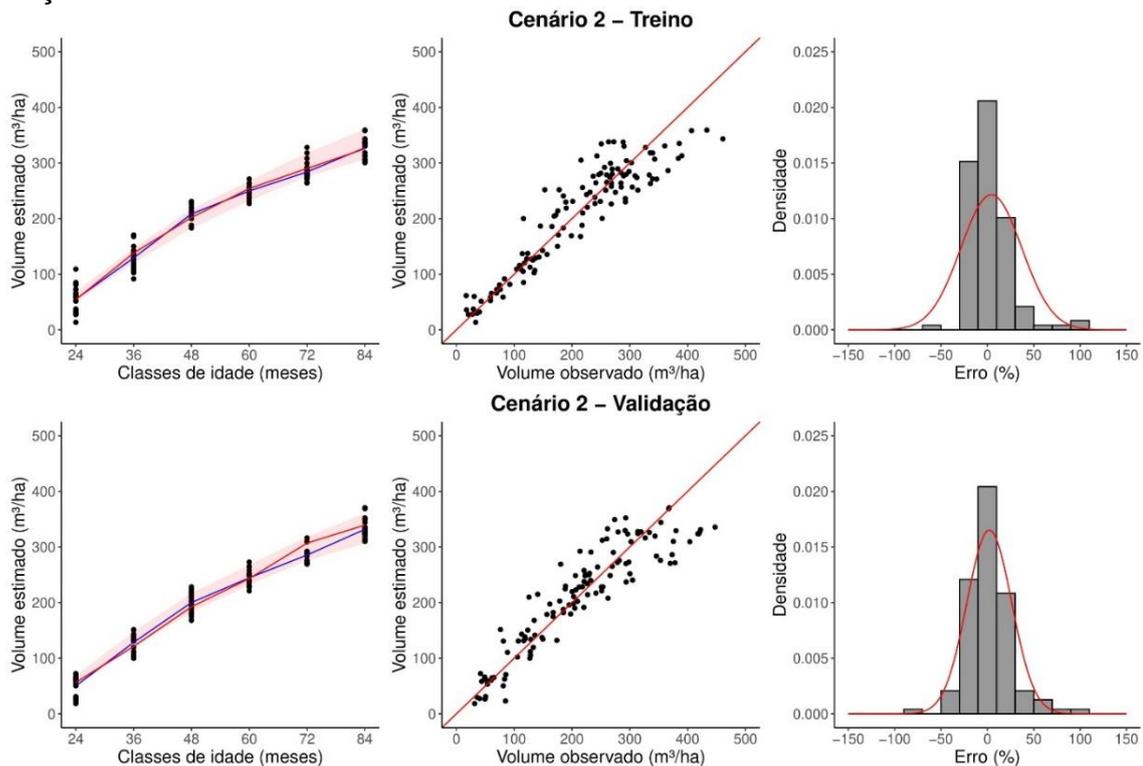


Em que: — = média estratificada do volume obtido no inventário florestal; — = média dos valores estimados para a predição do volume; = intervalo de confiança para a média do inventário florestal estratificado a 95% de probabilidade; classes dos histogramas com amplitude de 20%.

No cenário 2 (Figura 13), ao observar o gráfico do volume em função da idade, é possível notar que as médias foram próximas, sendo que na validação as mesmas ficaram no limite inferior, porém dentro do intervalo de confiança do inventário florestal aos 24 e 36 meses. No gráfico observado versus estimado, é possível verificar uma

tendência de subestimação em áreas com volume observado maior que $300 \text{ m}^3\text{ha}^{-1}$. No histograma dos erros percentuais, nota-se que a maior parte dos erros ficou entre $\pm 30\%$. Além disso, o ponto de máximo da curva normal ficou próximo do valor zero no eixo x, indicando baixa tendenciosidade das estimativas do treino e da validação.

Figura 13 – Dispersão dos valores estimados em função da idade, valores estimados versus observados e histograma dos erros percentuais, em nível de parcela, para predição no cenário 2.

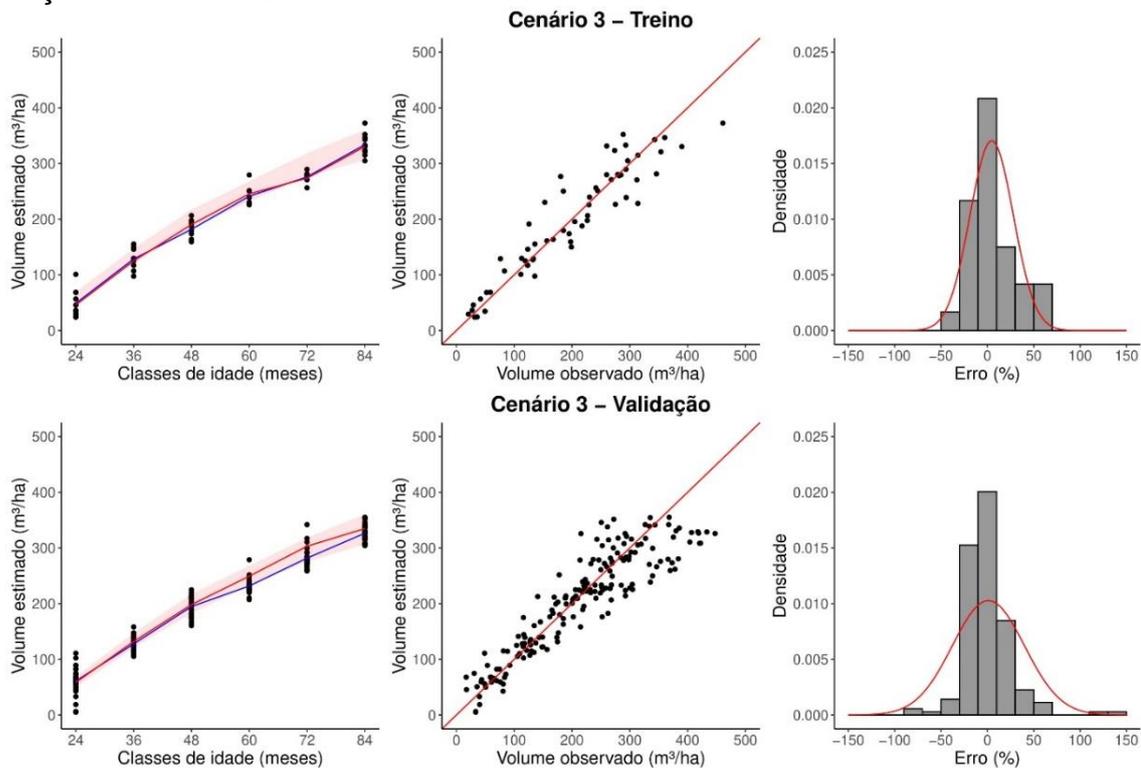


Em que: — = média estratificada do volume obtido no inventário florestal; — = média dos valores estimados para a predição do volume; = intervalo de confiança para a média do inventário florestal estratificado a 95% de probabilidade; classes dos histogramas com amplitude de 20%.

Para o cenário 3 (Figura 14), é possível verificar que a média do inventário florestal ficou no limite inferior do intervalo de confiança para o treino. Isso pode ter ocorrido pelo fato desse cenário possuir um número reduzido de dados para o treino e durante o processo de aleatorização desse conjunto foram selecionadas as parcelas com menores valores volumétricos. Com isso, na validação, a média dos valores estimados pela RNA teve a tendência de subestimar o volume. Na relação entre valores observados e estimados, nota-se uma tendência de subestimação em áreas de maior volume, assim como ocorrido nos cenários anteriores. Já nos histogramas dos erros percentuais é possível verificar que o cenário 3 produziu a maior amplitude de erro na validação, com valores chegando a 150%. Entretanto, a distribuição dos

erros foi normal, com média próxima a zero, indicando que não houve tendenciosidade, de modo geral.

Figura 14 – Dispersão dos valores estimados em função da idade, valores estimados versus observados e histograma dos erros percentuais, em nível de parcela, para predição no cenário 3.



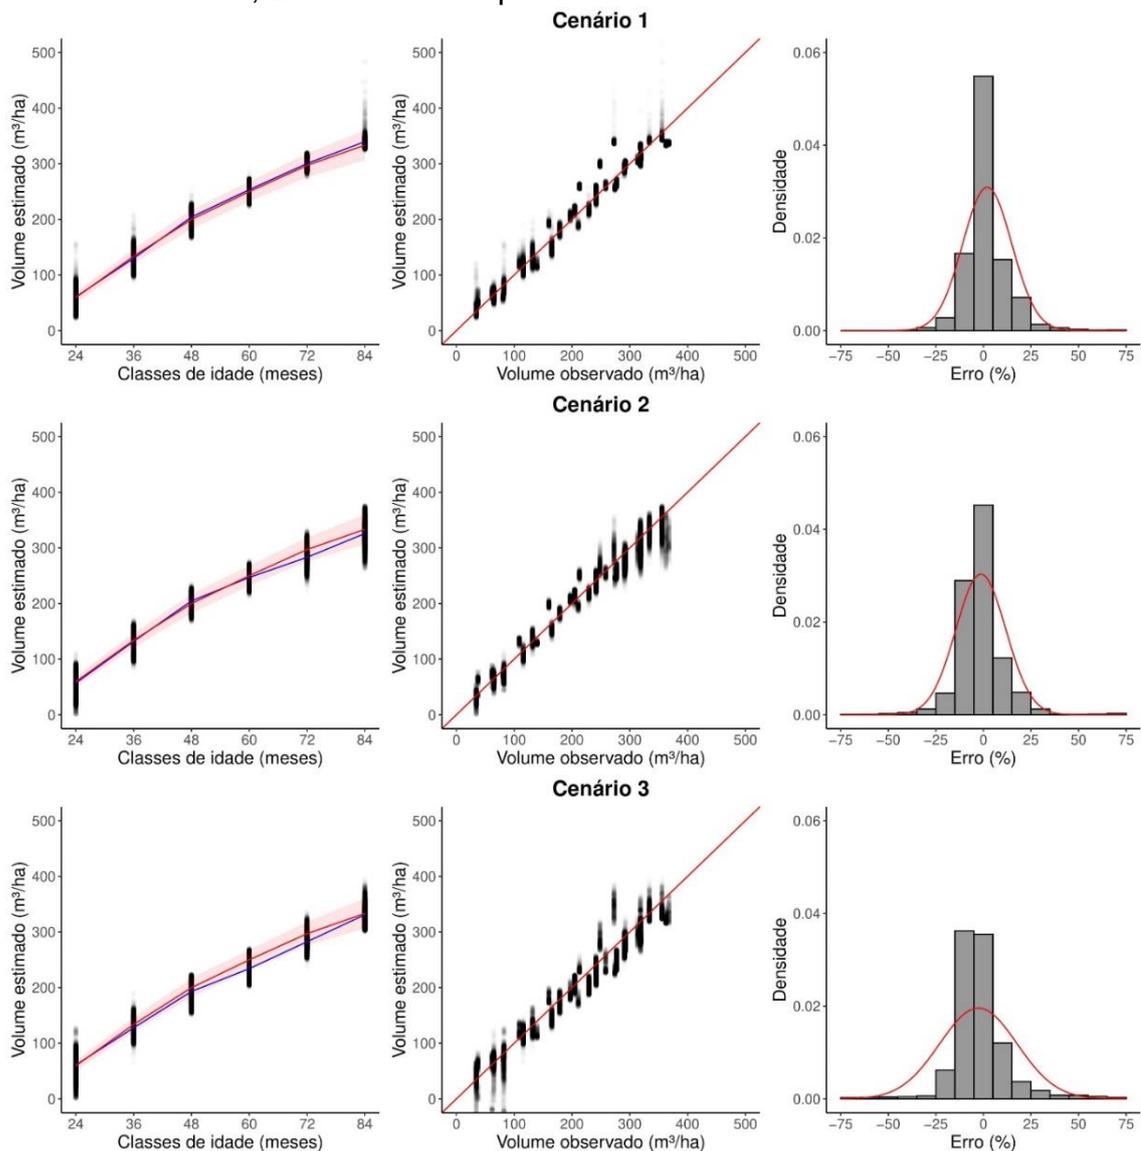
Em que: — = média estratificada do volume obtido no inventário florestal; — = média dos valores estimados para a predição do volume; = intervalo de confiança para a média do inventário florestal estratificado a 95% de probabilidade; classes dos histogramas com amplitude de 20%.

Na Figura 15 encontram-se os gráficos do volume estimado em função da idade, relação entre valores observados e estimados e dispersão dos erros percentuais, para toda a área, nos cenários 1, 2 e 3. Ao observar as médias do inventário florestal e médias estimadas, nota-se que no cenário 1 essas médias foram praticamente idênticas, no cenário 2 houve subestimação da média aos 72 e 84 meses, enquanto no cenário 3 houve subestimação aos 60 e 72 meses. Entretanto, em todos os cenários as médias dos valores estimados foram muito próximas da média do inventário florestal durante toda a rotação da floresta, estando todas dentro do intervalo de confiança.

Nos gráficos dos valores observados versus valores estimados, é possível verificar que os cenários 2 e 3 apresentaram tendência de subestimação em áreas de maior produção em volume. Contudo, de modo geral, em todos os cenários os valores

estimados seguiram a tendência da linha 1:1. Nos histogramas dos erros percentuais pode-se observar que a maior parte dos erros ficou entre $\pm 15\%$. Houve uma tendência da curva de distribuição dos erros percentuais se tornar platicúrtica à medida que o número de parcelas utilizadas no treino das redes diminuiu. Entretanto, em todos os casos, as médias foram próximas de zero, não havendo tendenciosidade.

Figura 15 – Dispersão dos valores estimados em função da idade, valores estimados versus observados e histograma dos erros percentuais para a predição em toda a área nos cenários 1, 2 e 3 a nível de pixel.



Em que: — = média estratificada do volume obtido no inventário florestal; — = média dos valores estimados para a predição do volume; = intervalo de confiança para a média do inventário florestal estratificado a 95% de probabilidade; classes dos histogramas com amplitude de 10%.

Considerando os resultados obtidos em toda a área, o cenário 1 foi o que estimou o volume com maior acurácia. Entretanto, o cenário 3 apresentou resultados

muito próximos, com valor de *RMSE* apenas 2,75 pontos percentuais acima do cenário 1.

Na Tabela 8 é possível observar a diferença entre os valores estimados pelo *IFC* e aqueles estimados pelos diferentes cenários para a predição do volume anualmente. Verifica-se que quanto maior o conjunto de treino, menor foi a diferença entre os valores estimados pelo *IFC* e os estimados via sensoriamento remoto nos cenários avaliados. De modo geral, não houve discrepância entre os cenários, sendo que a diferença entre o melhor (cenário 1) e o pior (cenário 3) foi de 1,74 pontos percentuais.

Tabela 8 – Diferença percentual entre os valores obtidos pelo inventário florestal estratificado e os estimados pelos diferentes cenários para a predição volumétrica em povoamentos de eucalipto de 2006 a 2011.

| Ano | Diferença (%) | | |
|---------------------------------------|---------------|-------------|-------------|
| | Cenário 1 | Cenário 2 | Cenário 3 |
| 2006 | 2,23 | -4,31 | -2,35 |
| 2007 | -2,88 | -1,48 | -4,46 |
| 2008 | 2,18 | 2,38 | -3,41 |
| 2009 | 1,37 | -1,26 | -6,33 |
| 2010 | 1,16 | -4,70 | -4,86 |
| 2011 | 1,91 | -2,27 | -0,71 |
| Média das diferenças absolutas | 1,95 | 2,73 | 3,69 |

5.3 Projeção da produção volumétrica dos povoamentos de eucalipto

As estatísticas para avaliar a projeção do crescimento da floresta nos três cenários, em nível de parcela e para toda a área, estão apresentadas na Tabela 9. Ao analisar o *r*, pode-se notar que houve uma forte correlação, tanto no treino quanto na validação, sendo o menor valor encontrado na validação do cenário 3. Os valores de viés foram baixos em todos os cenários (*Viés* < 2%), o que indica não tendenciosidade das estimativas. Em relação ao *RMSE*, pode-se notar que os valores da validação foram muito superiores aos obtidos no treino. Isso se deve ao fato de que no treino foram utilizados valores de volume inicial reais, enquanto na validação o volume inicial

foi aquele obtido na etapa de predição, acumulando assim o erro da estimativa de predição. Além disso, houve uma tendência de aumento no *RMSE* da validação à medida que foi reduzido o conjunto de treino.

Tabela 9 – Resultado das estatísticas para avaliar a acurácia da projeção do crescimento e produção dos povoamentos de eucalipto.

| Estatísticas | Cenário 1 | | Cenário 2 | | Cenário 3 | |
|--|-----------|-----------|-----------|-----------|-----------|-----------|
| | Treino | Validação | Treino | Validação | Treino | Validação |
| Em nível de parcela | | | | | | |
| <i>r</i> | 0,9861 | 0,8148 | 0,9839 | 0,8066 | 0,9890 | 0,7523 |
| Viés (%) | -0,25 | 0,22 | -0,002 | -1,88 | 0,36 | 0,42 |
| <i>RMSE</i> (%) | 5,85 | 20,69 | 5,90 | 21,20 | 5,31 | 24,32 |
| Para toda a área (nível de pixel) | | | | | | |
| <i>r</i> | 0,9447 | | 0,9485 | | 0,9332 | |
| Viés (%) | -0,58 | | 0,22 | | -1,45 | |
| <i>RMSE</i> (%) | 10,07 | | 9,68 | | 11,75 | |

Em que, *r* = coeficiente de correlação entre valores observados e estimados; *V* = viés e; *RMSE* = raiz quadrada do erro quadrático médio.

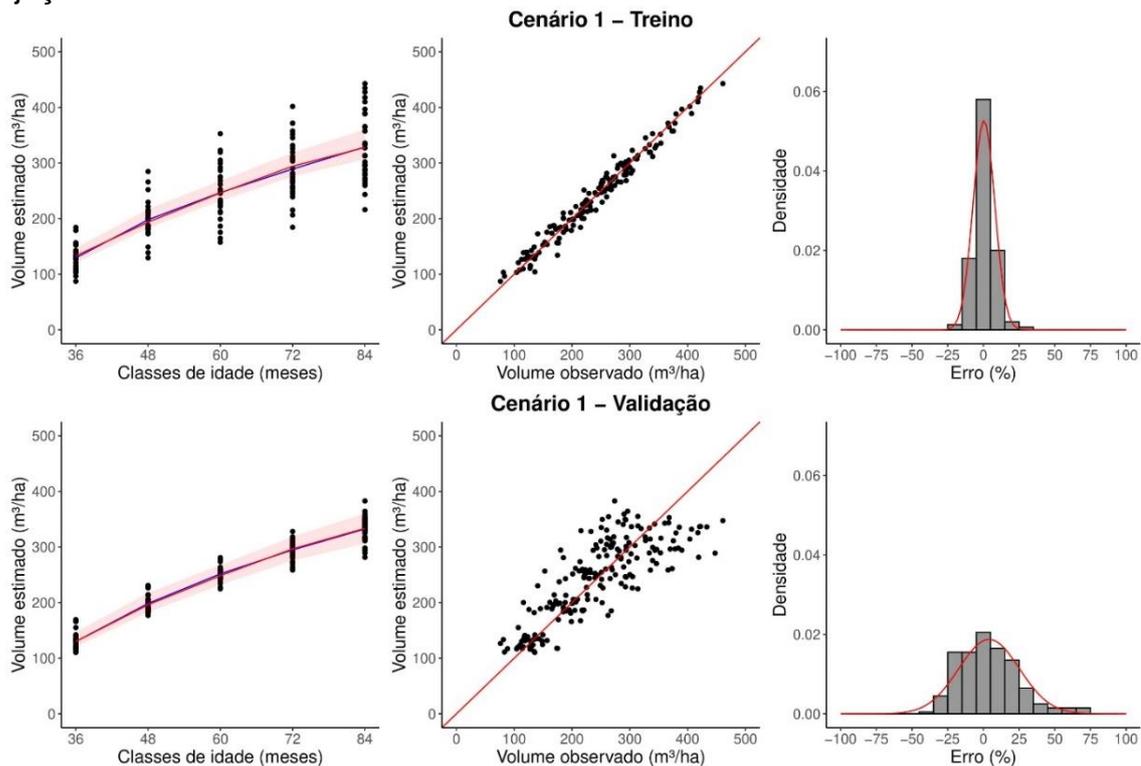
Ao analisar os resultados para toda a área, percebe-se uma melhoria na acurácia se comparado aos valores de validação em nível de parcela, assim como nos resultados da predição (Tabela 7). Assim como na predição, a redução do número de parcelas utilizadas no treino das *RNA* para a projeção do volume não causou redução considerável da acurácia das estimativas para toda a área. O cenário com menor *RMSE* foi o 2, seguido pelo cenário 1 e, por fim, o cenário 3. Entretanto, a diferença de *RMSE* entre o melhor e o pior cenário foi de apenas 2,07 pontos percentuais, não seguindo a tendência esperada de maior acurácia no cenário com mais parcelas utilizadas para o treino. Isso pode indicar que essas diferenças de acurácia não se devem ao número de parcelas utilizadas no treino, mas são consequência dos valores iniciais dos pesos das *RNA* que são gerados aleatoriamente (SILVA, SPATTI; FLAUZINO, 2010).

Os gráficos do volume estimado em função da idade, relação entre volume observado e volume estimado e dispersão dos erros percentuais para a projeção nos cenários 1, 2 e 3 estão apresentados nas Figuras 16, 17 e 18, respectivamente.

Nos gráficos do cenário 1 (Figura 16), pode-se observar que as médias do inventário florestal e das estimativas não foram discrepantes durante todo a rotação dos povoamentos. A relação entre os valores observados e estimados seguiu a

tendência de 1:1, sendo mais dispersos na validação. No histograma dos erros percentuais para o treino, pode-se observar que, aproximadamente, 60% dos valores ficou na classe entre $\pm 5\%$, enquanto na validação, a maior parte dos erros ficou entre $\pm 15\%$, não havendo indícios de tendenciosidade.

Figura 16 – Dispersão dos valores estimados em função da idade, valores estimados versus observados e histograma dos erros percentuais, em nível de parcela, para projeção no cenário 1.

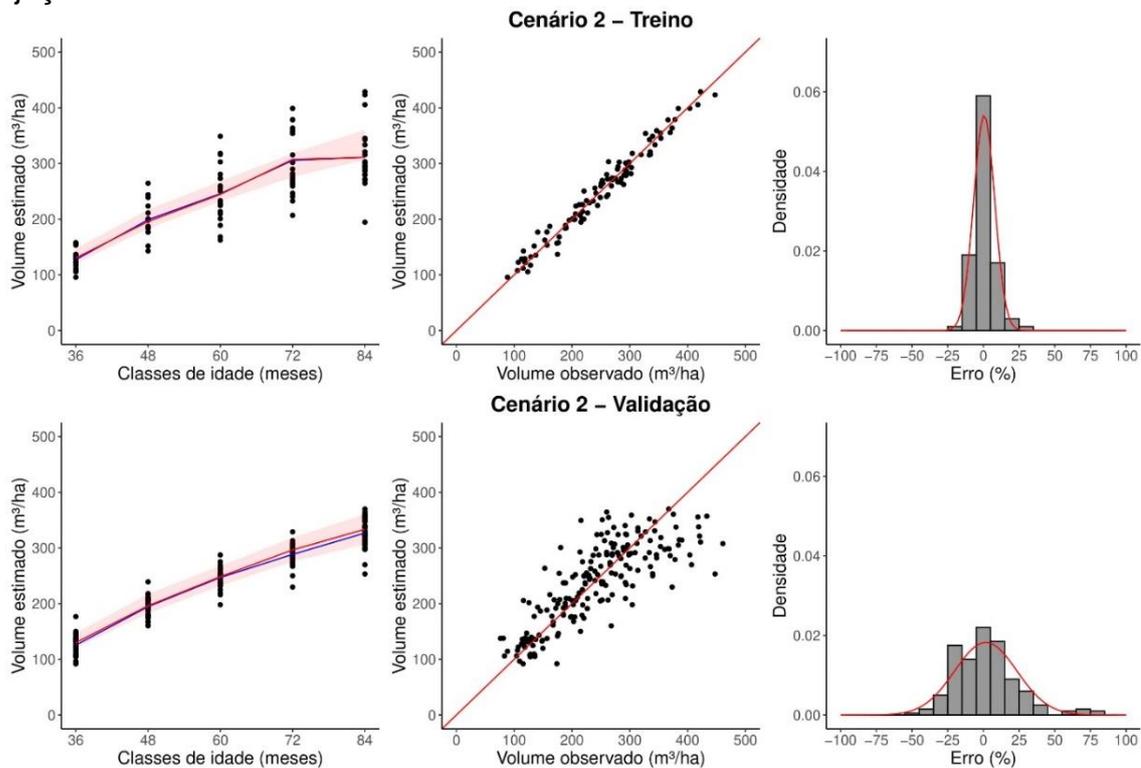


Em que: — = média estratificada do volume obtido no inventário florestal; — = média dos valores estimados para a projeção do volume; ■ = intervalo de confiança para a média do inventário florestal estratificado a 95% de probabilidade; classes dos histogramas com amplitude de 10%.

Ao observar as médias do inventário florestal e das estimativas no cenário 2 (Figura 17), é possível notar uma tendência de subestimação do volume a partir dos 72 meses para a validação. Entretanto, as médias foram semelhantes e ficaram dentro do intervalo de confiança do inventário florestal, tanto para o conjunto de dados de treino e de validação. No gráfico com a relação entre os valores observados e estimados, fica evidente a tendência de subestimação em áreas com volume real maior do que $300 \text{ m}^3\text{ha}^{-1}$ para o conjunto de validação. Em relação ao histograma dos erros percentuais, o conjunto de treino apresentou resultados semelhantes ao do cenário 1, com 60% dos dados no intervalo entre $\pm 5\%$. Na validação, a amplitude dos

erros foi maior, com valores superiores a 75%. Entretanto, não houve tendenciosidade nas estimativas.

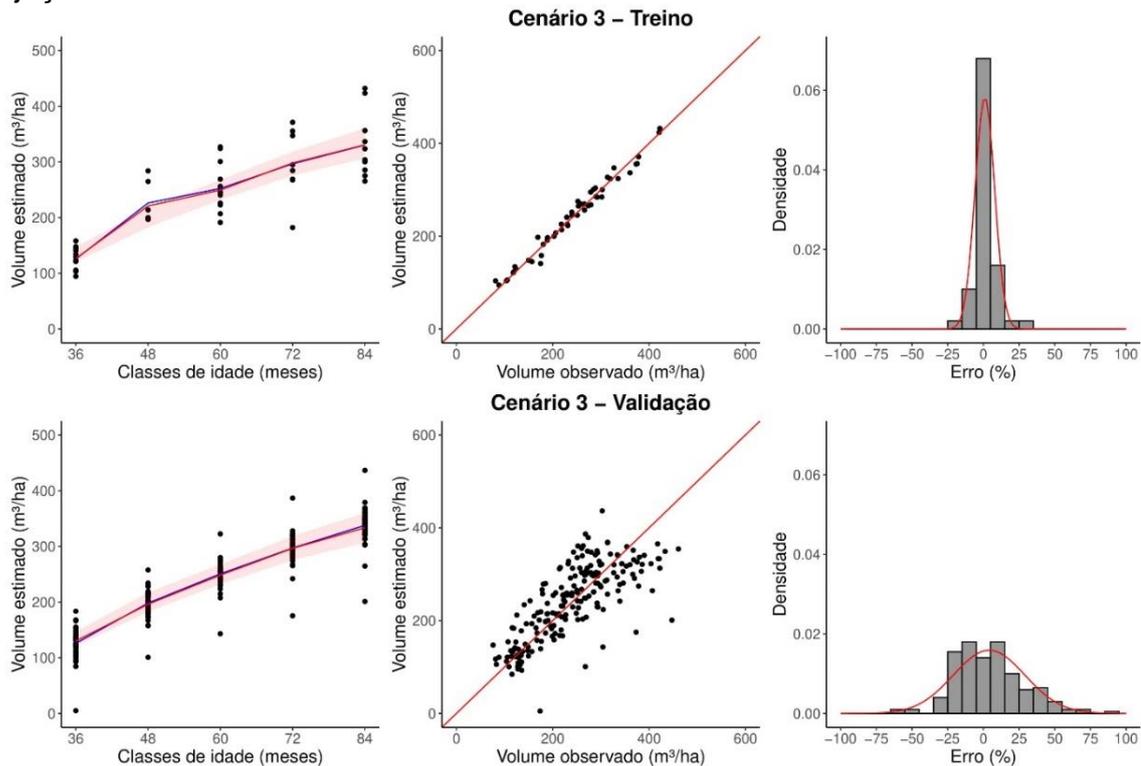
Figura 17 – Dispersão dos valores estimados em função da idade, valores estimados versus observados e histograma dos erros percentuais, em nível de parcela, para projeção no cenário 2.



Em que: — = média estratificada do volume obtido no inventário florestal; — = média dos valores estimados para a projeção do volume; = intervalo de confiança para a média do inventário florestal estratificado a 95% de probabilidade; classes dos histogramas com amplitude de 10%.

Ao aplicar o cenário 3 (Figura 18), em função do processo de aleatorização dos conjuntos de treino e validação, a média do inventário florestal do conjunto de treino ficou acima do limite superior do intervalo de confiança em 1,79%, o que levou os respectivos valores estimados a extrapolarem esse limite superior em 4,19%. Apesar disso, as médias foram semelhantes, tanto no conjunto de treino quanto não de validação. Em relação a relação entre valores observados e estimados, esse cenário também apresentou maior dispersão no conjunto de dados de validação. O histograma de erros percentuais do treino foi semelhante ao obtido pelos cenários 1 e 2. Entretanto, no conjunto de validação esse cenário apresentou maior amplitude de erros. Apesar disso, aproximadamente 80% dos erros ficaram no intervalo de $\pm 25\%$, não havendo sinais claros de tendenciosidade das estimativas.

Figura 18 – Dispersão dos valores estimados em função da idade, valores estimados versus observados e histograma dos erros percentuais, em nível de parcela, para projeção no cenário 3.

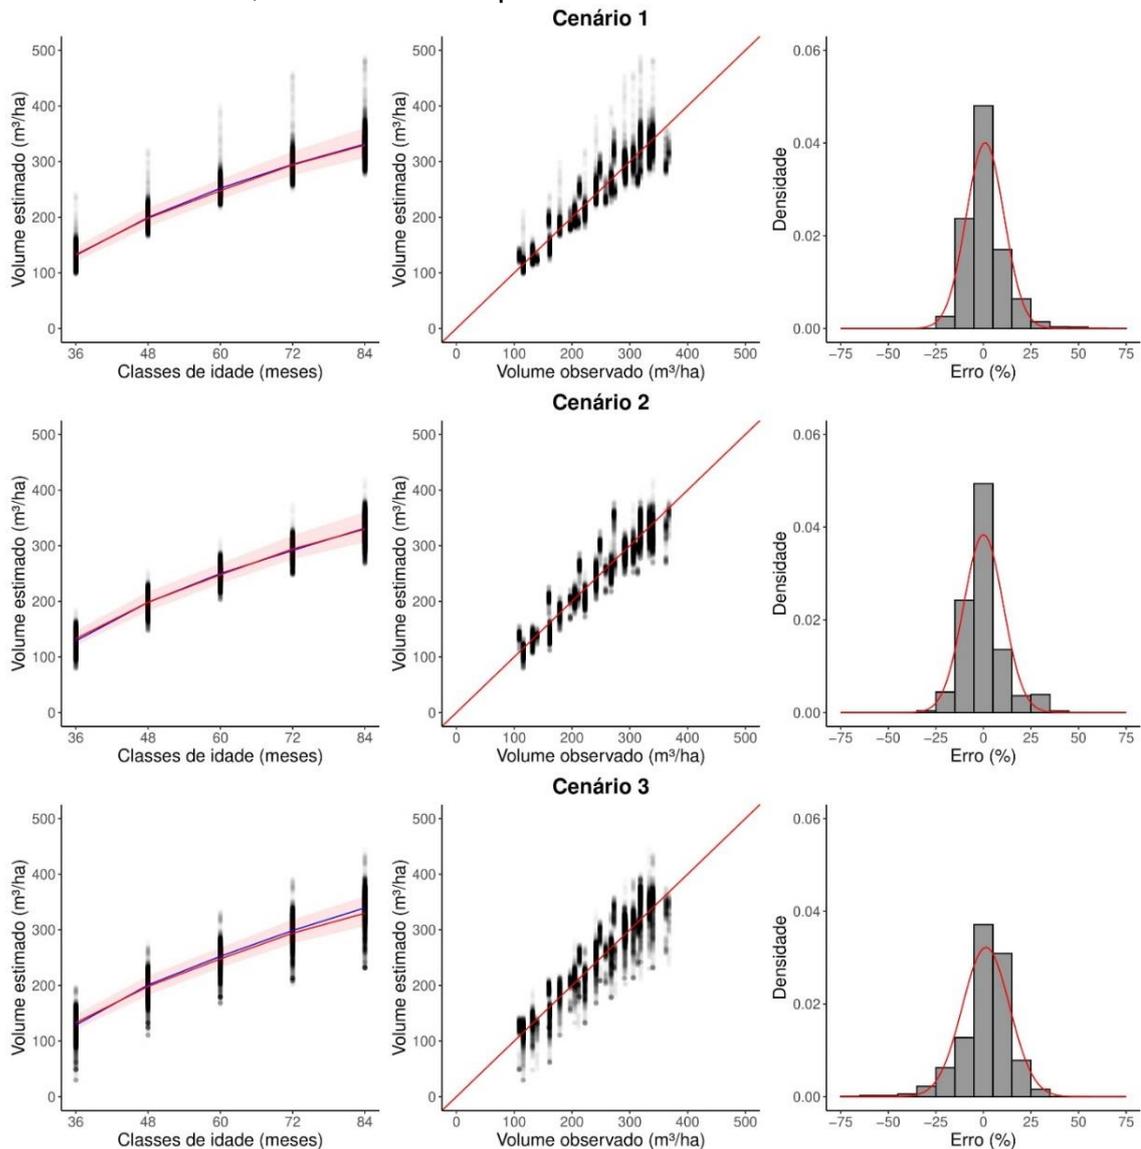


Em que: — = média estratificada do volume obtido no inventário florestal; — = média dos valores estimados para a projeção do volume; = intervalo de confiança para a média do inventário florestal estratificado a 95% de probabilidade; classes dos histogramas com amplitude de 10%.

Na Figura 19 são apresentados os gráficos do volume projetado em função da idade, relação dos valores observados e estimados e a dispersão dos erros percentuais para a projeção do volume em toda a área. As médias do inventário florestal e dos valores estimados foram idênticas em todos os cenários, com exceção ao cenário 3 aos 72 e 84 meses, que foram ligeiramente superiores. Entretanto, a maior diferença entre essas médias, que ocorreu aos 84 meses no cenário 3, foi de $9,66 \text{ m}^3\text{ha}^{-1}$ (2,93%). Em todos os cenários, a média dos valores estimados ficou dentro do intervalo de confiança do inventário florestal.

A relação entre os valores observados e estimados seguiu a tendência da linha 1:1, havendo pouca dispersão entre os valores estimados. Quanto aos histogramas dos erros percentuais, é possível observar que aproximadamente 50% das estimativas apresentam erros entre $\pm 5\%$ nos cenários 1 e 2, enquanto no cenário 3, a frequência de erros nessa mesma classe é de aproximadamente 40%. Entretanto, de modo geral, não houve tendência nas estimativas.

Figura 19 – Dispersão dos valores estimados em função da idade, valores estimados versus observados e histograma dos erros percentuais para a projeção em toda a área nos cenários 1, 2 e 3 a nível de pixel.



Em que: — = média estratificada do volume obtido no inventário florestal; — = média dos valores estimados para a projeção do volume; = intervalo de confiança para a média do inventário florestal estratificado a 95% de probabilidade; classes dos histogramas com amplitude de 10%.

Na Tabela 10 encontram-se as diferenças percentuais entre as médias estimadas pelo *IFC* e as médias obtidas para a projeção nos diferentes cenários. Assim como na predição (Tabela 8), houve uma tendência de aumento da diferença percentual à medida que o conjunto de treino foi reduzido. Entretanto, até no pior resultado (cenário 3), essa diferença não foi relevante, não chegando a 2% de média.

Tabela 10 – Diferença percentual entre os valores obtidos pelo inventário florestal estratificado e os estimados pelos diferentes cenários para a projeção do crescimento em volume dos povoamentos de eucalipto de 2007 a 2011.

| Ano | Diferença (%) | | |
|---------------------------------------|---------------|-----------|-----------|
| | Cenário 1 | Cenário 2 | Cenário 3 |
| 2007 | -1,75 | -3,64 | -3,74 |
| 2008 | -0,10 | -0,82 | 0,52 |
| 2009 | 0,84 | 0,00 | 0,95 |
| 2010 | -0,69 | -1,87 | 0,57 |
| 2011 | -0,57 | -0,55 | 1,79 |
| Média das diferenças absolutas | 0,79 | 1,38 | 1,52 |

Considerando que os resultados dos cenários avaliados não foi discrepante, ou seja, não apresentaram diferença considerável em termos de acurácia, e que o objetivo do presente trabalho é a redução de custos dos levantamentos em campo, o cenário 3 pode ser aplicado com segurança para a projeção do volume em povoamentos de eucalipto.

5.4 Análise do incremento mensal

Na Tabela 11 encontram-se os valores máximos de *IMM* e *ICM*. Em relação ao *IMM*, apenas o cenário 1 obteve ponto de máxima na mesma idade em que ocorre no *IFC*, sendo que houve uma tendência de aumento dessa idade nos cenários 2 e 3. Para o *ICM*, também ocorreu a mesma tendência de aumento na idade em que ocorre o ponto de máxima à medida que o número de parcelas utilizadas no treino foi reduzido. Entretanto, o cenário 1 subestimou o ponto de máxima em um mês, enquanto o cenário 3 superestimou em um mês.

Esse resultado mostra que a redução no número de parcelas utilizadas no treinamento das *RNA* não teve forte influência na projeção do comportamento de crescimento dos talhões ao longo dos anos, sendo todos os valores de incremento e das respectivas idades muito próximos. Em comparação com o obtido a partir dos dados de *IFC*, a maior discrepância entre a idade em que ocorre o máximo *IMM* foi

com o cenário 3 (3,33%). Em relação ao máximo *ICM*, a maior diferença foi com os cenários 1 e 3, entretanto, o cenário 1 subestimou essa idade (-2,50%) e cenário 3 superestimou (2,50%).

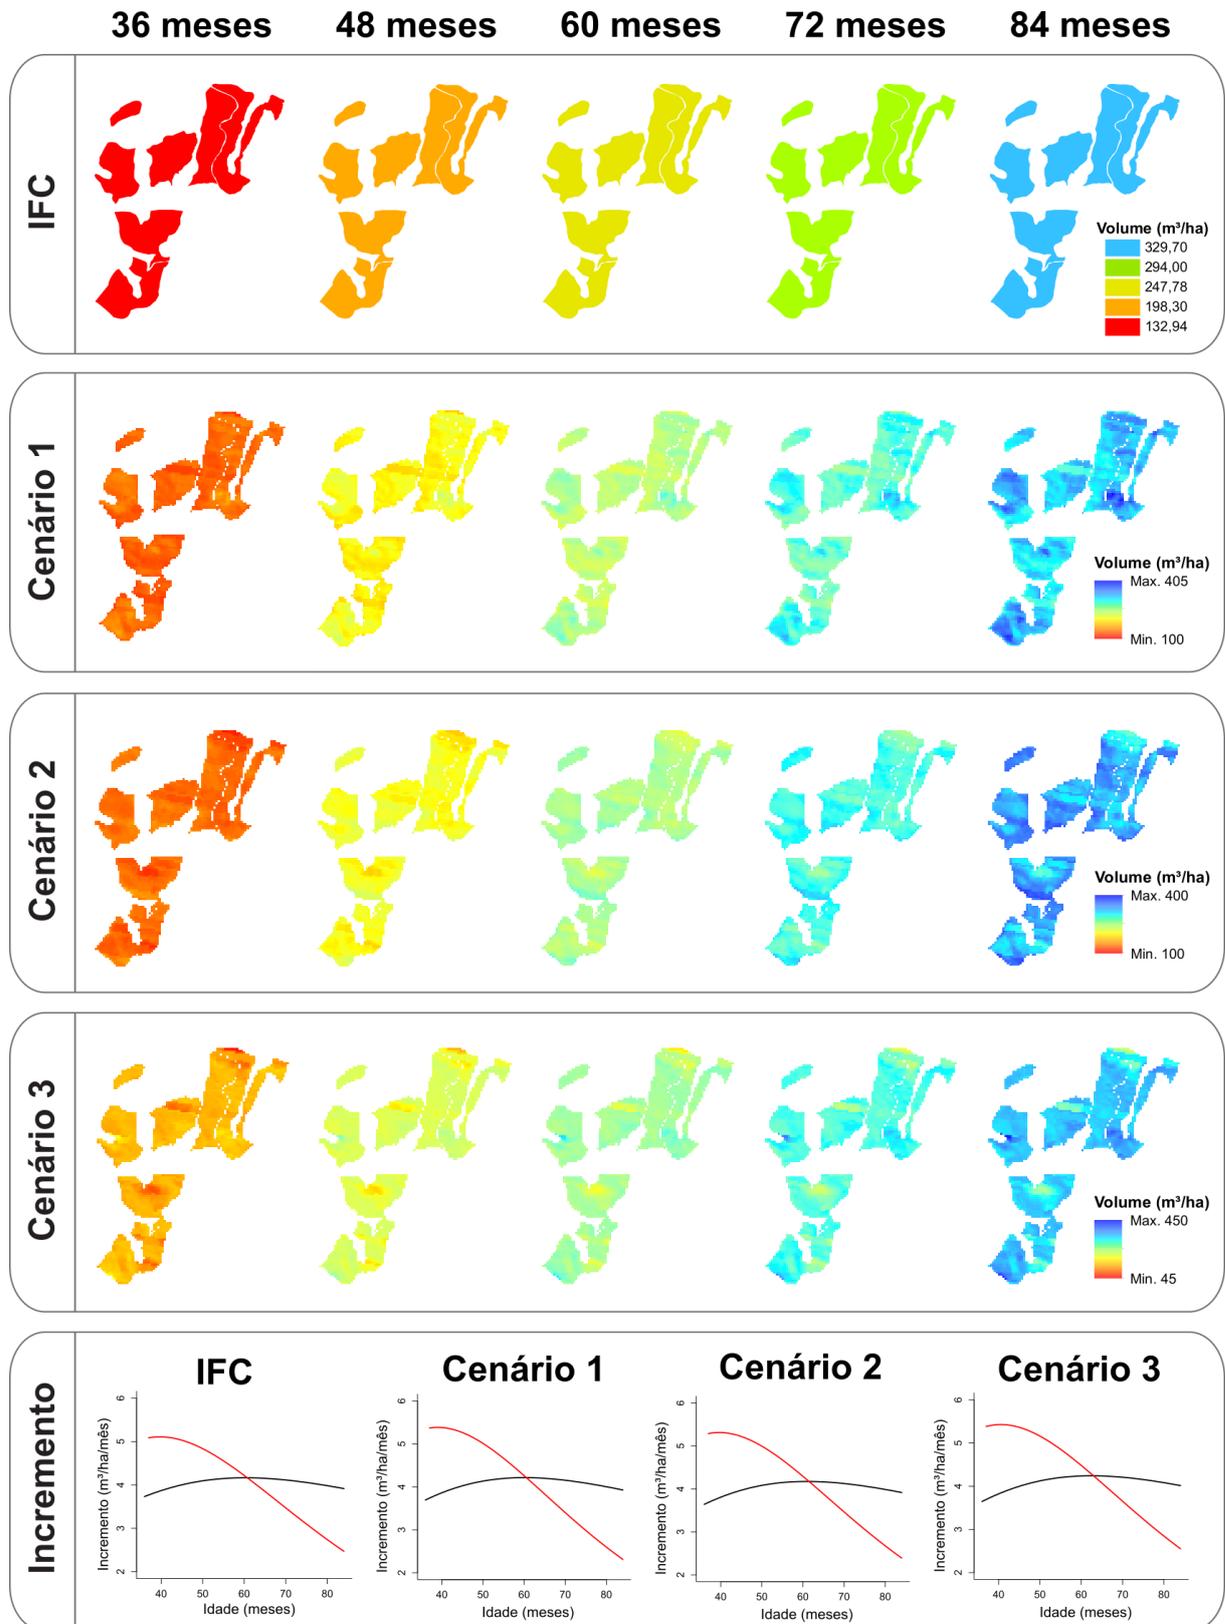
Tabela 11 – Valores máximos de incremento médio mensal e incremento corrente mensal.

| | IMM | | ICM | |
|------------|---------------------|----------------------|---------------------|----------------------|
| | Valor máximo | Idade (meses) | Valor máximo | Idade (meses) |
| <i>IFC</i> | 4,165 | 60 | 5,108 | 40 |
| Cenário 1 | 4,215 | 60 | 5,385 | 39 |
| Cenário 2 | 4,175 | 61 | 5,314 | 40 |
| Cenário 3 | 4,242 | 62 | 5,428 | 41 |

Em que: *IMM* = Incremento Médio Mensal, em $\text{m}^3\text{ha}^{-1}\text{mes}^{-1}$; *ICM* = Incremento Corrente Mensal, em $\text{m}^3\text{ha}^{-1}\text{mes}^{-1}$.

Na Figura 20 estão apresentados os mapas de produção volumétrica de um dos projetos inventariados e as curvas de *IMM* e *ICM* para toda a área de estudo, obtidas a partir de dados do *IFC* e dos cenários analisados. Nos mapas de projeção da produção volumétrica é possível observar que, com dados de *IFC*, só é possível a obtenção de valores de volumes médios para o projeto em cada ano. Entretanto, com a modelagem realizada a partir de dados de sensoriamento remoto, é possível obter informações mais detalhadas, podendo-se perceber a variação da produção volumétrica que ocorre dentro dos talhões, a cada ano. Além disso, pode-se notar que as curvas de *IMM* e *ICM* geradas pelos três cenários foram praticamente idênticas às obtidas com dados de *IFC*.

Figura 20 – Projeção da produção volumétrica e curvas de incremento para os povoamentos de eucalipto estimados com dados de *IFC* e de sensoriamento remoto.



Em que: — = Incremento médio mensal; — = Incremento corrente mensal.

5.5 Considerações sobre a predição e projeção do crescimento e produção de povoamentos de eucalipto com dados de sensoriamento remoto passivo

Diversos trabalhos foram realizados sobre crescimento e produção em plantios florestais. Para uma análise dos resultados apresentados por esta metodologia de estimar o volume de povoamentos florestais por meio de sensoriamento remoto via predição e projeção foi comparado os resultados desta proposição com dados de alguns trabalhos relacionados ao tema.

Reis et al. (2019) combinaram dados obtidos do sensor OLI/Landsat 8 com dados de *Synthetic Aperture Radar* (SAR) do Sentinel-1B e o modelo digital de elevação (MDE) obtido do ALOS/PALSAR para estimar o volume de povoamentos de eucalipto variando de 2,9 a 6,6 anos, nos anos de 2015 a 2017, respectivamente. A estimação foi feita com *RF*, tendo como variáveis de entrada a idade dos povoamentos, bandas espectrais e diversos índices de vegetação obtidos com dados do sensor OLI, três índices calculados a partir dos dados de polarização do SAR e variáveis geomorfométricas obtidas a partir do MDE. A base de dados foi dividida em 70% para treino e 30% para validação, com *RMSE* e *r* da validação igual a 12,88% e 0,71, respectivamente.

Os resultados de predição obtidos por Reis et al. (2019) para a validação em nível de parcela apresentaram maior acurácia do que os obtidos no presente estudo. Isso pode indicar uma possibilidade de melhoria na acurácia da metodologia aqui proposta, caso sejam adicionadas variáveis de entrada extraídas de dados do SAR e MDE. Além disso, outros fatores podem ter influenciado para a maior acurácia encontrada no trabalho de Reis et al. (2019), como um maior número de parcelas, em média 117 por ano, para realizar estimativas em uma menor abrangência temporal, apenas três anos, maior área das parcelas (500 m²) e maior intensidade amostral do conjunto utilizado para o treino da *RF*. Em Reis et al. (2019), foi utilizada uma intensidade de uma parcela a cada 18 ha, enquanto no presente trabalho, a maior intensidade amostral foi de uma parcela a cada 28 ha no cenário 1. Entretanto, mesmo utilizando menos variáveis de entrada, o presente trabalho avaliou a possibilidade de redução da intensidade amostral para predição do volume a partir de dados de sensoriamento remoto e obteve estimativas com menos de 3,7% de diferença às obtidas pelo *IFC* (Tabela 8).

Para prever a produção volumétrica em plantios de eucalipto aos seis e sete anos para todo o estado de Minas Gerais, Alcântara et al. (2018) utilizaram *RNA*, tendo como entradas as variáveis categóricas sub-região, espaçamento, material genético, regime de manejo e solo predominantes; além das variáveis como a altitude, temperaturas máxima, média e mínima e precipitações máxima, média e mínima. Esses autores obtiveram *RMSE* e *r* para toda a área de 21,93% e 0,5295, respectivamente, ao utilizar 95% dos dados para treino da *RNA*. Quando utilizaram 85% dos dados para treino, os valores de *RMSE* e *r* aumentaram para 22,22% e 0,5355, respectivamente.

Apesar de utilizar diversas variáveis categóricas e climáticas, Alcântara et al. (2018) obtiveram menor acurácia do que no presente trabalho na estimação para toda a área. Isso sugere que a utilização de dados de sensoriamento remoto consiste em uma ferramenta mais eficaz para prever a produção volumétrica quando comparada com variáveis climáticas e de cadastro. O melhor resultado encontrado no presente estudo com o uso das métricas do *TC* pode ter ocorrido pois estas variáveis podem explicar melhor a variação do volume em relação a variação da idade dos plantios de eucalipto. Isso pode ser explicado pelo fato das métricas do *TC* se correlacionarem com a idade dos povoamentos (CHEN et al., 2018; HEO et al., 2006; SIVANPILLAI et al., 2006).

Avaliando a projeção do volume em povoamentos de eucalipto, Binoti et al. (2015) utilizaram *RNA* do tipo *perceptron*, *multilayer perceptron* e *radial basis function* (*RBF*). Considerando como variáveis de entrada a idade atual e futura, área basal atual e futura e volume atual, além das variáveis categóricas projeto, tipo de solo, relevo, textura do solo, material genético e espaçamento, esses autores encontraram valores de *RMSE* variando de 10,89% a 15,49% e *r* de 0,9305 a 0,9652. Já Silva (2018) comparou o uso de *RF* e do sistema *Neuro-Fuzzy* (*SNF*) para a projeção do crescimento e produção de eucalipto, tendo como variáveis preditoras o material genético, volume atual, área basal futura e as idades atual e futura. Este autor encontrou valores de *RMSE* de 10,80% e 15,30% e *r* de 0,9577 e 0,9295, para o *SNF* e *RF*, respectivamente. Tanto Binoti et al. (2015) quanto Silva (2018) obtiveram valores de *RMSE* inferiores aos obtidos na validação do presente trabalho. Porém, ao considerar a projeção para toda a área, em nível de pixel, os valores de *RMSE* e *r* foram compatíveis com os obtidos por esses autores.

Scolforo et al. (2019b) avaliaram a inclusão do déficit hídrico em modelos de crescimento e produção para povoamentos clonais de eucalipto. Essa variável foi responsável por uma redução de até 77% e 84% no *RMSE* para predição e projeção, respectivamente. Entretanto, mesmo os melhores modelos, compostos por submodelos para estimação da altura dominante, número de árvores por hectare (sobrevivência) e área basal, todos com a inclusão da variável déficit hídrico, obtiveram *RMSE* de 26,35% para a predição e de 22,19% para a projeção, valores maiores do que os obtidos nos diferentes cenários deste trabalho. Contudo, é válido ressaltar que o trabalho de Scolforo et al. (2019b) possui maior abrangência espacial, com dados coletados em todo o país, o que pode ter afetado negativamente nas medidas de acurácia.

É importante destacar que os tipos de variáveis de entrada normalmente utilizadas em modelos de crescimento e produção, como nos trabalhos de Binoti et al. (2015), Silva (2018) e Scolforo (2019b), impossibilitam a predição e projeção do volume em locais que não possuam nenhuma informação de inventário florestal. Diante disso, a metodologia proposta neste trabalho possui a vantagem de, após o treinamento das *RNA*, permitir a sua aplicação em outras áreas florestais, sendo a idade do povoamento a única informação necessária, além das imagens orbitais, o que não gera custo adicional.

Comparando os resultados obtidos pela predição e projeção por modelos de distribuição de diâmetros, Leite et al. (2013) constataram que a projeção se mostrou mais eficiente para estimar a produção volumétrica. Observando as Tabelas 8 e 10, é possível notar essa mesma tendência, sendo as diferenças percentuais menores para a projeção.

Considerando a pequena diferença entre as médias estimadas pelos diferentes cenários e os valores de referência (Tabela 8 e 10), é possível indicar a metodologia proposta neste trabalho para a predição e projeção do crescimento e produção em povoamentos de eucalipto, sobretudo os cenários 2 e 3 que visam uma maior redução de custos.

Ao analisar os valores máximos das taxas de incremento mensais apresentados na Tabela 11, pode-se observar que a idade na qual ocorre inflexão na curva de crescimento da floresta (máximo *ICM*) obtida com dados de *IFC* foi muito próxima às obtidas nos três cenários. O mesmo aconteceu com a estimação da idade em que a floresta apresenta fase final de maturidade e *ITC* (máximo *IMM*). Isso mostra

que a projeção da produção volumétrica a partir de dados de sensoriamento remoto se mostrou eficiente para projetar o comportamento biológico de crescimento da floresta.

Um outro aspecto que deve ser levado em consideração é o fato de que, na maioria das vezes, modelos de crescimento e produção de florestas equiâneas são ajustados contendo informações de *IFC* com intensidade amostral de uma parcela a cada 10 ha (1:10). Ao realizar a modelagem com dados de sensoriamento remoto proposta pelos cenários 1, 2 e 3, seria possível uma redução dessa intensidade para uma parcela a cada 28, 42 e 83 ha, respectivamente, com resultados dentro do intervalo de confiança. Desta forma, os custos da obtenção de informações para o planejamento adequado da floresta podem ser reduzidos significativamente.

Como exemplo da possibilidade de redução de custos proporcionada pela utilização de dados de sensoriamento remoto pela metodologia aqui apresentada, foi considerado o custo de mensuração de uma parcela igual a R\$ 107,90 (BINOTI et al., 2013). O *IFC* realizado na área de estudo deste trabalho foi conduzido na intensidade amostral de aproximadamente uma parcela a cada 21 ha, sendo necessário mensurar 40 parcelas anualmente, o que iria gerar um custo de R\$ 25.896,00 ao final dos seis anos. Considerando a intensidade amostral tradicionalmente utilizada de uma parcela a cada dez ha, seria necessário mensurar 83 parcelas anualmente, gerando um custo de R\$ 53.734,20 durante os seis anos de realização do *IFC*.

Ao aplicar a metodologia aqui apresentada, seria necessário mensurar 30, 20 e 10 parcelas anualmente, segundo os cenários 1, 2 e 3, respectivamente. Ao final dos seis anos do *IFC*, o custo de mensuração das parcelas segundo os cenários 1, 2 e 3 seria de R\$ 19.442,00, R\$ 12.948,00 e R\$ 6.474,00, respectivamente. Dessa forma, é possível obter uma redução dos custos de até 75% quando comparado com a intensidade amostral utilizada no *IFC* deste estudo. Se comparado com a metodologia tradicional de realização de *IFC*, com uma parcela a cada dez ha, é possível obter uma redução de custos de aproximadamente 12% ao utilizar a intensidade amostral do cenário 3.

Além disso, existe a possibilidade de treinamento das *RNA* com os dados de *IFC* já existentes nas empresas florestais. Com isso, a *RNA* selecionada seria mais robusta, contando com uma maior quantidade de parcelas para o treino, não gerando novos custos para a obtenção de informações.

Em relação ao processo de amostragem, com uma intensidade amostral de uma parcela para cada 10 ha, considerando parcelas com área de 300 m², a amostragem corresponde a 0,3% da área, enquanto os dados de sensoriamento remoto são obtidos em 100% do talhão. Essa é uma das vantagens da metodologia aqui proposta, pois o uso de dados de sensoriamento remoto permite gerar informações espacializadas, em nível de pixel, sobre o crescimento e produção da floresta, o que não é possível ao utilizar apenas dados de inventários florestais. Esse elevado grau de detalhamento sobre a produção dos talhões ao aplicar técnicas de sensoriamento remoto é fundamental para atender às exigências atuais do mercado e para a aplicação das novas tecnologias de manejo e colheita proporcionadas pelo manejo florestal de precisão.

6 CONCLUSÕES

O uso de dados multiespectrais de média resolução espacial, juntamente com a idade do povoamento, permitiu estimar com acurácia a predição e projeção do crescimento e da produção volumétrica de florestas de eucalipto.

A redução na intensidade amostral do inventário florestal contínuo não influenciou negativamente na acurácia da predição e projeção do volume a partir de dados de sensoriamento remoto, gerando resultados compatíveis com o obtido pela metodologia tradicional.

A projeção da produção volumétrica a partir de dados de sensoriamento remoto se mostrou eficiente para projetar o comportamento biológico de crescimento da floresta.

É possível utilizar dados espectrais de média resolução espacial para reduzir o número de parcelas mensuradas no inventário florestal contínuo e, conseqüentemente, os custos, sem incorrer em perdas de acurácia.

7 REFERÊNCIAS

- ABREU, E. C. R. et al. Modelagem para prognose precoce do volume por classe diamétrica para *Eucalyptus grandis*. **Scientia Forestalis**, v.3, n. 61, p. 86-102, 2002.
- ALCÂNTRA, A. E. M. et al. Use of artificial neural networks to assess yield projection and average production of eucalyptus stands. **African Journal of Agricultural Research**. v. 13, n. 42, p. 2285-2297, 2018.
- ALMEIDA, A. Q. et al. Relações empíricas entre características dendrométricas da Caatinga brasileira e dados TM Landsat 5. **Pesquisa Agropecuária Brasileira**, v. 49, n. 4, p. 306–315, 2014.
- BAIG, M. H. A. et al. Derivation of a tasselled cap transformation based on Landsat 8 at-satellite reflectance. **Remote Sensing Letters**, v. 5, n. 5, p. 423-431, 2014.
- BERRA, E. F. **Avaliação e comparação de imagens LISS/RESOURCESAT-1 e TM/LANDSAT 5 para estimar volume de madeira de um plantio de *Pinus elliotii***. 2013. 127 f. Dissertação (Mestrado em Sensoriamento Remoto) – Universidade Federal do Rio Grande do Sul, Porto Alegre, 2013.
- BINOTI, D. H. B. et al. Redução dos custos em inventário de povoamentos equiâneos. **Revista Brasileira de Ciências Agrárias**. v. 8, n. 1, p. 125-129, 2013.
- BINOTI, M. L. M. S. et al. Prognose em nível de povoamento de clones de eucalipto empregando redes neurais artificiais. **Cerne**. v. 21, n. 1, p. 97-105, 2015.
- BOYD, D. S.; DANSON, F. M. Satellite remote sensing of forest resources: three decades of research development. **Progress in Physical Geography**, v. 29, n. 1, p. 1–26, 2005.
- CAMPOS, J. C. C; LEITE, H. G. **Mensuração florestal: perguntas e respostas**. 5. ed., Viçosa: UFV, 2017. 636 p.
- CAO, R. et al. A simple method to improve the quality of NDVI time-series data by integrating spatiotemporal information with the Savitzky-Golay filter. **Remote sensing of environment**. v. 217, p. 233-257, 2018.
- CASTRO, R. V. O. et al. Crescimento e produção de plantios comerciais de eucalipto estimados por duas categorias de modelos. **Pesquisa Agropecuária Brasileira**, v. 48, n. 3, p. 287-295, 2013.
- CHEN, G. et al. Stand age estimation of rubber (*Hevea brasiliensis*) plantations using an integrated pixel- and object-based tree growth model and annual Landsat time series. **ISPRS Journal of Photogrammetry and Remote Sensing**. v. 144, p. 94-104, 2018.
- CHEN, J. et al. A simple method for reconstructing a high-quality NDVI time-series data set based on the Savitzky–Golay filter. **Remote Sensing of Environment**. v. 91, p. 332-344, 2004.

CHU, T.; GUO, X.; TAKEDA, K. Remote sensing approach to detect post-fire vegetation regrowth in Siberian boreal larch forest. **Ecological Indicators**, v. 62, p. 32–46, 2016.

CLARK, R. N. et al. Imaging spectroscopy: earth and planetary remote sensing with the USGS Tetracorder and expert systems. **Journal of Geophysical research**. v. 108, n. 12, p. 1-44, 2003.

CLUTTER, J. L. Compatible growth and yield models for loblolly pine. **Forest Science**, v. 9, p. 354-371, 1963.

CRIST, E. P.; CICONE, R. C. A physically-based transformation of Thematic Mapper data – The TM Tasseled Cap. **IEEE Transactions on Geoscience and Remote Sensing**. v. GE-22, n. 3, 1984.

DAVIS, L. S. et al. **Forest management: to sustain ecological, economic, and social values**. 4. ed. Illinois: Waveland, 2005. 804 p.

DJOMO, A. N.; CHIMI, C. D. Tree allometric equations for estimation of above, below and total biomass in a tropical moist forest: case study with application to remote sensing. **Forest Ecology and Management**, v. 391, p. 184–193, 2017.

EASTMAN, J. R. **Idrisi for Windows**. Manual do usuário. Trad. HASENACK, H.; WEBER, E. Porto Alegre: UFRGS, Centro de Recursos Idrisi, Brasil, 1998.

FRAGA FILHO, C. V. **Modelagem para prognose do crescimento e produção de Eucalipto em diferentes níveis de abordagem**. 2016. 280 f. Tese (Doutorado em Ciências Florestais) – Universidade Federal do Espírito Santo, Jerônimo Monteiro, 2016.

GORELICK, N. et al. Google Earth Engine: Planetary-scale geospatial analysis for everyone. **Remote Sensing of Environment**, v. 202, p. 18-27, 2017.

GU, Y. et al. NDVI saturation adjustment: A new approach for improving cropland performance estimates in the Greater Platte River Basin, USA. **Ecological Indicators**. v. 30, 2013.

HEALEY, S. P. et al. Comparison of Tasseled Cap-based Landsat data structures for use in forest disturbance detection. **Remote Sensing of Environment**. v. 97, n. 3, p. 301-310, 2005.

HEO, J. et al. Timber age verification using historical satellite image analysis. **Forest Ecology and Management**. v. 236, n. 2-3, p. 315-323, 2006.

HUANG, C. et al. Derivation of a tasseled cap transformation based on Landsat 7 at-satellite reflectance. **International journal of remote sensing**. v. 23, n. 8, p. 1741-1748, 2002.

HUETE, A. et al. MODIS vegetation index (MOD13). **Algorithm theoretical basis document**. v. 3, n. 213, 1999.

HUETE, A.R. A soil-adjusted vegetation index. **Remote Sensing of Environment**, v.25, p.295-309. 1988.

JIN, S.; SADER, S. A. Comparison of time series tasseled cap wetness and the normalized difference moisture index in detecting forest disturbances. **Remote Sensing of Environment**. v. 94, n. 3, p. 364-372, 2005.

KAUTH, R. J.; THOMAS, G. S. The Tasseled Cap: A Graphic Description of the Spectral-Temporal Development of Agricultural Crops as Seen by LANDSAT. **LARS Symposia**, 1976.

KERSHAW Jr. et al. **Forest Mensuration**. John Wiley & Sons, Ltd, Chichester, UK. 5. ed., 2016.

LASSERRE, B. et al. Assessment of potential bioenergy from coppice forests through the integration of remote sensing and field surveys. **Biomass and Bioenergy**, v. 35, n. 1, p. 716–724, jan. 2011.

LEAL, F. A. **Técnicas de sensoriamento remoto e geoestatística aplicadas em um povoamento de *Eucalyptus urophylla* S. T. Blake para estimativa de volume**. 2013. 96 f. Dissertação (Mestrado em Ciências Florestais) – Universidade de Brasília, Brasília, 2013.

LEITE, H. G. et al. Comparação entre predição e projeção da distribuição de diâmetros de povoamentos de eucalipto submetidos a desbastes. **Revista Árvore**. v. 37, n. 2, p. 321-328, 2013.

LIGGES, U. et al. **Package ‘signal’**. R Foundation for Statistical Computing. 2015. Disponível em: <<http://cran.r-project.org/web/packages/signal/>>. Acesso em 19 dez. 2019.

LU, D. et al. Relationships between forest stand parameters and Landsat TM spectral responses in the Brazilian Amazon Basin. **Forest Ecology and Management**, v. 198, n. 1–3, p. 149–167, 2004.

LUTHER, J. E. et al. Biomass mapping using forest type and structure derived from Landsat TM imagery. **International Journal of Applied Earth Observation and Geoinformation**, v. 8, n. 3, p. 173–187, 2006.

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

MASEK, J. G. et al. The role of remote sensing in process-scaling studies of managed forest ecosystems. **Forest Ecology and Management**, v. 355, p. 109–123, 2015.

- MATHWORKS, INC. **Neural network toolbox**: User's Guide (R2016a). MathWorks, 2016.
- MATSUSHITA, B, et al. Sensitivity of the enhanced vegetation index (EVI) and normalized difference vegetation index (NDVI) to topographic effects: a case study in high-density cypress forest. **Sensors**. v. 7, n. 11, p. 2636-2651, 2007.
- MENESES, P. R.; ALMEIDA, T. **Introdução ao processamento de imagens e sensoriamento remoto**. Brasília: UNB, 2012. 266 p.
- MIGUEL, E. P. et al. Redes neurais artificiais para a modelagem do volume de madeira e biomassa do cerrado com dados de satélite. **Pesquisa Agropecuária Brasileira**, v. 50, n. 9, p. 829–839, 2015.
- MORAES, E. C. Fundamentos do sensoriamento remoto. In: RUDORFF, B. F. T. et al. **Curso de uso de sensoriamento remoto no estudo do meio ambiente**. São José dos Campos: INPE, 2002. Cap 1, p. 1-22.
- National Aeronautics and Space Administration. NASA. **Regions of the electromagnetic spectrum**. 2013. Disponível em: <https://imagine.gsfc.nasa.gov/science/toolbox/spectrum_chart.html>. Acesso em: 19 dez. 2019.
- NEIGH, C. S. R. et al. Regional rates of young US forest growth estimated from annual Landsat disturbance history and IKONOS stereo imagery. **Remote Sensing of Environment**, v. 173, p. 282–293, 2016.
- NOVO, E. M. L. M. **Sensoriamento Remoto**: princípios e aplicações. 2. ed. São Paulo: Edgard Blucher, 2010. 388p.
- PRETZSCH, H. **Forest dynamics, growth and yield**. Berlin: Springer, 2009. 664 p.
- PRODAN, M. et al. **Mensura forestal**. San José: IICA, 1997. 586 p.
- PUKKALA, T.; LÄHDE, E.; LAIHO, O. Growth and yield models for uneven-sized forest stands in Finland. **Forest Ecology and Management**. v. 258, n. 3, p. 207-216, 2009.
- PULITI, S. et al. Assessing 3D point clouds from aerial photographs for species-specific forest inventories. **Scandinavian Journal of Forest Research**, v. 32, 2017b, p. 68-79.
- PULITI, S. et al. Use of partial-coverage UAV data in sampling for large scale forest inventories. **Remote Sensing of Environment**, v. 194, 2017a, p. 115-126.
- R Core Team. **R**: a language and environment for statistical computing (R version 3.5.2.). Vienna: R Foundation for Statistical Computing, 2019.

REIS, A. A. et al. Spatial prediction of basal area and volume in Eucalyptus stands using Landsat TM data: an assessment of prediction methods. **New Zealand Journal of Forestry Science**. v. 48, n. 1, 2018.

REIS, A. A. et al. Volume estimation in a Eucalyptus plantation using multi-source remote sensing and digital terrain data: a case study in Minas Gerais State, Brazil. **International Journal of Remote Sensing**. v. 40, n. 7, p. 2683-2702, 2019.

SANQUETTA, C. R. et al. **Inventários florestais: planejamento e execução**. 3. ed. Curitiba: Multi-Graphic Gráfica e editora, 2014.

SAVITZKY, A.; GOLAY, M. J. E. Smoothing and differentiation of data by simplified least squares procedures. **Analytical chemistry**, v. 36, n. 8, p. 1627-1639, 1964.

SCOLFORO, H. F. et al. Eucalyptus growth and yield system: Linking individual-tree and stand-level growth models in clonal Eucalypt plantations in Brazil. **Forest Ecology and Management**. v. 432, p. 1-16, 2019a.

SCOLFORO, H. F. et al. Stand-level growth and yield model system for clonal eucalypt plantations in Brazil that accounts for water availability. **Forest Ecology and Management**. v. 448 p. 22-33, 2019b.

SCOLFORO, J. R. S. **Biometria florestal: modelos de crescimento e produção florestal**. Lavras: UFLA/FAEPE, 2006. 393 p.

SHI, T.; XU, H. Derivation of Tasseled Cap Transformation Coefficients for Sentinel-2 MSI At-Sensor Reflectance Data. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**. v. 12, n. 10, p. 4038-4048, 2019.

SILVA, C. A. et al. A principal component approach for predicting the stem volume in Eucalyptus plantations in Brazil using airborne LiDAR data. **Forestry**, v. 89, n. 4, p. 422–433, 2016.

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

SILVA, J. P. M. **Prognose da produção florestal utilizando Sistema Neurofuzzy e Random Forest**. 2018. 67 f. Dissertação (Mestrado em Ciências Florestais) – Universidade Federal do Espírito Santo, Jerônimo Monteiro, 2018.

SIVANPILLAI, R. et al. Estimation of managed loblolly pine stand age and density with Landsat ETM+ data. **Forest Ecology and Management**. v. 223, n. 1-3, p. 247-254, 2006.

SOUZA, C. C. et al. Técnicas de sensoriamento remoto como subsídios aos estudos de florestas implantadas no Brasil – uma revisão bibliográfica. **Ciência Florestal**, Santa Maria, v. 17, n. 4, p. 409-417, 2007.

SUMNALL, M. J.; HILL, R. A.; HINSLEY, S. A. Comparison of small-footprint discrete return and full waveform airborne lidar data for estimating multiple forest variables. **Remote Sensing of Environment**, v. 173, p. 214–223, 2016.

TOMPALSKI, P. et al. Enhancing forest growth and yield predictions with airborne laser scanning data: increasing spatial detail and optimizing yield curve selection through template matching. **Forests**, v. 7, n. 12, p. 255, 2016.

VAN GUNST, K. J. et al. Do denser forests have greater risk of tree mortality: A remote sensing analysis of density-dependent forest mortality. **Forest Ecology and Management**, v. 359, p. 19–32, 2016.

VAN LAAR, A.; AKÇA, A. **Forest mensuration**. Dordrecht: Springer Science & Business Media, 2007. 384p.

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

VELOSO, R. B. **Proposta de um modelo não linear de crescimento e produtividade florestal**. 2013. 102 f. Dissertação (Mestrado em Engenharia Florestal) – Universidade Federal de Lavras, Lavras, 2013.

WENDLING, W. T. Ajuste da função de distribuição diamétrica Weibull por planilha eletrônica. **Revista Floresta**, v. 41, n. 2, p. 205-220, 2011.

WHITE J. C. et al. Remote sensing technologies for enhancing forest inventories: a review. **Canadian Journal of Remote Sensing**. v. 42, p. 619–641, 2016.

WULDER, M. Optical remote-sensing techniques for the assessment of forest inventory and biophysical parameters. **Progress in Physical Geography**, v. 22, n. 4, p. 449-476, 1998.