

Estimativa de povoamento de *Eucalyptus urophylla* S.T. Blake utilizando Redes Neurais artificiais e índices de Vegetação

Estimation of *Eucalyptus urophylla* S.T. Blake stands using artificial neural networks and vegetation indices

Estimación de la población de *Eucalyptus urophylla* S.T. Blake usando redes neuronales artificiales e índices de vegetación

Recebido: 10/10/2023 | Revisado: 23/10/2023 | Aceitado: 24/10/2023 | Publicado: 27/10/2023

Moises Parreiras Pereira

ORCID: <https://orcid.org/0000-0002-2885-3035>
Universidade Federal do Acre, Brasil
E-mail: moisesgeo2020@gmail.com

Fabício Assis Leal

ORCID: <https://orcid.org/0000-0001-8522-0114>
Universidade Federal do Acre, Brasil
E-mail: fabricioassisleal@gmail.com

Glória da Silva Almeida Leal

ORCID: <https://orcid.org/0000-0002-0381-1584>
Universidade Federal do Acre, Brasil
E-mail: gloriaalmeidaleal@gmail.com

Valdemar de Matos Paula

ORCID: <https://orcid.org/0000-0002-6241-3156>
Universidade Federal do Acre, Brasil
E-mail: vldmrmatos@gmail.com

Alan Augusto Nobre Feitosa

ORCID: <https://orcid.org/0009-0001-4560-5965>
Instituto Federal do Acre, Brasil
E-mail: alan.feitosa@ifac.edu.br

Symone Maria de Melo Figueiredo

ORCID: <https://orcid.org/0000-0002-9702-736X>
Universidade Federal do Acre, Brasil
E-mail: symone.figueiredo@ufac.br

Resumo

No Brasil, as áreas de florestas plantadas abrangem 54,4% e realizar inventários florestais é fundamental para o Manejo florestal. Os métodos tradicionais de coleta para inventário são trabalhosos e dispendiosos. Uma alternativa tem sido a combinação de dados de sensores remotos e redes neurais artificiais (RNA) como uma abordagem comparativa. Objetivo deste estudo é avaliar a concordância entre estimativas de biomassa feitas por redes neurais artificiais usando índices de vegetação e o método tradicional de inventário florestal. Foi utilizado um inventário do ano de 2011, realizado no município de Rio Verde, Goiás, em um povoamento de *Eucalyptus urophylla* S. T. Blake, pertencente à Cooperativa Agroindustrial dos Produtores Rurais do Sudoeste Goiano (COMIGO), 23 parcelas amostrais aleatórias de 400 m² foram coletados o diâmetro, altura, volume, e outros parâmetros. As imagens de satélite RapidEye foram adquiridas e índices de vegetação, como NDVI, MSAVI, NDRE e EVI. Redes neurais artificiais foram treinadas e validadas no programa NeuroForest Star, para estimar o volume de árvores por parcela. Os resultados indicaram que as estimativas foram comparáveis às abordagens tradicionais de inventário florestal. Ademais, as correlações variaram de -0,84 a 0,99, com um erro padrão da estimativa relativo (syx %) variando de 0,20% a 16,59%. As diferentes arquiteturas de redes neurais artificiais apresentaram variações nas estimativas de volume, e algumas não se mostraram estáveis na etapa de validação. Entretanto, as arquiteturas dos índices NDRE e MSAVI se destacaram pela estabilidade para estimativas de volume por parcela, demonstrando eficácia da RNA como método eficiente e acessível.

Palavras-chave: Inventário florestal; Índice de vegetação; Inteligência artificial.

Abstract

In Brazil, planted forest areas cover 54.4% and carrying out forest inventories is essential for forest management. Traditional inventory collection methods are laborious and expensive. An alternative has been to combine data from remote sensors and artificial neural networks (ANN) as a comparative approach. The objective of this study is to evaluate the agreement between biomass estimates made by artificial neural networks using vegetation indices and the traditional forest inventory method. An inventory from the year 2011 was used, carried out in the municipality of Rio Verde, Goiás, in a stand of *Eucalyptus urophylla* S. T. Blake, belonging to the Cooperativa Agroindustrial dos Produtores Rurais do Sudoeste Goiano (COMIGO), 23 random sample plots of 400 m² were collected the diameter, height, volume, and other parameters. RapidEye satellite images were acquired and vegetation indices such as NDVI, MSAVI, NDRE and EVI. Artificial neural networks were trained and validated in the NeuroForest Star program to estimate the volume of trees per plot. The results indicated that the estimates were comparable to traditional forest inventory approaches. Furthermore, correlations ranged from -0.84 to 0.99, with a standard error of the relative estimate (syx %) ranging from 0.20% to 16.59%. The different artificial neural network architectures presented variations in volume estimates, and some were not stable in the validation stage. However, the architectures of the NDRE and MSAVI indices stood out for their stability for volume estimates per plot, demonstrating the effectiveness of ANN as an efficient and accessible method.

Keywords: Forest inventory; Vegetation index; Artificial intelligence.

Resumen

En Brasil, las áreas forestales plantadas cubren el 54,4% y la realización de inventarios forestales es fundamental para la gestión forestal. Los métodos tradicionales de recopilación de inventarios son laboriosos y costosos. Una alternativa ha sido combinar datos de sensores remotos y redes neuronales artificiales (RNA) como enfoque comparativo. El objetivo de este estudio es evaluar la concordancia entre las estimaciones de biomasa realizadas por redes neuronales artificiales utilizando índices de vegetación y el método tradicional de inventario forestal. Se utilizó un inventario del año 2011, realizado en el municipio de Rio Verde, Goiás, en un rodal de *Eucalyptus urophylla* S. T. Blake, perteneciente a la Cooperativa Agroindustrial dos Produtores Rurais do Sudoeste Goiano (COMIGO), 23 parcelas de muestreo aleatorio de 400 m² se recogieron el diámetro, altura, volumen y otros parámetros. Se adquirieron imágenes satelitales RapidEye e índices de vegetación como NDVI, MSAVI, NDRE y EVI. Se entrenaron y validaron redes neuronales artificiales en el programa NeuroForest Star para estimar el volumen de árboles por parcela. Los resultados indicaron que las estimaciones eran comparables a los enfoques tradicionales de inventario forestal. Además, las correlaciones oscilaron entre -0,84 y 0,99, con un error estándar de la estimación relativa (syx%) que oscila entre el 0,20% y el 16,59%. Las diferentes arquitecturas de redes neuronales artificiales presentaron variaciones en las estimaciones de volumen, y algunas no se mostraron estables en la etapa de validación. Sin embargo, las arquitecturas de los índices NDRE y MSAVI destacaron por su estabilidad para las estimaciones de volumen por parcela, demostrando la efectividad de las RNA como un método eficiente y accesible.

Palabras clave: Inventario forestal; Índice de vegetación; Inteligencia artificial.

1. Introdução

No território brasileiro as áreas de florestas equivalem a 463 milhões de hectares, que somam 54,4% do território nacional (SFB, 2013). Visando a importância econômica e a obtenção de informações dessas áreas, o inventário florestal é ferramenta indispensável que objetiva informar sobre os recursos e estoques existentes (Péllico Netto & Brena, 1997). Segundo Scolforo (1997) e Ferreira et al. (1977), por meio do inventário florestal e da coleta dos dados realizada em campo tornam-se possíveis avaliar o crescimento das árvores, obter a altura e o diâmetro das árvores, além da quantificação do volume, biomassa e área basal. Contudo, as estimativas tradicionais destas variáveis a partir de inventários florestais são muito laboriosas, onerosas e morosas, o que inviabiliza alguns levantamentos mais aprofundados e detalhados (Leal et al., 2016).

Alternativamente, os dados de sensores remotos têm se mostrado eficientes e úteis para algumas estimativas no meio florestal. Em geral, as estimativas obtidas tradicionalmente em campo são associadas aos dados e produtos derivados de sensores remotos que, posteriormente, são analisadas por diversos métodos a partir da correlação entre as observações, o que torna possível a estimativa de certas informações como, por exemplo, o volume (Souza et al., 2007). A utilização de métodos e processos que quantificam o volume utilizando dados de sensores remoto ganha espaço pela sua praticidade e escala de abrangência. Os índices de vegetação, por exemplo, são bastante empregados em trabalhos que visam quantificar determinada vegetação, por serem

excelentes descritores de florestas (Qi et al., 2000; Leal et al., 2016). Atualmente, os índices de vegetação estão sendo utilizados com tecnologias matemáticas que permitem o aprendizado de determinadas tarefas para melhorar as estimativas, bem como diminuam os equívocos nas predições.

Essas tecnologias matemáticas são um tipo de inteligência artificial e comumente são conhecidas por redes neurais artificiais (RNA). As RNA desempenham papel fundamental no aprendizado de importantes tarefas e são aplicadas em diversas áreas do conhecimento. Para as RNA são atribuídos várias vantagens e diversos trabalhos já relataram superioridade em relação a alguns métodos tradicionais de estimativas florestais (Kuan & White, 1994; Miguel et al., 2015; Leal et al., 2015).

As redes neurais artificiais (RNA), segundo Binoti et al. (2013c), são um conjunto de unidades de processamento simplificado, que fornecem estimativas e executam determinadas atividades de aprendizado. A aplicação e quantificação de parâmetros de produção florestal em grandes áreas, por meio de RNA, vêm sendo também utilizados em trabalhos com dados de sensores remotos (Almeida et al., 2014).

A utilização de RNA e dados de sensores remotamente situados é uma abordagem que vem ganhando espaço (Miguel et al., 2015). As RNA têm apresentado desempenhos satisfatórios, por mostrarem superioridade nas estimativas quando comparados com a regressão, por exemplo (Binoti et al., 2015; Haykin, 2001; Lek et al., 1996).

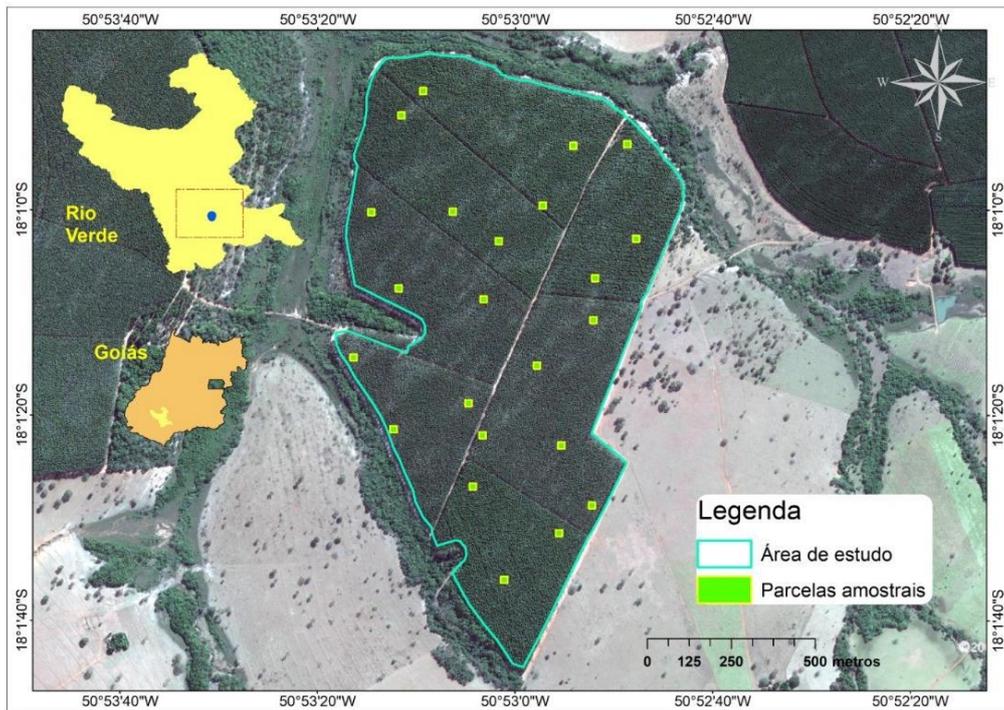
O estudo avaliou a concordância entre estimativas de biomassa feitas por redes neurais artificiais usando índices de vegetação e o método tradicional de inventário florestal. Também examinou o impacto de diferentes arquiteturas de redes neurais na precisão das estimativas de biomassa por parcela. O objetivo foi determinar se existem diferenças estatísticas entre as estimativas desses dois métodos e avaliar as diferenças por meio de validação.

2. Metodologia

Os dados para desenvolvimento deste estudo provêm de um inventário florestal realizado no município de Rio Verde/GO em 2011, em um povoamento de *Eucalyptus urophylla* S. T. Blake, com 6,5 anos de idade, plantado no espaçamento de 2,8 x 1,8 m, pertencente à Cooperativa Agroindustrial dos Produtores Rurais do Sudoeste Goiano - COMIGO. A área apresenta altitude média de 685 metros, localizada entre os paralelos 18° 00' 45'' e 18° 01' 45'' de latitude Sul, e entre os meridianos 50° 52' 45'' e 50° 53' 15'' de longitude Oeste. Segundo a classificação de KÖPPEN, o clima é do tipo Aw, tropical úmido. A precipitação média anual varia de 1.200 a 1.500 mm, com média anual em torno de 1300 mm e temperaturas médias em torno de 20° a 25°C. O inventário florestal serviu de base para estimar o volume de madeira (m³/parcela) em todas as unidades amostrais. E para esse procedimento o erro máximo admissível foi de 10%. Detalhes deste processo e podem ser vistos em Leal et al. (2011) e Leal (2013).

A área foi subdividida em parcelas de 20 x 20 m e as parcelas a serem inventariadas foram sorteadas aleatoriamente, como mostra a seguir na Figura 1.

Figura 1 - Imagens da área de estudo, respectivas parcelas de 400m².



Fonte: *Google Earth Pro* (09/2010). Elaborado pelos autores.

Nessas parcelas foi mensurado o DAP (diâmetro a altura do peito - 1,30 m) de todos os indivíduos vivos por meio de suta. Para a variável altura total (HT) foram consideradas apenas as árvores cubadas rigorosamente. Portanto, não houve estimativa dessa variável. A variável área basal (G) por parcela (m²/parcela) foi obtida com o somatório das áreas seccionais (g) de cada árvore.

A escolha das árvores a serem cubadas rigorosamente foi realizada em áreas próximas as parcelas amostradas, após caracterização quanto sua estrutura diamétrica. As 97 árvores selecionadas para a cubagem pertenceram a diferentes classes de diâmetro. Cada árvore foi abatida ao nível do solo com o uso de motosserra e o diâmetro inicial tomado neste ponto. A cubagem foi realizada pelo método de Hohenadl (Equação 1) com 10 seções: 5, 15, 25, 35, 45, 55, 65, 75, 85 e 95% da altura total da árvore (Machado; Figueiredo Filho, 2009). Nesses pontos foram obtidas as áreas seccionais para o cálculo do volume de cada árvore.

$$\text{vol} = \frac{\text{HT}}{10} * \left\{ \left(\frac{\pi * D^2 \text{seção } 5\%}{40.000} \right) + \left(\frac{\pi * D^2 \text{seção } 15\%}{40.000} \right) + \dots + \left(\frac{\pi * D^2 \text{seção } 95\%}{40.000} \right) \right\} + \text{vol ponta} \quad \text{Equação 1}$$

A partir dos dados da cubagem rigorosa foram ajustadas equações hipsométricas e volumétricas, após os ajustes e avaliação dos desempenhos estatísticos dos modelos para estimativa da altura e volume foram, respectivamente, Prodan (Equação 2) e Schumacher e Hall (Equação 3).

$$\text{HT} = \frac{\text{DAP}^2}{2,86349 - 0,0972117 * \text{DAP} + 0,0349208 * \text{DAP}^2} \quad \text{Equação 2}$$

$$\text{VOL} = 0,00004153 * \text{DAP}^{1,69978} * \text{HT}^{1,21340} \quad \text{Equação 3}$$

Na realização deste trabalho utilizou uma imagem do sensor REIS (RapidEye Earth Imaging System) do satélite

RapidEye (ID 2230715), adquirida em 9 de outubro de 2011, data próxima a que foi realizada o inventário florestal (agosto/2011). Esta imagem é cedida pelo ministério do MMA, por meio do Sitio eletrônico GEO catálogo. A imagem foi corrigida geometricamente na origem (Georreferenciada), bastando desta forma, apenas elaborar a conversão dos valores do número digital (DN) para reflectância do topo da atmosfera (TOA), utilizando dados do arquivo metadados que acompanha a imagem, conforme preconizam Chander et al. (2009).

A conversão radiométrica envolve a transformação de valores de números digitais para valores físicos de reflectância no topo da atmosfera (TOA), em imagens adquiridas por sensores remotamente situados. Há abordagens que nem sempre é necessário realizar a calibração radiométrica, porém, em estudos que envolvem comparação e análise do comportamento espectral de determinado alvo é fundamental que se realize esta calibração (Costa, 2017). Alguns índices de vegetação e de clorofila, derivados de dados de sensores remotos, foram utilizados nesta pesquisa para verificar as suas relações com variáveis dendrométricas mensuradas em campo.

Após a obtenção da imagem RapidEye no tópico anterior foi então obtido os índices de vegetação para, posteriormente, realizar as estimativas do volume por parcela, utilizando os índices de vegetação e redes neurais artificiais. Os índices de vegetação utilizados para quantificação da vegetação foram os seguintes: NDVI, MSAVI, NDRE e EVI (Weng et al., 2022; Costa et al., 2023). Para o treinamento de redes neurais artificiais, do total de 23 parcelas, 17 foram aleatoriamente selecionadas (74%) para o treinamento das redes neurais artificiais (RNA) e as outras 6 parcelas (26%) foram utilizadas para a validação das estimativas do volume por parcela. Ao todo foram treinadas 12 redes neurais artificiais do tipo Perceptron de múltiplas camadas (Multilayer Perceptron - MLP).

No presente estudo o algoritmo utilizado foi o Resilient Backpropagation (RPROP), proposto por Riedmiller e Braun (1993), com taxas de aprendizagem variando entre 0 (zero) e 1 (um). Esta é uma das alternativas mais precisas, eficientes e recomendadas para RNA do tipo Multilayer Perceptron (Shidlee et al., 2010). Esta categoria de redes neurais é a mais usual na resolução de problemas de modelagem, previsões e projeções, em função da existência de camadas ocultas ou de processamento, o que permite a rede adaptar e processar com maior precisão informações de entrada (preditoras), a valores de saída ou respostas (Heitari et al., 2016).

O número excessivo de ciclos pode induzir a rede a perda da capacidade de generalização (overfitting), também com baixo número de ciclos a rede pode não chegar a sua melhor performance (underfitting). Para solucionar tais problemas, como critério de parada do algoritmo RPROP de treinamento foi utilizado o número total de ciclos igual a 3 mil ou erro quadrático médio inferior a 1% (Chen et al., 2014). Portanto, o treinamento das redes foi concluído quando um dos critérios a ser alcançado. Optou-se pela função sigmoideal na ativação do treinamento das RNA. Esta função é a mais usual na elaboração de redes neurais artificiais, a qual, em arquiteturas bem elaboradas, pode aproximar qualquer função contínua com precisão (Haykin, 2001).

Para o treinamento das RNA foi utilizado o programa NeuroForest Star (Binoti et al., 2013b). Para verificar se diferentes arquiteturas de redes neurais artificiais, na estimativa de volume por parcela, influenciam nas estimativas dessa variável no povoamento em questão, foram testadas diversas arquiteturas de redes neurais artificiais. Ao todo foram treinadas e validadas 12 redes neurais artificiais. Cada uma das redes neurais artificiais treinadas e validadas tem como camada de entrada um índice de vegetação e como camada de saída foi o volume por parcela. Houve três variações para o número de neurônios na camada oculta, sendo 6, 8 ou 10 neurônios. Já para as variáveis categóricas, todas as redes neurais treinadas e validadas tiveram: área basal (G) da parcela (m^2 /parcela), diâmetro médio das árvores da parcela a altura do peito (DAP); porcentagem de abertura de dossel da parcela (AB%) e altura total (HT) média das árvores da parcela (Tabela 1).

Tabela 1 - Arquiteturas das redes neurais para treinamento e validação, variáveis de entrada, categóricas e camada oculta, para estimativa de volume por parcela.

| Camada de entrada | Neurônios na camada oculta | Variáveis categóricas | Camada de saída | Apêndice (arquitetura) |
|-------------------|----------------------------|-----------------------|--------------------|------------------------|
| NDVI | 10 | G; DAP; AB%; HT | Volume por parcela | 1 |
| | 8 | | | 2 |
| | 6 | | | 3 |
| MSAVI | 10 | G; DAP; AB%; HT | Volume por parcela | 4 |
| | 8 | | | 5 |
| | 6 | | | 6 |
| NDRE | 10 | G; DAP; AB%; HT | Volume por parcela | 7 |
| | 8 | | | 8 |
| | 6 | | | 9 |
| EVI | 10 | G; DAP; AB%; HT | Volume por parcela | 10 |
| | 8 | | | 11 |
| | 6 | | | 12 |

Em que: G = área basal média da parcela (m²); DAP = diâmetro médio das árvores da parcela a altura do peito; AB% = porcentagem de abertura de dossel da parcela; HT = altura total média das árvores da parcela. Fonte: Elaborado pelo autor.

As estimativas de volume por parcela e os desempenhos de cada rede neural artificial treinada e validada foram avaliadas por meio dos seguintes critérios: erro padrão da estimativa absoluto (syx) e porcentagem (syx%) e gráfico de dispersão de resíduos (Leal et al., 2015).

Para confirmar se houve ou não diferença significativa entre as estimativas advindas do inventário florestal, em relação as estimativas obtidas a partir das redes neurais artificiais utilizando os índices de vegetação como variável de entrada, foi realizado o teste estatístico de Kruskal e Wallis (1952). Este teste estatístico comparou as estimativas tanto dos treinamentos quanto para a validação, ao nível de 5% de significância.

3. Resultados e Discussão

Após a mensuração de todos os indivíduos nas 23 parcelas, da cubagem rigorosa das árvores, bem como da aplicação das equações de Prodan (Equação 2) e Schumacher e Hall (Equação 3), respectivamente, hipsometria e volumetria, aos dados medidos nas parcelas em campo, foram obtidas todas as informações necessárias para o presente trabalho (Tabela 2).

O erro amostral relativo do inventário florestal foi de 7,9% (ou 0,80665 m³), que ficou abaixo do erro máximo admitido no inventário florestal (10%). Desta forma não há nenhum impedimento de continuar as análises por falta de representatividade das 23 parcelas utilizadas (Scolforo; Mello, 2006; Leal, 2013; Leal et al., 2015).

Tabela 2 - Resumo das principais informações nas 23 parcelas, aleatoriamente amostradas na área de estudo, obtidas por meio do inventário florestal.

| Parcela | HT | DAP | H dom | Volume | G |
|---------|------|------|-------|---------|--------|
| 46-1 | 22,9 | 14,8 | 27,9 | 12,4046 | 1,1117 |
| 46-2 | 22,6 | 14,6 | 27,9 | 11,7842 | 1,0589 |
| 46-3 | 22,3 | 14,0 | 27,5 | 8,8002 | 0,7986 |
| 47-1 | 22,7 | 14,7 | 28,0 | 11,5512 | 1,0384 |
| 47-2 | 22,6 | 14,9 | 27,9 | 10,3860 | 0,9312 |
| 47-3 | 21,9 | 14,1 | 27,7 | 11,1312 | 1,0055 |
| 48-1 | 21,0 | 13,2 | 27,6 | 9,8879 | 0,9085 |
| 48-2 | 20,5 | 12,6 | 26,9 | 9,6880 | 0,8980 |
| 48-3 | 21,2 | 12,9 | 27,1 | 8,8266 | 0,8202 |
| 49-1 | 21,6 | 13,2 | 26,5 | 10,2612 | 0,9408 |
| 49-2 | 21,1 | 13,1 | 27,3 | 10,7197 | 0,9866 |
| 49-3 | 21,0 | 13,2 | 27,8 | 11,1831 | 1,0256 |
| 50-1 | 21,6 | 13,7 | 27,3 | 9,6791 | 0,8808 |
| 50-2 | 21,6 | 13,3 | 27,3 | 8,6597 | 0,7940 |
| 50-3 | 21,3 | 13,8 | 28,2 | 11,4998 | 1,0486 |
| 51-1 | 22,4 | 14,5 | 27,2 | 8,5599 | 0,7651 |
| 51-2 | 22,9 | 14,4 | 27,2 | 8,6483 | 0,7786 |
| 51-3 | 23,4 | 15,7 | 27,5 | 8,5444 | 0,7580 |
| 51-4 | 22,8 | 14,7 | 27,6 | 7,9867 | 0,7155 |
| 51-5 | 22,2 | 13,9 | 27,3 | 9,1372 | 0,8287 |
| 52-1 | 22,6 | 13,9 | 26,6 | 7,9530 | 0,7209 |
| 52-2 | 22,5 | 14,3 | 27,4 | 10,1026 | 0,9092 |
| 52-3 | 22,6 | 14,2 | 27,3 | 9,2956 | 0,8407 |

Em que: HT = altura total média (m); DAP = diâmetro médio (cm); H Dom = altura dominante (m); Volume = (m³/parcela); G = área basal (m²/parcela). Fonte: Elaborado pelo autor.

A obtenção do volume por meio de ajustes das equações para se estimar o volume biomassa florestal são encontrados em trabalho como Leal et al. (2016), entre outros trabalhos como de Souza et al. (2017), que buscam estimativa da altura e depois obtenção do volume. Já em Silva et al. (2009), a equação de Schumacher e Hall apresentou boa representatividade para estimativa de volume, em relação a outros métodos convencionais.

Para testar os efeitos sobre as estimativas do volume, as fotos hemisféricas para obter a abertura de dossel (AB%) foram processadas em cada parcela. O processo de avaliação da abertura de dossel gerou uma porcentagem média para cada parcela. Os resultados obtidos no inventário florestal por meio de três fotos hemisféricas descreveram valores entre 16% e 25,7% de abertura no dossel, mostrando que em certas áreas a entrada de luminosidade é maior que em outras parcelas. Na Tabela 3 podem ser observadas as porcentagens de abertura de dossel para cada parcela do inventário.

Tabela 3 - Abertura média de dossel (%) para as 23 parcelas do inventário florestal.

| Parcela | AB% | Parcela | AB% | Parcela | AB% | Parcela | AB% |
|---------|------|---------|------|---------|------|---------|------|
| 46-1 | 19,5 | 48-2 | 16,7 | 50-3 | 17,2 | 52-2 | 23,1 |
| 46-2 | 20,3 | 48-3 | 17,1 | 51-1 | 25,2 | 52-3 | 25,7 |
| 46-3 | 17,7 | 49-1 | 18,1 | 51-2 | 25,2 | - | - |
| 47-1 | 16,5 | 49-2 | 16,0 | 51-3 | 19,9 | - | - |
| 47-2 | 18,5 | 49-3 | 16,2 | 51-4 | 20,1 | - | - |
| 47-3 | 17,0 | 50-1 | 17,2 | 51-5 | 22,7 | - | - |
| 48-1 | 16,9 | 50-2 | 18,4 | 52-1 | 25,7 | - | - |

Fonte: Autores (2020).

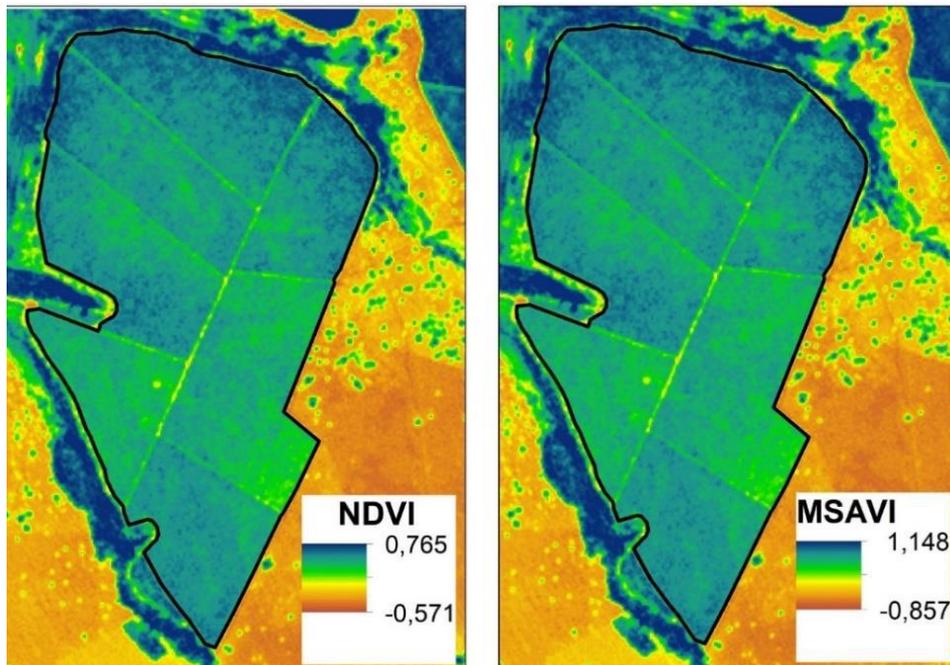
Os dados obtidos de abertura de dossel em plantio florestal, apresenta um dado importante para o inventário florestal, pois gera diminuição nos custos do inventário florestal e apresenta qualidade da abertura do dossel do povoamento nas unidades

amostrais, reduzindo assim custo do inventário quando aplicada em técnica de redes neurais artificiais (Leal et al., 2015). As imagens de abertura de dossel são consideradas uma técnica que gera menos custos e de fácil obtenção, sendo de grande potencial ao setor florestal, pois esta técnica se diferencia das tradicionais usadas em inventário florestal para se obter o volume pois elas são mais onerosas (Chaves et al., 2007).

Em diversos trabalhos de mensuração florestal a obtenção de dados como altura já não se é comumente medido, pelo fato de apresentar alguns obstáculos como o tempo de coleta dos dados, o erro ao observar e grande problema de obstrução visual, dificultando assim a obtenção destes dados (Colbert & Lootens, 2002; Campos & Leite, 2009; Binoti et al., 2012). Segundo Rodrigues et al. (2016), a boa qualidade das imagens multiespectrais da constelação de satélites RapidEye se destaca em comparação com as imagens advindas do sensor OLI (Operational Land Imager), a bordo do satélite Landsat 8, a partir da observação de indicadores estatísticos e a comparação visual entre as elas.

Após a composição de bandas foram obtidas as imagens índices de vegetação, aplicando as equações respectivamente NDVI, MSAVI, NDRE e EVI. Na Figura 2 é possível visualizar as imagens índice de vegetação para NDVI e MSAVI. Nota-se na escala do NDVI que para toda a área os valores variaram entre -0,571 e 0,765. Já para o MSAVI os valores ficaram entre -0,857 e 1,148. Vale ressaltar que valores positivos representam locais com maior quantidade de vegetação, em relação aos valores próximos a zero e negativos.

Figura 2 - Imagens índices de vegetação para NDVI e MSAVI obtidas para a área de estudo.



Fonte: Autores (2020).

Após obter as imagens índices NDVI e MSAVI foram então obtidos os índices de vegetação médio por parcela do inventário. Os valores de NDVI e MSAVI apresentam um nível de precisão na detecção da vegetação da área do plantio, como são descritos na Tabela 4 pode-se observar os valores médios encontrados do NDVI e MSAVI para as 23 parcelas.

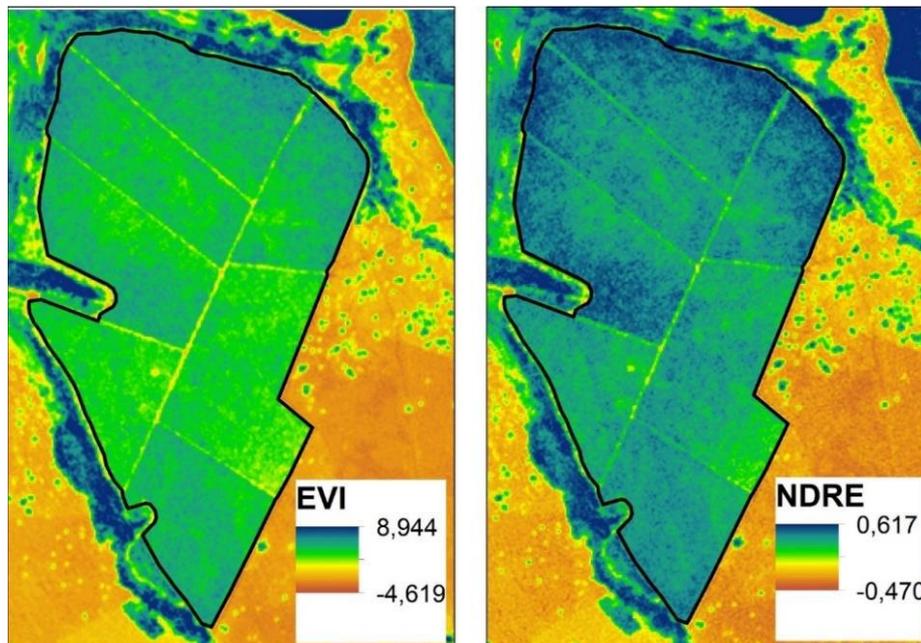
Tabela 4 - Índices de vegetação NDVI e MSAVI médio por parcela.

| Parcela | NDVI | MSAVI | Parcela | NDVI | MSAVI | Parcela | NDVI | MSAVI |
|---------|-------|-------|---------|-------|-------|---------|-------|-------|
| 46-1 | 0,501 | 0,751 | 48-3 | 0,550 | 0,825 | 51-2 | 0,482 | 0,723 |
| 46-2 | 0,509 | 0,763 | 49-1 | 0,517 | 0,776 | 51-3 | 0,459 | 0,688 |
| 46-3 | 0,408 | 0,612 | 49-2 | 0,572 | 0,858 | 51-4 | 0,399 | 0,599 |
| 47-1 | 0,568 | 0,852 | 49-3 | 0,578 | 0,868 | 51-5 | 0,529 | 0,793 |
| 47-2 | 0,536 | 0,804 | 50-1 | 0,558 | 0,837 | 52-1 | 0,488 | 0,733 |
| 47-3 | 0,555 | 0,832 | 50-2 | 0,515 | 0,773 | 52-2 | 0,549 | 0,824 |
| 48-1 | 0,563 | 0,845 | 50-3 | 0,595 | 0,893 | 52-3 | 0,546 | 0,818 |
| 48-2 | 0,529 | 0,793 | 51-1 | 0,483 | 0,725 | | | |

Fonte: Autores (2020).

Na Figura 3 é possível visualizar as imagens índice de vegetação para EVI e NDRE. Nota-se na escala do EVI que para toda a área apresentada os valores variaram entre -4,619 e 8,944. Já para o NDRE os valores foram entre -0,470 e 0,617.

Figura 3 - Imagens índices de vegetação para EVI e NDRE obtidas para a área de estudo.



Fonte: Autores (2010).

Da mesma forma que anteriormente, após obter as imagens índices EVI e NDRE foram então obtidos os índices de vegetação médio por parcela do inventário. Na Tabela 5 pode-se observar os valores médios encontrados do EVI e NDRE para as 23 parcelas, os valores de EVI variaram entre -4,619 e 8,944. Já para o NDRE os valores foram entre -0,470 e 0,617.

Tabela 5 - Índices de vegetação EVI e NDRE médio por parcela.

| Parcela | EVI | NDRE | Parcela | EVI | NDRE | Parcela | EVI | NDRE |
|---------|-------|-------|---------|-------|-------|---------|-------|-------|
| 46-1 | 0,416 | 0,382 | 48-3 | 0,473 | 0,413 | 51-2 | 0,394 | 0,368 |
| 46-2 | 0,430 | 0,387 | 49-1 | 0,431 | 0,380 | 51-3 | 0,370 | 0,349 |
| 46-3 | 0,322 | 0,314 | 49-2 | 0,502 | 0,424 | 51-4 | 0,324 | 0,311 |
| 47-1 | 0,498 | 0,440 | 49-3 | 0,517 | 0,429 | 51-5 | 0,453 | 0,405 |
| 47-2 | 0,453 | 0,405 | 50-1 | 0,484 | 0,418 | 52-1 | 0,414 | 0,368 |
| 47-3 | 0,483 | 0,424 | 50-2 | 0,438 | 0,386 | 52-2 | 0,481 | 0,404 |
| 48-1 | 0,486 | 0,424 | 50-3 | 0,534 | 0,442 | 52-3 | 0,483 | 0,396 |
| 48-2 | 0,453 | 0,393 | 51-1 | 0,402 | 0,380 | | | |

Fonte: Autores (2020).

Uma vez obtidos os índices de vegetação médio por parcela (Tabelas 4 e 5), esses valores foram concatenados aos dados das Tabelas 2 e 3, obedecendo rigorosamente a correspondência de cada valor com sua respectiva parcela de origem. De posse desses dados foram então treinadas e validadas as redes neurais artificiais, com suas diferentes arquiteturas.

Através das imagens dos gráficos é possível notar que os resultados estatísticos demonstram um erro no padrão da média (syx em m³ e %), que mediu o quão os valores observados variaram em relação aos valores estimados, bem como as bias.

Tabela 6 - Resultados estatísticos obtidos após o treinamento das diferentes arquiteturas de redes neurais artificiais adotadas neste trabalho.

| Índice | Neurônios | Treinamento | | | |
|--------|-----------|-------------|-----------------------|---------|------------------------|
| | | <i>r</i> | syx (m ³) | syx (%) | Bias (m ³) |
| NDVI | 6 | 0,9996 | 0,044 | 0,44 | 0,002 |
| | 8 | 0,9997 | 0,043 | 0,44 | 0,008 |
| | 10 | 0,9996 | 0,044 | 0,44 | 0,001 |
| MSAVI | 6 | 0,9996 | 0,044 | 0,44 | 0,007 |
| | 8 | 0,9997 | 0,045 | 0,45 | 0,021 |
| | 10 | 0,9996 | 0,044 | 0,44 | 0,010 |
| NDRE | 6 | 0,9997 | 0,052 | 0,52 | 0,034 |
| | 8 | 0,9996 | 0,044 | 0,44 | 0,009 |
| | 10 | 0,9997 | 0,044 | 0,44 | 0,008 |
| EVI | 6 | 0,9996 | 0,046 | 0,46 | -0,013 |
| | 8 | 0,9996 | 0,044 | 0,44 | 0,006 |
| | 10 | 0,9997 | 0,044 | 0,44 | 0,010 |

Onde: *r* = correlação entre valores observados e as estimativas; syx (m³) = erro padrão da estimativa absoluto; syx (%) = erro padrão da estimativa em porcentagem; Bias (m³) = volume da estimativa menos volume observado. Fonte: Elaborado pelos autores.

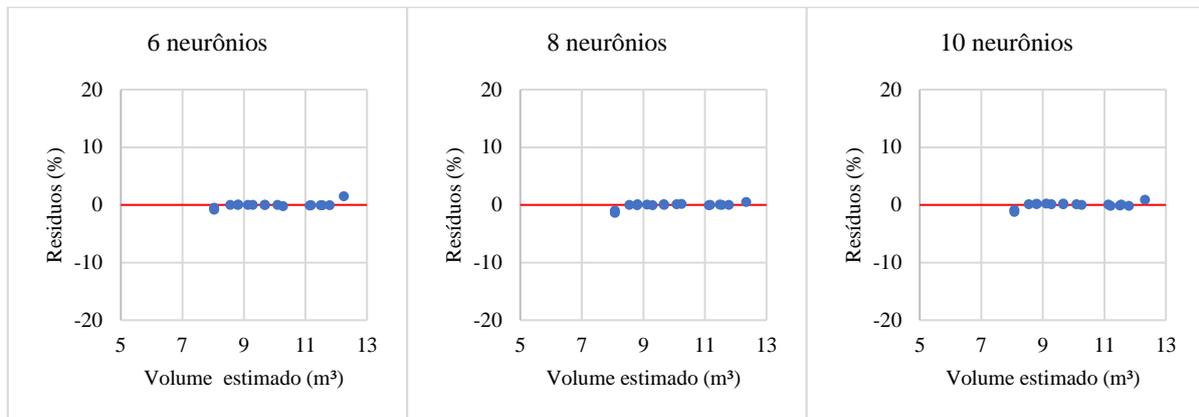
É possível notar nos dados da Tabela 6 que para todas as arquiteturas utilizadas os resultados foram bastante satisfatórios. Destacam-se os valores de correlação encontrados, sendo todos acima de 0,9996. Tais resultados explicam o potencial das redes neurais como ferramenta que possui capacidade de aprender determinada tarefa e obter excelentes resultados. Segundo dados encontrados após treinamento de RNA por Binoti et al. (2013d), os valores de correlação (0,99) também foram bem aproximados aos obtidos neste trabalho.

Os excelentes resultados obtidos nos treinamentos das RNA também refletiram no erro padrão da estimativa (syx). Essa estatística que mede a precisão das estimativas e é amplamente utilizada para comparar estimativas (Miguel et al., 2016; 2017; Leal et al., 2017; Lanssanova et al., 2013; Scolforo, 2005; Draper; Smith, 1998), apresentou todos os valores relativos (syx%) menores que 0,52%. Já as bias repetiram os mesmos comportamentos notados no erro padrão da estimativa, apresentando valores próximos a zero, o que é desejável.

Nas Figuras 4 (NDVI), 5 (MSAVI), 6 (NDRE) e 7 (EVI) podem ser observados os gráficos de dispersão de resíduos

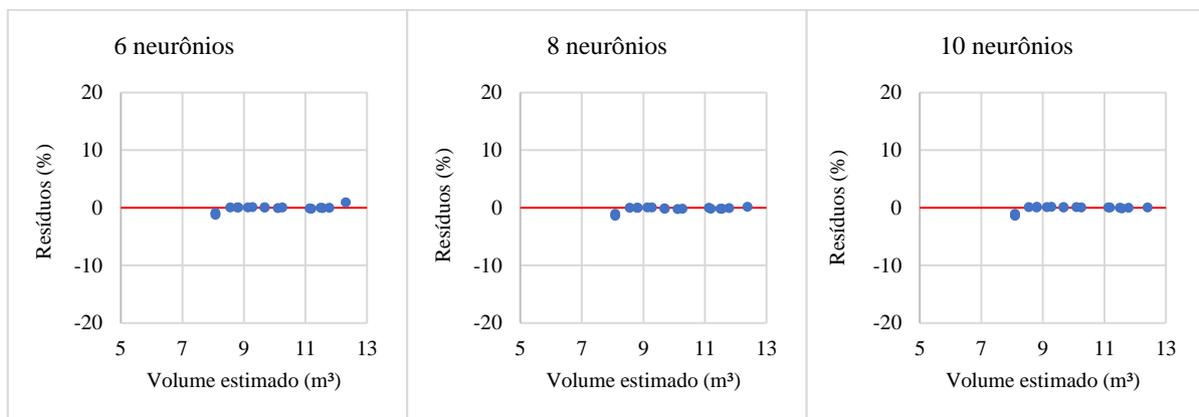
(%) em relação aos valores do volume (m^3) advindo das estimativas, para a etapa de treinamento das redes.

Figura 4 - Gráfico de dispersão de resíduos (%) para três arquiteturas de redes neurais artificiais, utilizando o índice de vegetação NDVI na camada de entrada.



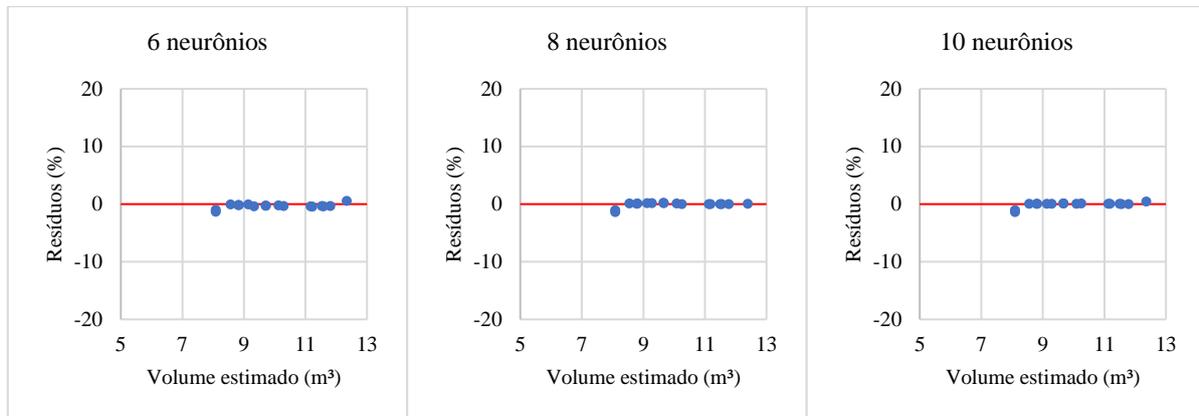
Fonte: Autores (2020).

Figura 5 - Gráfico de dispersão de resíduos (%) para três arquiteturas de redes neurais artificiais, utilizando o índice de vegetação MSAVI na camada de entrada.



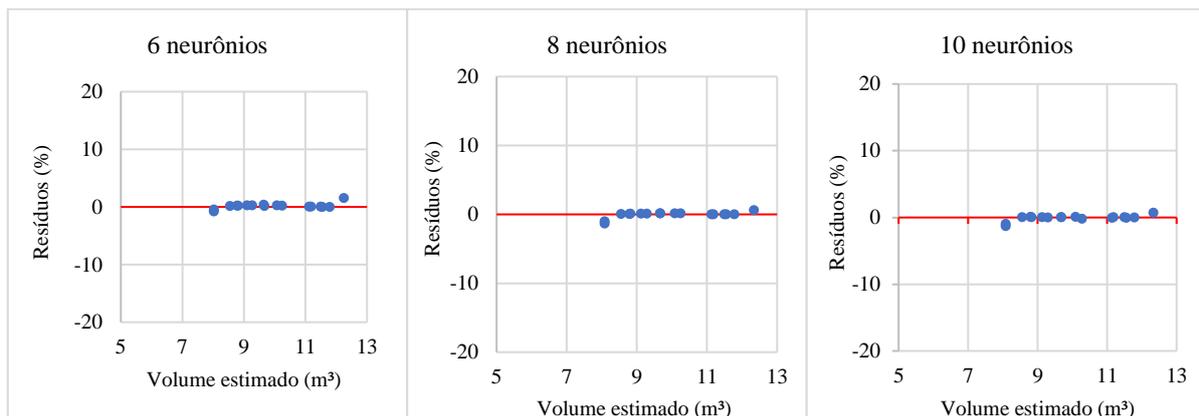
Fonte: Autores (2020).

Figura 6 - Gráfico de dispersão de resíduos (%) para três arquiteturas de redes neurais artificiais, utilizando o índice de vegetação NDRE na camada de entrada.



Fonte: Autores (2020).

Figura 7 - Gráfico de dispersão de resíduos (%) para três arquiteturas de redes neurais artificiais, utilizando o índice de vegetação EVI na camada de entrada.



Fonte: Autores (2020).

O estudo desenvolvido por Miguel et al. (2015), evidenciou a superioridade das redes neurais artificiais em relação a análise de regressão tradicional para estimativa de volume e biomassa em área de cerradão, utilizando dados de sensores remotos. Enquanto a regressão apresentava erro padrão da estimativa entre 9,7% e 11,9% para volume de madeira total e do fuste, respectivamente, as redes neurais artificiais erravam menos e apresentaram 4,9% e 4,8%, respectivamente para volume de madeira total e do fuste. Já em relação a biomassa as diferenças forma maiores. A regressão apresentou valores de s_{yx} (%) de 22,7% e 16,8%, respectivamente biomassa total e biomassa do fuste. Já as redes neurais artificiais apresentaram 8,9% e 7,9%, respectivamente biomassa total e biomassa do fuste.

Outra forma de avaliar o bom desempenho das redes neurais artificiais foi a análise de dispersão de resíduos, preconizada por Draper e Smith (1998). Note nas Figuras 4,5,6 e 7 que toda a dispersão dos resíduos ficou exatamente sobre o eixo zero por cento. Este é o comportamento desejável para os gráficos de dispersão de resíduos, em relação aos valores das estimativas (Castro et al., 2016). Vale ressaltar que todos os índices de vegetação apresentaram excelentes resultados nas estatísticas adotadas como avaliadoras de desempenho e, por isso, na fase de treinamento não foi possível destacar uma arquitetura que se sobressaiu em relação a outra.

Os resultados estatísticos após a validação apresentaram algumas diferenças importantes para algumas arquiteturas e índices de vegetação. Os resultados estatísticos para correlação, erro padrão da estimativa (m^3 e %), bem como para bias (m^3) podem ser visualizados na Tabela 7. Nesta Tabela 7 podem ser avaliadas as correlações obtidas entre os valores observados e as estimativas, além do erro padrão da média (syx em m^3 e %), que mediu o quão os valores observados variaram em relação aos valores estimados, bem como as bias. Cabe ressaltar que a validação das redes treinadas ocorreu em seis parcelas do inventário florestal.

Tabela 7 - Resultados estatísticos obtidos após a validação das diferentes arquiteturas de redes neurais artificiais treinadas neste trabalho.

| Índice | Neurônios | Validação | | | |
|--------|-----------|-----------|---------------|---------|----------------|
| | | <i>r</i> | syx (m^3) | syx (%) | Bias (m^3) |
| NDVI | 6 | 0,8564 | 1,572 | 16,59 | 1,337 |
| | 8 | 0,8681 | 0,859 | 9,06 | 0,026 |
| | 10 | -0,8670 | 1,357 | 14,32 | 0,998 |
| MSAVI | 6 | 0,9909 | 0,020 | 0,21 | 0,002 |
| | 8 | 0,9898 | 0,020 | 0,22 | 0,004 |
| | 10 | 0,9903 | 0,021 | 0,22 | 0,005 |
| NDRE | 6 | 0,9995 | 0,030 | 0,32 | 0,000 |
| | 8 | 0,9998 | 0,022 | 0,23 | 0,005 |
| | 10 | 0,9998 | 0,019 | 0,20 | 0,001 |
| EVI | 6 | -0,8416 | 1,284 | 13,56 | -0,858 |
| | 8 | 0,8608 | 1,346 | 14,21 | -1,040 |
| | 10 | -0,8419 | 1,079 | 11,39 | -0,510 |

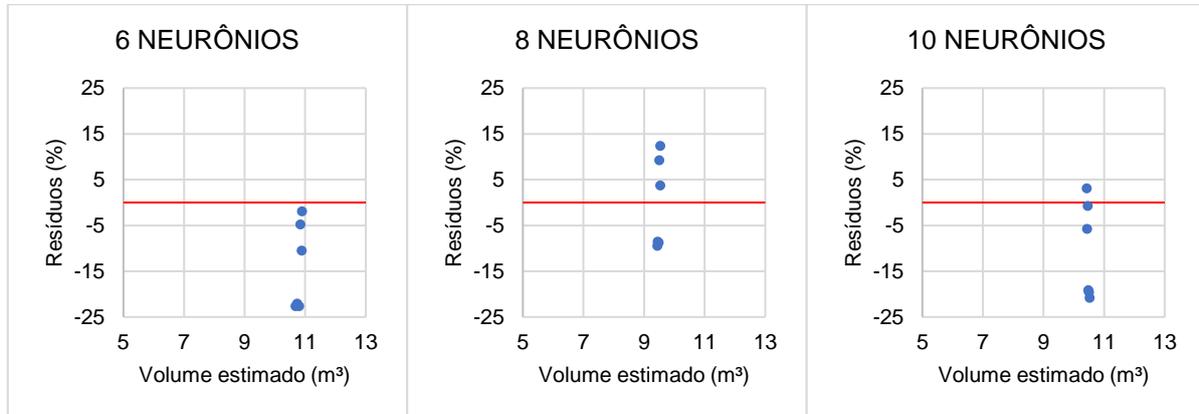
Onde: *r* = correlação entre valores observados e as estimativas; syx (m^3) = erro padrão da estimativa absoluto; syx (%) = erro padrão da estimativa em porcentagem; Bias (m^3) = volume da estimativa menos volume observado. Fonte: Elaborado pelos autores.

Em análise sobre as estatísticas da validação foi possível notar que os resultados apresentaram diferentes valores para correlação, bem como para erro padrão da estimativa (m^3 e %) e bias, conforme pode ser visualizado na Tabela 7. É importante destacar que a validação é o processo mais importante dessa abordagem, pois nesta parte as redes treinadas anteriormente foram aplicadas e testadas numa base de dados totalmente desconhecida. Os bons resultados aqui obtidos credenciam a aplicação de determinada arquitetura de rede, em estimativas de volume por parcela em outras áreas com características equivalentes a essa.

Segundo Miguel et al. (2015), valores obtidos na etapa de validação tendem a apresentar maiores erros, pois o número de parcelas amostrais processadas na validação pela RNA diminui em comparação com treinamento. Neste sentido vale destacar que os índices NDVI e EVI não apresentaram resultados satisfatórios, quando comparados aos índices NDRE e MSAVI (Tabela 7). Os índices NDVI e EVI apresentaram excelentes resultados no treinamento, mas na validação não mantiveram tal desempenho. O EVI, por exemplo, apresentou syx (%) acima dos 11% para todas as arquiteturas e correlação negativa para as arquiteturas com seis e 10 neurônios.

Já os índices NDRE e MSAVI apresentaram, para todas as arquiteturas, estatísticas parecidas com a etapa de treinamento. Com destaque para o erro padrão da estimativa relativo (syx %) abaixo de 0,32% e média de 0,23%. Os resultados para NDRE e MSAVI foram muito acima do esperado e tais desempenhos refletiram nos gráficos de dispersão de resíduos. Nas Figuras 8 (NDVI), 9 (MSAVI), 10 (NDRE) e 11 (EVI) podem ser observados os gráficos de dispersão de resíduos (%) em relação aos valores do volume (m^3) advindo das estimativas, para a etapa de validação das redes.

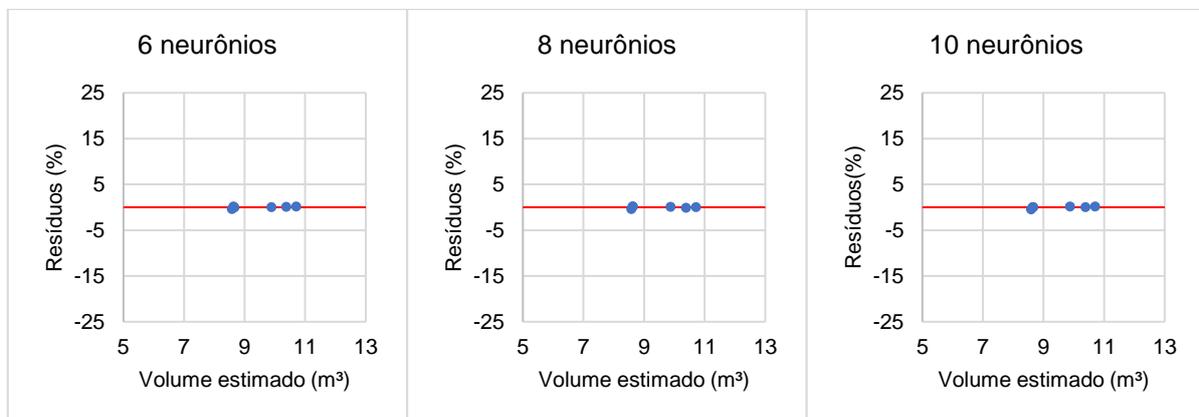
Figura 8 - Gráfico de dispersão de resíduos (%) para a validação, em três arquiteturas de redes neurais artificiais, utilizando o índice de vegetação NDVI na camada de entrada.



Fonte: Autores (2020).

Esse índice foi desenvolvido por Barnes et al. (2000), especialmente para identificar parâmetros correlacionado com as características de diferenciação do estresse das plantas, focando na aproximação da visualização da concentração de clorofila em plantios agrícolas ou áreas de vegetação. Vale ressaltar também o o sensor REIS abordo do satélite RapidEye é um dos poucos que possuem a banda red edge.

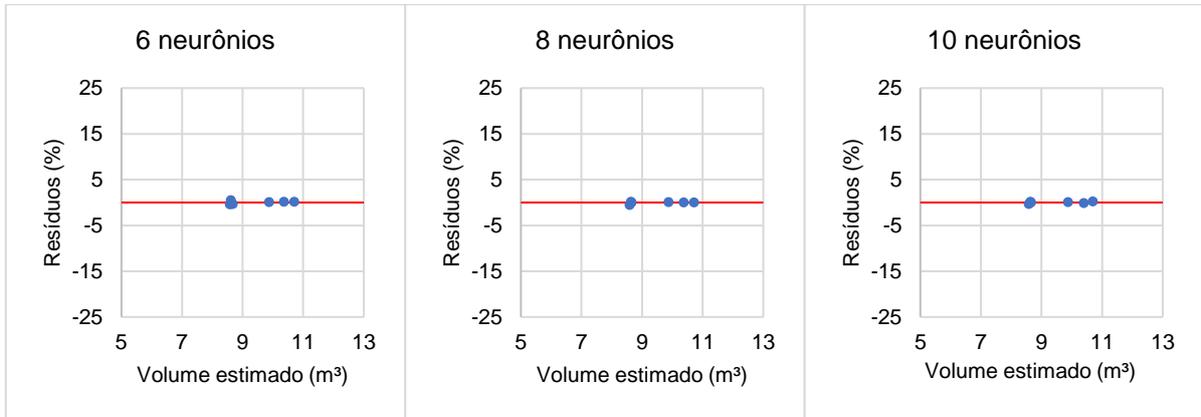
Figura 9 - Gráfico de dispersão de resíduos (%) para a validação, em três arquiteturas de redes neurais artificiais, utilizando o índice de vegetação MSAVI na camada de entrada.



Fonte: Autores (2020).

Comparativamente é possível notar a diferença em relação ao desempenho entre os índices NDVI e MSAVI. Para todas as arquiteturas os resíduos do NDVI foram muito dispersos e não apresentaram variação para o volume da estimativa. Já em relação ao MSAVI a dispersão dos resíduos foi satisfatória em todas as arquiteturas.

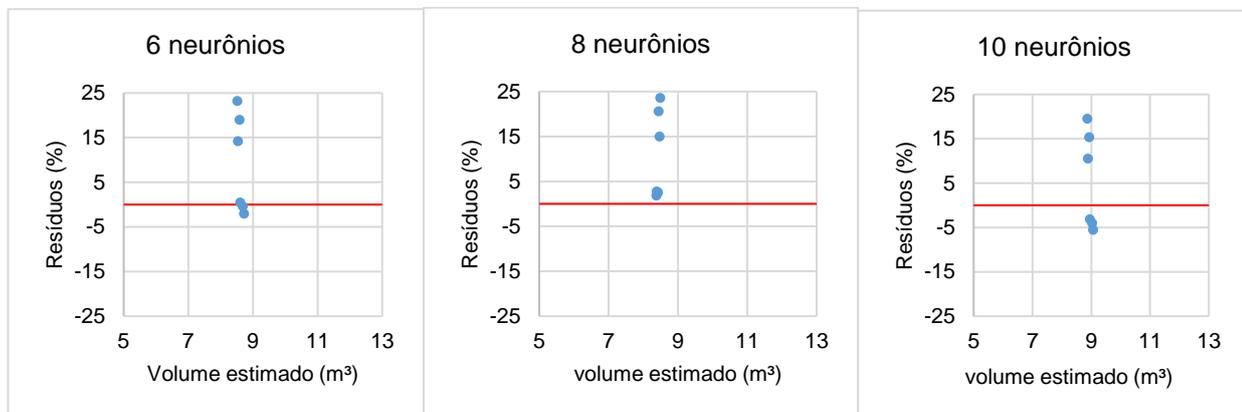
Figura 10 - Gráfico de dispersão de resíduos (%) para a validação, em três arquiteturas de redes neurais artificiais, utilizando o índice de vegetação NDRE na camada de entrada.



Fonte: Autores (2020).

Os valores apresentados pela validação dos dados do índice de vegetação NDRE apresentaram graficamente excelente desempenho e baixo nível de dispersão de resíduos. Tal resultado advém de sua propriedade de captação espectral da diferença normalizada do índice da borda vermelha (red edge).

Figura 11 - Gráfico de dispersão de resíduos (%) para a validação, em três arquiteturas de redes neurais artificiais, utilizando o índice de vegetação EVI na camada de entrada.



Fonte: Autores (2020).

No processo de validação ficou evidenciado que as arquiteturas de redes neurais que possuíam o NDRE e o MSAVI foram superiores aos índices NDVI e EVI. Essa superioridade ficou constatada nos valores de erro padrão da estimativa e gráficos de dispersão de resíduos. Entretanto cabe ainda verificar se houve ou não diferença estatística entre os valores observados e as estimativas. Para incluir uma abordagem mais ampla, essa verificação ocorreu tanto para os resultados do treinamento quanto para a validação.

Após a aplicação do teste de Kruskal e Wallis (1952) foram obtidas as probabilidades estatisticamente significativas e não significativas para cada comparação realizada. Na Tabela 8 podem ser visualizadas as probabilidades encontradas, ao nível de 5% de significância (α). Vale ressaltar que probabilidades superiores a α ($p > 0,05$) não são consideradas diferentes entre si e probabilidades menores que α ($p < 0,05$) são consideradas diferentes estatisticamente.

Tabela 8 - Probabilidades encontradas com o teste proposto por Kruskal-Wallis, utilizado para comparar os volume por parcela observados e as estimativas, por meio de redes neurais artificiais.

| Neurônios | NDVI | | MSAVI | | NDRE | | EVI | |
|-----------|--------|-----------|--------|-----------|--------|-----------|--------|-----------|
| | Treino | Validação | Treino | Validação | Treino | Validação | Treino | Validação |
| 6 | 0,904 | 0,006 | 0,986 | 0,873 | 0,744 | 0,873 | 0,877 | 0,109 |
| 8 | 0,986 | 1,000 | 0,796 | 0,810 | 0,986 | 1,000 | 0,959 | 0,004 |
| 10 | 0,904 | 0,055 | 0,904 | 0,873 | 0,877 | 0,873 | 0,986 | 1,000 |

Hipótese H_0 = os volumes observados e as estimativas são iguais ($p > 0,05$ ou 5%); Hipótese H_1 = os volumes observados e as estimativas não são iguais ($p < 0,05$ ou 5%), conforme preconizam Kruskal e Wallis (1952). Fonte: Elaborado pelos autores.

Conforme Tabela 8, as únicas arquiteturas de redes neurais artificiais que tiveram bons desempenhos tanto no treinamento quanto na validação foram os índices MSAVI e NDRE. Além de não apresentarem diferenças estatísticas, entre os valores observados e as estimativas, apresentaram também excelentes resultados em relação a correlação, erro padrão da estimativa, gráfico de dispersão de resíduos e bias. Portanto, o MSAVI e NDRE foram os únicos que puderam ter seus usos recomendados devido sua estabilidade em todas as etapas.

Já as arquiteturas que continham o NDVI e o EVI, por não apresentarem bons desempenhos, especialmente, no processo de validação, mesmo com algumas arquiteturas não diferindo estatisticamente dos valores observados, não se recomenda a aplicação das redes neurais artificiais aqui treinadas e validadas (NDVI e EVI). Tal instabilidade nos processos aqui testados pode significar em estimativas equivocadas de volume por parcela.

A utilização das redes neurais possibilitou a geração de resultados satisfatório, que ao ser comparado com o método tradicional demonstra viabilidade para geração de dados confiáveis (Bhering et al., 2015), Segundo Souza et al. (2018), as RNA são uma técnica eficiente, geradora de bons resultados e desempenho e que possui ampla aplicação no meio florestal.

4. Conclusão

Em linhas gerais, todas as estimativas realizadas por meio das redes neurais artificiais foram compatíveis ao método tradicional de inventário florestal. Obviamente algumas arquiteturas se destacaram melhor em relação à outras. Foi verificado que algumas arquiteturas de redes neurais artificiais influenciaram nas estimativas do volume por parcela, especialmente as arquiteturas que tinham como variável de entrada o índice NDRE e MSAVI. Mas, nesses índices não foram verificadas diferenças quando utilizados números diferentes de neurônios na camada oculta.

Na etapa de treinamento todas as arquiteturas não diferiram estatisticamente dos volumes observados em campo. Contudo, na etapa de validação, onde se requer maior estabilidade dos resultados para aplicar de fato o que foi produzido, algumas arquiteturas não foram estáveis, com destaque para os índices NDVI e EVI. Já as arquiteturas com os índices NDRE e MSAVI foram bastante estáveis e tiveram suas aplicações recomendadas para as estimativas de volume por parcela.

Agradecimentos

Agradeço a CNPQ, aos meus orientadores, a Professor Dr. Fabricio leal e Prof. Gloria, e a COMIGO pela disponibilidade dos dados de inventario e estudos em sua área.

Referências

- Almeida, A. Q. D., Mello, A. A. D., Neto, A. L. D., & Ferraz, R. C. (2014). Relações empíricas entre características dendrométricas da Caatinga brasileira e dados TM Landsat 5. *Pesquisa Agropecuária Brasileira*, 49, 306-315.
- Barnes, E. M., Clarke, T. R., Richards, S. E., Colaizzi, P. D., Haberland, J., Kostrzewski, M., ... & Moran, M. S. (2000, July). Coincident detection of crop water stress, nitrogen status and canopy density using ground based multispectral data. *In Proceedings of the fifth international conference on precision agriculture*, Bloomington, MN, USA (Vol. 1619, p. 6).
- Bhering, L. L., Cruz, C. D., Peixoto, L. D. A., Rosado, A. M., Laviola, B. G., & Nascimento, M. (2015). Application of neural networks to predict volume in eucalyptus. *Crop Breeding and Applied Biotechnology*, 15, 125-131.
- Binoti, D. H. B., Binoti, M. L. M. D. S., Leite, H. G., Silva, A. A. L. D., & Albuquerque, A. C. (2013c). Modelagem da distribuição de diâmetros utilizando autômatos celulares e redes neurais artificiais. *Cerne*, 19, 677-685.
- Binoti, D. H., Binoti, M. L. D. S., Leite, H. G., & Silva, A. (2013a). Redução dos custos em inventário de povoamentos equiâneos. *Revista Brasileira de Ciências Agrárias*, 8(1), 125-129.
- Binoti, D. H. B., Binoti, M. L. M. S., & Leite, H. G. (2013a). NeuroForest Star. Patente: Programa de Computador. Número do registro: 13410-5, data de registro: 30/04/2013, título: "NeuroForest Star", *Instituição de registro: INPI - Instituto Nacional da Propriedade Industrial*.
- Binoti, M. L. M. D. S. (2010). Redes neurais artificiais para prognose da produção de povoamentos não desbastados de eucalipto.
- Binoti, M. L. M. D. S. (2012). Emprego de redes neurais artificiais em mensuração e manejo florestal. *Tese (doutorado) Universidade Federal de Viçosa*, Viçosa – MG.
- Binoti, M. L. M. D. S., Binoti, D. H. B., & Leite, H. G. (2013d). Aplicação de redes neurais artificiais para estimação da altura de povoamentos equiâneos de eucalipto. *Revista Árvore*, 37, 639-645.
- Binoti, M. L. M. D. S., Binoti, D. H. B., Leite, H. G., Garcia, S. L. R., Ferreira, M. Z., Rode, R., & Silva, A. A. L. D. (2014). Redes neurais artificiais para estimação do volume de árvores. *Revista Árvore*, 38, 283-288.
- Binoti, M. L. M. D. S., Leite, H. G., Binoti, D. H. B., & Gleriani, J. M. (2015). Prognose em nível de povoamento de clones de eucalipto empregando redes neurais artificiais. *Cerne*, 21, 97-105.
- Campos, J. C. C., & Leite, H. G. (2009). Mensuração florestal: perguntas e respostas. rev. e ampl. Viçosa, MG: Universidade Federal de Viçosa, 548p.
- Castro, R. V. O., Araújo, R. A. A., Leite, H. G., Castro, A. F. N. M., Silva, A., Pereira, R. S., & Leal, F. A. (2016). Modelagem do crescimento e da produção de povoamentos de eucalyptus em nível de distribuição diamétrica utilizando índice de local. *Revista Árvore*, 40, 107-116.
- Chander, G., Markham, B. L., & Helder, D. L. (2009). Summary of current radiometric calibration coefficients for Landsat MSS, TM, ETM+, and EO-1 ALI sensors. *Remote sensing of environment*, 113(5), 893-903.
- Chaves, R. D. A., Reis, M. D. G. F., Reis, G. G. D., Pezzopane, J. E. M., Xavier, A., & Monte, M. A. (2007). Dinâmica de cobertura de dossel de povoamento de clone de *Eucalyptus grandis* w. hill ex-maiden submetidos a desrama artificial a desbaste. *Revista Árvore*, 31, 989-998.
- Chen, W. C., Tseng, L. Y., & Wu, C. S. (2014). A unified evolutionary training scheme for single and ensemble of feedforward neural network. *Neurocomputing*, 143, 347-361.
- Colbert, K. C., Larsen, D. R., & Lootens, J. R. (2002). Height-diameter equations for thirteen midwestern bottomland hardwood species. *Northern Journal of Applied Forestry*, 19(4), 171-176.
- Costa, A. C. D., Pinto, J. R. R., Miguel, E. P., Xavier, G. D. O., Marimon, B. H., & Aparecido Trondoli Matricardi, E. (2023). Artificial intelligence tools and vegetation indices combined to estimate aboveground biomass in tropical forests. *Journal of Applied Remote Sensing*, 17(2), 024512-024512.
- Costa, O. B. D. (2017). Degradação Florestal por extração seletiva e fogo na Amazônia Legal. Tese de Doutorado em Ciências Florestais, Publicação PPGEFL.TD - 074/2017. *Departamento de Engenharia Florestal*, Universidade de Brasília, Brasília, DF, 2017.
- Draper, N., & Smith, H. (1998). Applied regression analysis. *John Wiley e Sons*. (3a ed.).
- Ferreira, C. A., Mello, H. A., & Kajiya, S. (1977). Estimativa do volume de madeira aproveitável para celulose em povoamentos de *Eucalyptus* spp.: determinação de equações para o cálculo do volume de povoamentos de *Eucalyptus* spp. IPEF, Piracicaba, 14, 29-50.
- Haykin, S. (2001). Redes neurais: princípios e prática. (2a ed.), Bookman.
- Instituto Brasileiro de Geografia e Estatística – IBGE. (2014). Manual técnico da vegetação brasileira. (2a ed.).
- Kruskal, W. H., & Wallis, W. A. (1952). Use of ranks in one-criterion variance analysis. *Journal of the American Statistical Association*, 47(260), 583-621.
- Kuan, C. M., & White, H. (1994). Artificial neural networks: An econometric perspective. *Econometric Reviews*, 13, 1-91.
- Leal, F. A., Miguel, E. P., & Matricardi, E. A. T. (2016). Estimativa do volume em um povoamento de eucalipto utilizando redes neurais artificiais e dados provenientes de satélite RapidEye. *III MENSU FLOR*, Piracicaba, SP.

- Leal, F. A. (2013). Técnicas de sensoriamento remoto e geoestatística aplicadas em um povoamento de *Eucalyptus urophylla* S.T. Blake para estimativa de volume. Dissertação de mestrado em Ciências Florestais. *Publicação PPGEFL.DM-190/2013*. Departamento de Engenharia Florestal, Universidade de Brasília - UnB, Brasília/DF.
- Leal, F. A., Castro, R. V. O., & Matricardi, E. A. T. (2017). Validação de modelos de afilamento para estimativa do diâmetro, altura e volume em povoamento comercial de eucalipto. *Revista Brasileira de Biometria*, 35(3), 449-460.
- Leal, F. A., Miguel, E. P., & Matricardi, E. A. T. (2016). Estimativa do volume em um povoamento de eucalipto utilizando redes neurais artificiais e dados provenientes de satélite RapidEye. *III MENSU FLOR*, Piracicaba, SP.
- Leal, F. A., Miguel, E. P., Matricardi, E. A. T., & Pereira, R. S. (2015). Artificial neural networks in volume estimation at eucalyptus plantation using hemispherical photographs and number of trees. *Revista Brasileira de Biometria*, 33(2), 234-250.
- Leite, H. G., Neto, R. R. de O., Monte, M. A., Fardin, L., Alcantra, A. M., Binoti, M. L. M. da S., & Castro, R. V. O. (2011). Modelo de afilamento de cerne de *Tectona grandis* Lf (Taper models of heartwood of *Tectona grandis* Lf). *Scientia forestalis*, Piracicaba, 39(89), 053-059.
- Machado, S. A., & Figueiredo Filho, A. (2009). *Dendrometria*, 2ª edição. Guarapuava: UNICENTRO.
- Pélico Neto, S., & Brena, A. D. (1997). *Inventário Florestal*. Curitiba: Editorado pelos autores.
- Riedmiller, M., & Braun, H. (1993). A direct adaptive method for faster backpropagation learning: the RPORP algorithm. In: IEEE International Conference On Neural Networks, 1993. *Proceedings (pp. 586-591)*. IEEE.
- Rodrigues, T. W. P., Guimarães, U. S., Rotta, L. H. D. S., Watanabe, F. S. Y., Alcântara, E., & Imai, N. N. (2016). Delineamento amostral em reservatórios utilizando imagens Landsat-8/OLI: um estudo de caso no reservatório de Nova Avanhandava (Estado de São Paulo, Brasil). *Boletim de Ciências Geodésicas*, 22, 303-323.
- Weng, L., Kang, Y., Jiang, K. & Chen, C. (2022). Redes Neurais Convolucionais Time Gated para Classificação de Culturas. Pré-impressão do arXiv arXiv:2206.09756.