



Diferentes configurações de redes neurais artificiais para estimativa de volume em florestas naturais no estado do Amapá

Ingrid Rezende de Oliveira¹, Anthoinny Vitória dos Santos Silva², Bruno Costa Santos³, Beatriz Costa Monteiro⁴, Rafael Lucas Figueiredo de Souza⁵, Jadson Coelho de Abreu⁶

Resumo

O volume é uma variável de extrema importância no manejo florestal, sua quantificação é importante para o planejamento e exploração sustentável. E por meio das ferramentas da inteligência artificial, como as redes neurais artificiais (RNAs), se pode efetuar a quantificação do estoque volumétrico de uma floresta de maneira mais precisa. Com isso, o objetivo do presente trabalho foi avaliar qual algoritmo de aprendizado apresenta melhor desempenho e o número ótimo de neurônios nas camadas intermediárias para estimar volume na Floresta Estadual do Amapá. Os dados foram separados em 70% para o treino e 30% para a validação, avaliou-se 2000 RNAs do tipo Multilayer Perceptron, empregando-se os algoritmos de treinamento *Backpropagation* e *Simulated Annealing*, respectivamente. Utilizou-se como variáveis de entrada (*inputs*) o diâmetro à altura do peito (DAP) e a altura do fuste (H), e como neurônio na camada de saída (*outputs*) o volume. Os critérios estatísticos empregados para seleção da melhor RNA foram: correlação (r^2), raiz quadrada do erro quadrático médio (RQEM) e análise gráfica dos resíduos. Os dados foram processados no software Neuro 4.0 e Excel. Para o *Backpropagation* para os dados de treinamento a melhor configuração foi com dez neurônios na camada intermediária e para validação com seis neurônios. A melhor configuração para o *Simulated Annealing*, foi com oito neurônios na camada intermediária tanto para treino quanto para validação. Sendo assim, a RNA que obteve a configuração mais eficiente para estimativa de volume, foi o *Simulated Annealing* oito neurônios na camada intermediária.

Palavras-chave: Inteligência artificial; algoritmos; floresta nativa.

Different configurations of artificial neural networks for volume estimation in natural forests in the state of Amapá. Volume is an extremely important variable in forest management, its quantification is important for planning and sustainable exploitation. Quantification of volumetric stock of a forest can be performed more accurately by means of the tools of artificial intelligence, such as artificial neural networks (ANN). With this, the objective of the present work was to evaluate which learning

¹ Engenheira Florestal, UEAP, Macapá, AP rezendeingrid12@gmail.com

² Graduanda Engenharia Florestal, UEAP, Macapá, AP vittoria.sntsilva@gmail.com

³ Engenheiro Florestal, UEPA, Macapá, AP brunosantos114@outlook.com

⁴ Engenheira Florestal, UEPA, Macapá, AP beatrizcostamonteiro@outlook.com

⁵ Engenheiro Florestal UEAP, mestrando em Engenharia Florestal, UFLA, Lavras, MG rafaelflorestal55@gmail.com

⁶ Docente UEAP, UFV, Viçosa, MG jadson.abreu@ueap.edu.br



algorithm has the best performance and the optimal number of neurons in the intermediate layers to estimate volume in the State Forest of Amapá. The data was separated by 70% for training and 30% for validation, 2000 Multilayer Perceptron ANNs were evaluated, using the Backpropagation and Simulated Annealing training algorithms, respectively. The diameter at breast height (DBH) and the bole height (H) were used as input variables and the volume as the neuron in the output layer. The statistical criteria used to select the best ANN were correlation ($r_{\hat{y}}$), square root-mean-square error (RMSE) and graphical analysis of the residues. Data was processed using Neuro 4.0 and Excel software. For Backpropagation with training data, the best configuration contains ten neurons in the middle layer and for validation with six neurons. The best configuration for Simulated Annealing is the one with eight neurons in the middle layer for both training and validation. With these results, the ANN that obtained the most efficient configuration for volume estimation, was the Simulated Annealing with eight neurons in the hidden layer

Keywords: Artificial intelligence; algorithms; Native Forest.

1. Introdução

A quantificação da variável volume é de extrema importância para o manejo florestal, sendo relevante no planejamento e exploração sustentável. O estoque volumétrico de uma floresta pode ser quantificado através de modelos volumétricos, com a cubagem de indivíduos através da medição de diâmetro à altura do peito e altura de amostras representativas da população (ANATAZIO *et al.*, 2020).

Em geral, essa quantificação ocorre de maneira não destrutiva, ou seja, fazendo a estimativa volumétrica com a aplicação dos modelos de regressão e o fator de forma (SILVA; SANTANA, 2014; NAZARENO, 2019). Porém, as técnicas de estimativas do volume cresceram progressivamente com os avanços tecnológicos (LOPES *et al.*, 2020), permitindo a aplicação da inteligência artificial, que é proveniente da ciência da computação, e permite por meio de um aprendizado induzido modelos com maiores precisões (MICHELL, 1997; BRUNIALTI *et al.*, 2015).

E uma dessas ferramentas são as denominadas Redes Neurais Artificiais (RNAs), que são programações computacionais que se baseiam nos neurônios do cérebro humano, através

das conexões sinápticas, para o aprendizado (CAMPOS *et al.*, 2016). As estimativas de variáveis em análise passam por uma sequência de camadas, denominadas: camada de entrada, oculta e de saída (PEREIRA; CENTENO, 2017). As quais estão organizadas e diretamente conectadas, assim como estão os dendritos e axônios biológicos.

As RNAs necessitam de técnicas de aprendizado para sua solução, realizadas através dos métodos heurísticos. Como os algoritmos de treinamento *Backpropagation* e *Simulated Annealing*. O algoritmo *Backpropagation*, conhecido como "retropropagação do erro", como o nome diz, é baseado na regra de aprendizado de correção do erro, ou minimização deste, em que seu treinamento envolve após os cálculos, o ajuste dos pesos (RODRÍGUEZ, 2017; HIDALGO-CAJO *et al.*, 2020).

O *Simulated Annealing* baseia-se na ideia da termodinâmica, de desprendimento e resfriamento dos átomos, que analogamente inicia com uma grande taxa de variação, tendo por consequência uma grande variedade de soluções. Ou seja, o algoritmo apresenta meios de escapar



de ótimos locais por permitir movimentos de escalada para encontrar um ótimo global (ZHAN *et al.*, 2016).

Segundo Bezerra (2016) para se obter um bom resultado é necessário levar em consideração parâmetros dentro dos algoritmos de treinamento, como a função de ativação, a quantidade de camadas ocultas, o número de redes, taxas de aprendizado e outras características, ressaltando a importância dos testes para se atingir os objetivos propostos.

Sendo assim, partindo do princípio que as redes neurais artificiais apresentam modelos com maiores acurácias na estimativa do volume e que suas diferentes configurações podem alterar o seu desempenho. O objetivo do presente estudo foi testar as diferentes configurações que as RNAs possuem para estimar volume de uma floresta na nativa no estado do Amapá.

2.1 Área de Estudo

O estudo foi desenvolvido na Floresta Estadual do Amapá (FLOTA), uma unidade de conservação sustentável, localizada na região central do Amapá, Amazônia, Brasil (01°15'52,01"N; 51°24'05,18"O). Os dados para esta pesquisa foram obtidos a partir do inventário florestal do módulo IV de produção, pelo Instituto Estadual de Florestas (IEF, 2018).

De acordo com o Plano de Manejo da Floresta Estadual do Amapá (2014), a área possui, segundo a classificação de Köppen, clima do tipo Am, com chuva média superior a 1.500 mm/mês e mínima de 60 mm nos meses mais secos, propriedades de um clima tropical úmido ou subúmido.

A Unidade de Conservação possui 2,3 milhões de hectares, fazendo parte do grande corredor da biodiversidade, abrangendo cerca de dez municípios do estado: Mazagão, Porto Grande, Pedra

Branca do Amaparí, Serra do Navio, Ferreira Gomes, Tartarugalzinho, Pracuúba, Amapá, Calçoene e Oiapoque (IEF, 2018).

O Módulo IV da FLOTA tem como predominância, três tipos de vegetação, a Floresta de Terra Firme de Baixo Platô (FTFBP), a Floresta de Terra Firme Densa Submontana (FTFDS) e Transição Cerrado-Floresta (TCF) (LIMA *et al.*, 2014).

2.2 Base de dados

O inventário de árvores vivas e caídas foi iniciado em 2008 se adotando o processo de amostragem estratificada em conglomerados. Foram utilizadas 30 unidades de amostra (conglomerados) distribuídas aleatoriamente nos três tipos de floresta descritos anteriormente.

O número de unidades de amostra é proporcional à área de cada tipo de floresta: 23, 4 e 3 em FTFBP, FTFDSm, TCF, respectivamente. Cada unidade de amostra consiste em 5 unidades secundárias compostas de 4 faixas de 20 x 200 m (unidades terciárias) formando uma cruz alinhada nas quatro direções cardinais.

Nas unidades terciárias, um total de 1264 árvores com valor econômico, com diâmetro à altura do peito (DAP, 1,30 m) \geq 10 cm foram medidas. O volume do fuste foi obtido adotando-se a metodologia combinada de Smalian e Hohenadl. Onde o comprimento da base do tronco para o ramo mais baixo foi dividido em 10 seções de igual comprimento (LIMA *et al.*, 2014). A circunferência central de cada seção foi medida e, posteriormente, convertida em diâmetro.

4.3 Treinamento das redes neurais artificiais

Foram avaliadas de forma supervisionada 2000 redes neurais do tipo *Multilayer Perceptron* (Multicamadas), empregando-se os algoritmos de

treinamento *Backpropagation* e *Simulated Annealing*, respectivamente. Das 1107 árvores mensuradas cerca de 70% foram utilizados para o treino e 30% para a validação dos resultados.

Utilizou-se como variáveis de entrada (*inputs*) o diâmetro à altura do peito (DAP) e a altura do fuste (H) e como neurônio na camada de saída o volume (*outputs*). Foram abordadas diferentes configurações de RNA em que para cada algoritmo houve o treinamento das configurações com número de neurônios na camada intermediária variando de 1 a 10.

Os critérios de parada de treinamento adotados para os algoritmos de Redes Neurais Artificiais foram: erro quadrático médio (0,001) e o número de ciclos (1000). A função de

ativação utilizada foi do tipo sigmoide, tanto na camada oculta, quanto na camada de saída, que apresenta um balanço entre comportamentos lineares e não-lineares.

O *Simulated Annealing* tem como base a alternância de temperaturas, portanto, foi utilizado o valor de 10° para a temperatura inicial e 2° para a temperatura final e o número de ciclos 500, no algoritmo. Também como critério de parada foi utilizado um total de 20 convergências. O algoritmo *Backpropagation* foi executado com Taxa de Aprendizado de 0,01 e *Momentum* de 0,005 que se trata de uma constante que leva em consideração os pesos anteriores, para a mudança do peso atual.

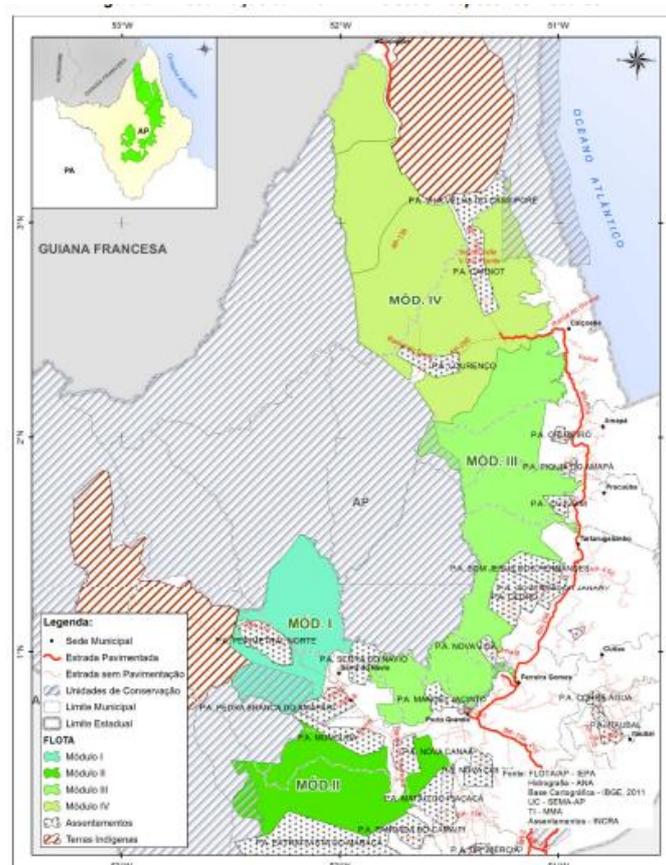


Figura 1. Localização da Floresta Estadual do Amapá. Fonte: IEF, 2014.



4.4 Seleção da melhor topologia de RNA

Para possibilitar a comparação entre as diversas topologias de redes neurais artificiais (RNA), foi utilizado os seguintes critérios de avaliação: coeficiente de correlação ($r_{y\hat{y}}$) entre os volumes observados e estimados, raiz quadrada do erro quadrático médio (RQME%) e análise gráfica dos resíduos (SILVA *et al.* 2009; BINOTI, 2010). Todo o processamento e análise dos dados foram feitos no Microsoft Excel ® e no NeuroForest 4.0 (NEUROFOREST, 2018).

2. Resultados e Discussão

Foram treinadas de maneira supervisionada 100 redes neurais para cada algoritmo, variando a camada oculta de 1 a 10 neurônios, para o *Simulated Annealing* e *Backpropagation*. O número de neurônios na camada oculta é responsável, principalmente, pela extração de características de não linearidade dos dados, neste caso, um número superior a quatro neurônios é necessário para a extração da relação entre as variáveis consideradas de entrada e as de saída (LEITE *et al.*, 2016).

Recomenda-se que, nas aplicações de RNA, sejam escolhidas configurações mais simples, com o menor número de neurônios possível na camada oculta, a fim de evitar o *overfitting* e facilitar o processo de busca e otimização da configuração para uma determinada tarefa (BULLINARIA, 2018).

Portanto, deve-se priorizar a escolha da estimativa com configurações com menor número de neurônios na camada oculta para evitar a memorização dos dados treinados, comprometendo a capacidade de generalização (BRAGA *et al.*, 2000; SILVA *et al.*, 2010).

Neste sentido, foram treinadas 100 redes neurais, usando como arquitetura, neurônios de 1 a 10 na camada oculta, visando a extração dessas características e observando o seu comportamento com números inferiores de neurônios na camada oculta, evitando o *overfitting*.

Tratando-se da função de ativação utilizada, neste caso a sigmoide, a apresentação de resultados satisfatórios em relação à estimativa de volume, para a camada oculta e a de saída.

A tabela 1 apresenta os resultados dos indicadores utilizados para identificação da RNA que apresentou melhor acurácia para os dados de treino e validação, para a RNA do algoritmo de treinamento o *Simulated*

A mensuração da qualidade do ajuste de treinamento das RNAs ao longo do tamanho da amostra, utilizado para seu ajuste, foi realizada por meio de dois indicadores o de correlação (R) e diferença quadrática média (RQME), identificando a que apresenta resultados mais precisos, mesmo que não ocorra grande variação entre elas.

A correlação entre os valores observados e estimados pelos 10 tipos de neurônios utilizando o algoritmo de treinamento *Simulated Annealing*, variou entre 0,9732 e 0,9787, o RQME entre 0,3887 e 0,4206 para os dados de treino. Na análise dos dados de validação a correlação variou entre 0,9538 e 0,9615, e para a RQME esta variação foi de 0,5347 a 0,5998.

Observa-se na tabela 1, que as estatísticas apresentadas pelas RNAs treinadas geraram resultados com alto grau de correlação e com valores satisfatórios para a avaliação da diferença quadrática média o que evidência um bom ajuste das RNAs para essa base de dados.

Tabela 1. Treino e Validação do Algoritmo *Simulated Annealing*

| | TREINO | | VALIDAÇÃO | | |
|---------------------|-----------|--------|-----------|--------|--------|
| | NEURÔNIOS | R | RQME | R | RQME |
| SIMULATED ANNEALING | 1 | 0,9743 | 0,4164 | 0,9538 | 0,5998 |
| | 2 | 0,975 | 0,413 | 0,9584 | 0,5584 |
| | 3 | 0,977 | 0,4025 | 0,9586 | 0,5532 |
| | 4 | 0,9783 | 0,3918 | 0,9614 | 0,5388 |
| | 5 | 0,9784 | 0,3892 | 0,9611 | 0,5392 |
| | 6 | 0,9786 | 0,3886 | 0,961 | 0,5351 |
| | 7 | 0,9785 | 0,3896 | 0,9613 | 0,5378 |
| | 8 | 0,9787 | 0,3887 | 0,9615 | 0,5347 |
| | 9 | 0,9732 | 0,4206 | 0,9611 | 0,5364 |
| | 10 | 0,9736 | 0,4184 | 0,9614 | 0,5439 |

Para os dados de treino e validação, nota-se que a quantidade de neurônios utilizados não influenciou na qualidade do resultado final dos indicadores, apresentando um padrão estatístico em seus resultados.

Analisando os dados de treino, a RNA treinada com 8 neurônios em sua camada oculta, foi a que apresentou maior exatidão em suas estimativas com um valor de 0,9787 para em sua correlação entre as variáveis e um erro quadrático de 0,3887, indicando que está RNA possui uma boa capacidade de generalização.

O mesmo padrão foi mantido quando se utiliza os dados de validação, sendo a RNA treinada com 8 neurônios a que apresenta os melhores indicadores estatísticos, sendo de 0,9615 para correlação e de 0,5347 (31%) para o seu erro quadrático.

Percebe-se que na validação ocorreu uma perda em exatidão das estimativas, ou seja, quando o treinamento foi realizado com uma base de dados menor a RNA não foi capaz de generalizar de forma tão eficiente como para os dados de treino.

Vale ressaltar que nenhuma RNA treinada apresentou resultados discrepantes em seus indicadores

estatísticos, sendo confiável a sua utilização para a estimativa de volume, utilizando RNA do tipo Multilayer Perceptron, sendo o algoritmo de treinamento o *Simulated Annealing*.

A tabela 2 apresenta os resultados dos indicadores utilizados para identificação da RNA que apresentou melhor acurácia para os dados de treino e validação, para a RNA do tipo Multilayer Perceptron, sendo o algoritmo de treinamento o *backpropagation*.

A correlação entre os valores observados e estimados pelas 10 redes utilizando o algoritmo de treinamento *Backpropagation*, variou entre 0,9736 e 0,9507, e o RQME entre 0,4184 e 0,539 para os dados de treino. Na análise dos dados de validação a correlação variou entre 0,9538 e 0,9505, e para a RQME está variância foi de 0,5745 a 0,6425.

Observa-se na tabela 2, que a RNA que apresentou melhor desempenho foi a que utilizou 10 neurônios em sua camada oculta atingindo valores de 0,9736 de correlação, apresentando resultados satisfatórios, no entanto com um pequeno grau de inferioridade em relação ao treinamento utilizando *Simulated Annealing*.

Tabela 2. Treino e Validação do Algoritmo *Backpropagation*.

| | TREINO | | | VALIDAÇÃO | |
|-----------------|-----------|--------|--------|-----------|--------|
| | NEURÔNIOS | R | RQME | R | RQME |
| BACKPROPAGATION | 1 | 0,9507 | 0,539 | 0,9508 | 0,5745 |
| | 2 | 0,9667 | 0,4525 | 0,9505 | 0,6425 |
| | 3 | 0,9712 | 0,4298 | 0,9525 | 0,6261 |
| | 4 | 0,9709 | 0,4317 | 0,9524 | 0,627 |
| | 5 | 0,9713 | 0,4285 | 0,9529 | 0,6238 |
| | 6 | 0,9716 | 0,426 | 0,9538 | 0,616 |
| | 7 | 0,9725 | 0,4226 | 0,9536 | 0,6162 |
| | 8 | 0,9724 | 0,4252 | 0,9528 | 0,6228 |
| | 9 | 0,9732 | 0,4206 | 0,9534 | 0,6174 |
| | 10 | 0,9736 | 0,4184 | 0,9537 | 0,6133 |

Quando se analisa o erro quadrático, percebe-se que houve queda na exatidão deste indicador, sendo que para todas as RNAs treinadas, apresentou-se valores inferiores aos obtidos quando se utilizou o *Simulated Annealing*, sendo que a RNA que apresentou o menor erro foi a com 10 neurônios em sua camada com um valor de 0,4184.

Observa-se na tabela 2, que as estatísticas apresentadas pelas RNAs utilizando os dados de treino geraram resultados com um bom grau de correlação, destoando das demais as RNAs treinadas com 1 e 2 neurônios. No entanto, constata-se um aumento considerável em seu erro quadrático, para todas as 10 RNAs treinadas, ou seja, queda em sua exatidão, apresentando o menor erro para a RNA com 10 neurônios em sua camada com um valor de 0,4184, bem inferior ao encontrado utilizando-se o *Simulated Annealing*.

Ao fazer a análise das estatísticas apresentadas para os dados de validação, tem-se a RNA com 6 neurônios, a que apresenta melhor desempenho entre as 10 utilizadas. Seu grau de correlação foi abaixo do encontrado para os dados de treino, sendo de 0,9538 e seu erro quadrático

aumentou, passando a ser de 0,616, no entanto uma boa configuração de RNA é aquela que apresenta boa capacidade de generalização.

O erro quadrático apresentado pela RNA de 6 neurônios, não foi o menor, porém ao fazer a análise conjunta de erro e correlação a mesma apresenta o melhor desempenho. Sendo a RNA com 1 neurônio em sua camada a que atingiu um menor grau em seu erro, sendo este de 0,5745 (35%).

Igualmente o ocorrido na RNA utilizando o algoritmo de treinamento *Simulated Annealing*, ao realizar o treinamento com os dados de validação, detecta-se a queda na precisão dos indicadores estatísticos de algumas configurações de RNA. Para o indicador de correlação, atingiu-se um grau de 0,9538 e para o erro quadrático um valor de 0,616, um erro alto, não satisfatório.

Está queda em exatidão para os dois algoritmos de treinamentos utilizados, pode ser explicada pela ocorrência de outliers ou pelo fato da não inserção de variáveis categóricas, como solo ou temperatura.

Analisando os resultados obtidos através dos indicadores, para as RNAs treinadas utilizando o algoritmo



Simulated Annealing e o *Backpropagation*, o mais indicado pra a estimativa de volume é o *Simulated Annealing*, visto que apresenta estatísticas mais precisas do que as alcançadas pela *Backpropagation*.

Na Figura 1, apresentam-se os gráficos de análise de resíduos para as RNAs treinadas utilizando o *Simulated Annealing*, para os dados de treino.

A RNA com 8 neurônios em sua camada, selecionada como a que apresentou o melhor desempenho dentre as 10 analisadas, mostrou uma leve superestimação para os seus menores valores de volume, e tendo seus pontos distribuído de uma forma homogênea ao longo da reta, comprovando seu bom desempenho nos indicadores.

Desempenhos semelhantes nos gráficos de resíduos foram encontrados para as RNAs treinadas com 3, 4, 5, 6, 7, 9 e 10 neurônios, com um pequeno grau de superestimação para os menores valores de volume, sendo que no decorrer da reta, os pontos se aproximam e distribuem-se de forma mais homogênea, indicado que não ocorre tendenciosidade nas estimativas, o mesmo vale para a RNA com 8 neurônios. As RNAs treinadas com um menor número de neurônios em sua camada, sendo as de 1 e 2, destoaram das demais analisadas.

O grau de superestimação para essas RNAs, nas primeiras classes volumétricas foram elevados, discrepantes, comprometendo a generalização destas RNAs treinadas, assim influenciando na distribuição de seus resíduos.

Destaca-se que mesmo as RNAs que obtiveram resultados inferiores nos

seus indicadores em comparação com a melhor RNA treinada, os seus desempenhos ao ser feita a análise dos gráficos de resíduos, foram similares a melhor configuração identificada, com exceção das RNAs com 1 e com 2 neurônios, que destoaram das demais.

Seguindo o melhor desempenho apresentado pelos resultados dos indicadores, a RNA que utiliza 8 neurônios em sua camada, manteve-se com o melhor desempenho entre as 10 RNAs treinadas.

Ao ser feita a análise gráfica de resíduos gerados a partir de seus dados, nota-se o mesmo padrão encontrado para os dados de treino, no entanto é perceptível que ao longo da reta sua distribuição torna-se menos homogênea quando se compara a obtida para os dados de treino.

Sua perda em homogeneidade, afeta diretamente no seu grau de generalização, afetando a precisão da estimativa. Este comportamento, reafirma o que os indicadores utilizados representam. Apesar de ocorrer diferença estatística nos indicadores, mesmo que baixa, é possível identificar que as demais RNAs treinadas, com a exceção da RNA com 1 neurônio em sua camada, obedecem ao comportamento da melhor RNA identificada, com um leve grau de superestimação nas menores classes volumétricas.

A RNA com 1 neurônio em sua camada, demonstrou comportamento bem adverso das demais, com um alto grau de superestimação nas primeiras classes, influenciando diretamente na sua exatidão da estimativa, provavelmente com problema de *underfit*.

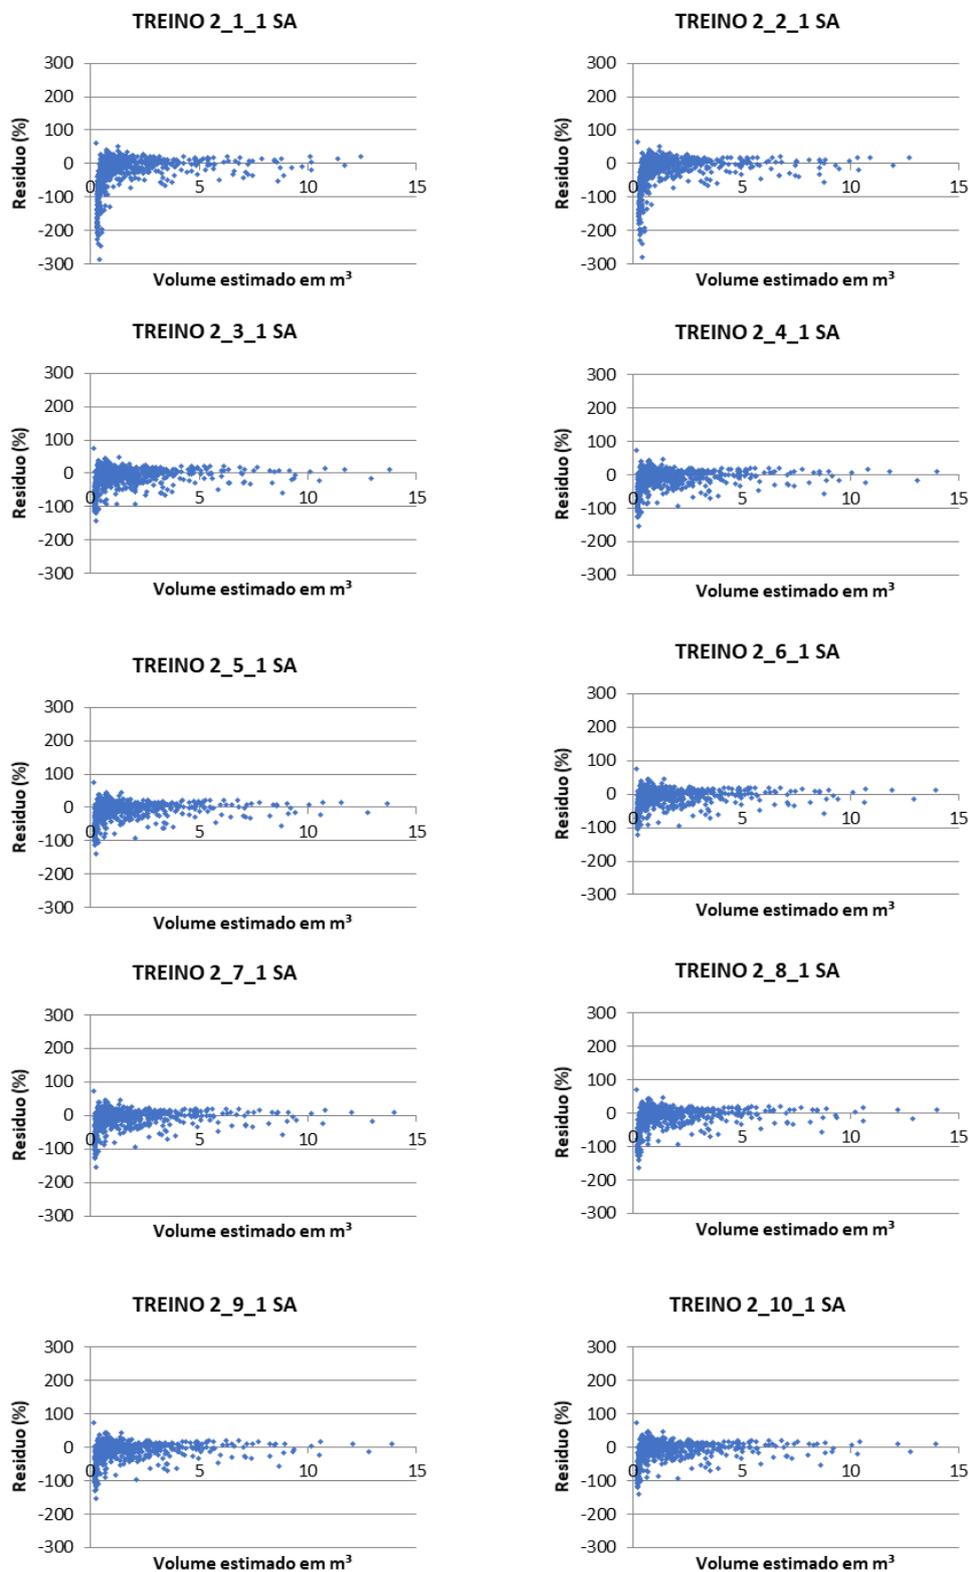


Figura 1. Gráficos de Treino do algoritmo *Simulated Annealing*, representando as camadas de entrada (DAP e Altura), as camadas ocultas variando de 1 a 10 e a camada de saída (Volume).

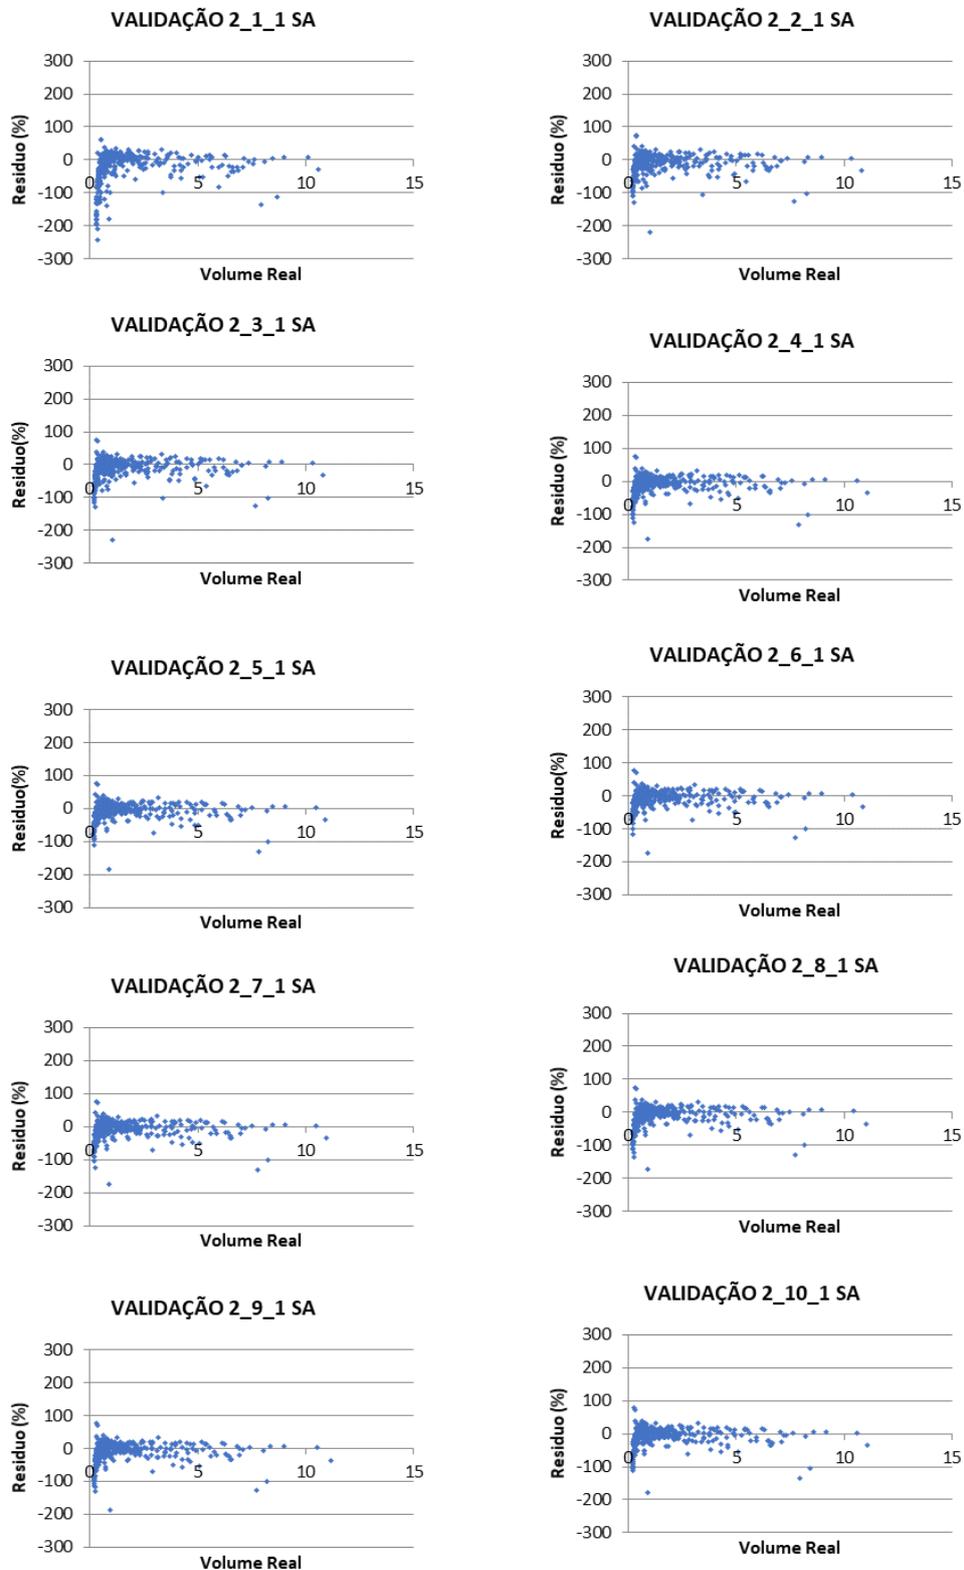


Figura 2. Gráficos de validação do algoritmo *Simulated Annealing*, representando as camadas de entrada (DAP e H), as camadas ocultas variando de 1 a 10 e a camada de saída (Volume).



Na figura 3, apresentam-se os gráficos de análise de resíduos para as RNAs treinadas utilizando o *backpropagation*, para os dados de treino.

De acordo com o melhor desempenho estabelecido pelos critérios estatísticos utilizados, a RNA com 10 neurônios foi a selecionada com o melhor desempenho. Ao ser feita a análise gráfica do resíduo para a melhor RNA, detectou-se um alto nível de superestimação nas classes menores de volume, comportamento este encontrado nos piores desempenhos pelas RNAs utilizando o *Simulated Annealing*.

Este comportamento implica em um pior desempenho na generalização e em sua exatidão, confirmando o que foi apresentado nos indicadores, que obtiveram uma queda considerável quando comparada as RNAs utilizando o *Simulated Annealing*. Nota-se que esse comportamento se estendeu para as demais RNAs treinadas, sem exceções, quando se utiliza o *backpropagation*, resultando em estatísticas com menor precisão.

Na figura 4, apresentam-se os gráficos de análise de resíduos para as RNAs treinadas utilizando o *backpropagation*, para os dados de validação.

Seguindo os critérios apresentados para os indicadores, a RNA com 6 neurônios em sua camada foi a que apresentou o melhor desempenho dentre as 10 treinadas para os dados de validação.

Nota-se que ela seguiu o padrão ocorrido para os dados de treino, gerando superestimação nas classes de menores volume, indo de acordo com os resultados obtidos de seus indicadores, que não foram satisfatórios como os encontrados quando se utilizou o

Simulated Annealing, havendo queda na precisão de suas estatísticas.

As demais RNAs obtiveram desempenho semelhantes a selecionada como melhor, de acordo com seus gráficos de resíduos, sendo que todas as RNAs treinadas para os dados de validação, ocorreu a perda de homogeneidade em sua distribuição ao longo da reta, explicando a sua pior generalização em comparação aos melhores resultados identificados neste trabalho.

Desta forma, indica-se as RNAs utilizadas do tipo *Multilayer Perceptron*, empregando-se o algoritmo de treinamento *Simulated Annealing*, visto que se apresentaram com maior grau de exatidão, sendo capazes de uma boa generalização, sendo a mais indicada para esta base de dados para a estimativa de volume.

Resultados semelhantes indicando a RNA como alternativa para estimativa de volume foram encontrados por (GORGENS *et al.* 2009; BINOTI, 2012; SOUZA *et al.* 2018), apresentando-a como uma ferramenta precisa e superior aos modelos tradicionais utilizados para a estimativa de volume.

Destaca-se também a influência na utilização nos números utilizados de neurônios, sendo estes os que destoaram seus resultados dos demais, sendo os piores, bastante perceptível quando se faz a análise gráfica de resíduos.

3. Conclusão

Sendo assim o melhor algoritmo de aprendizado para RNA foi *Simulated Annealing*, se mostrando mais eficiente para estimativa de volume. A melhor arquitetura de RNA empregada foi com 2 neurônios na camada de entrada, 8 na camada intermediária e um na saída. O *backpropagation* por mais que tenha apresentado bons resultados, não foi superior ao *Simulated Annealing*.

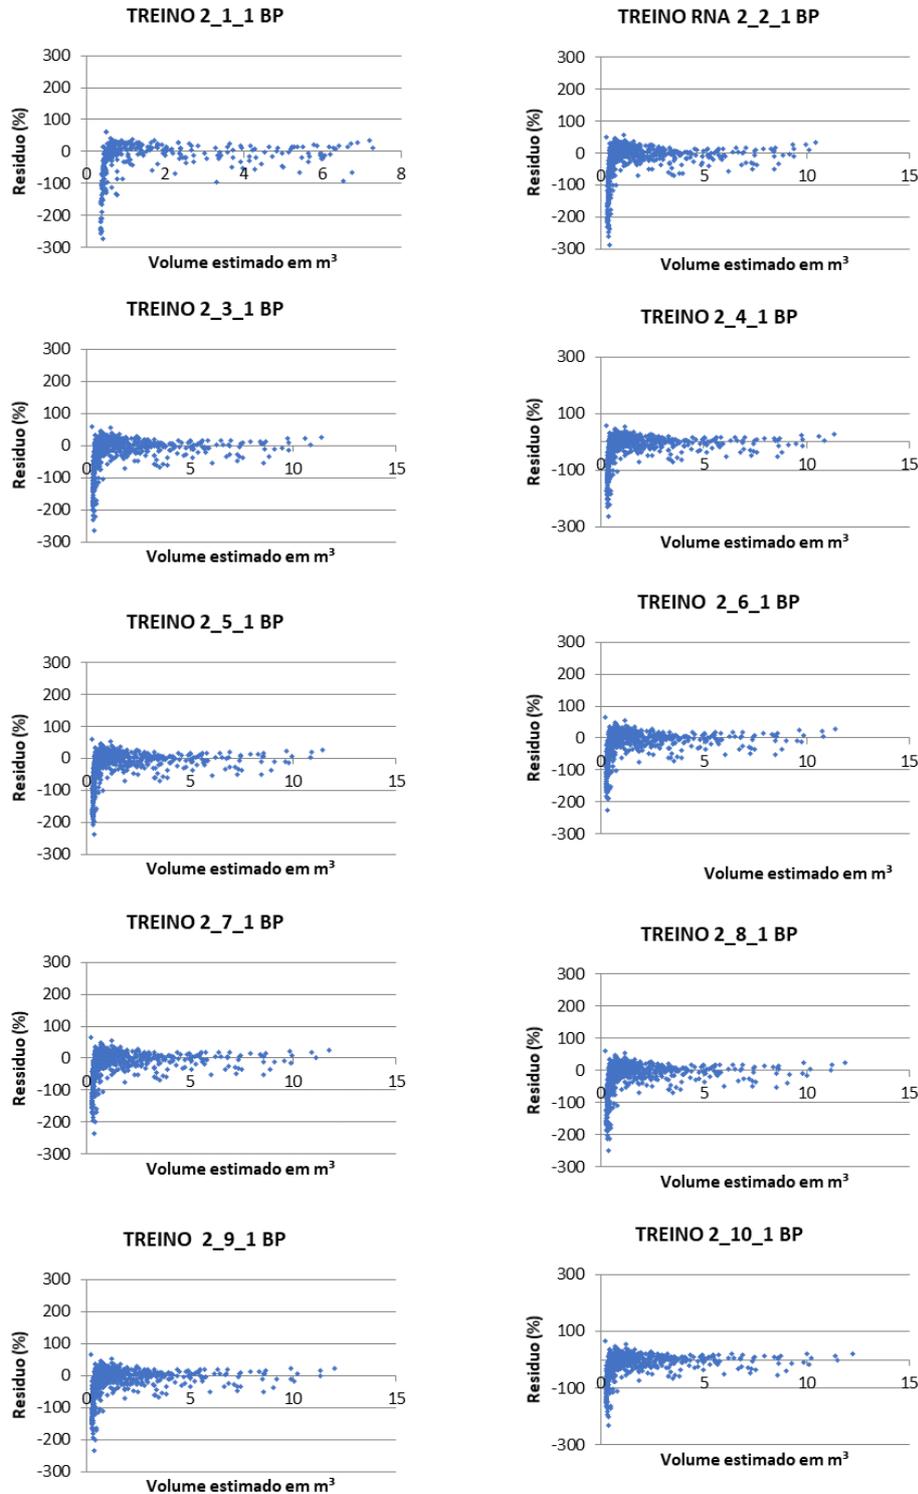


Figura 3. Gráficos de Treino do algoritmo *Backpropagation*, representando as camadas de entrada (DAP e Altura), as camadas ocultas variando de 1 a 10 e a camada de saída (Volume).

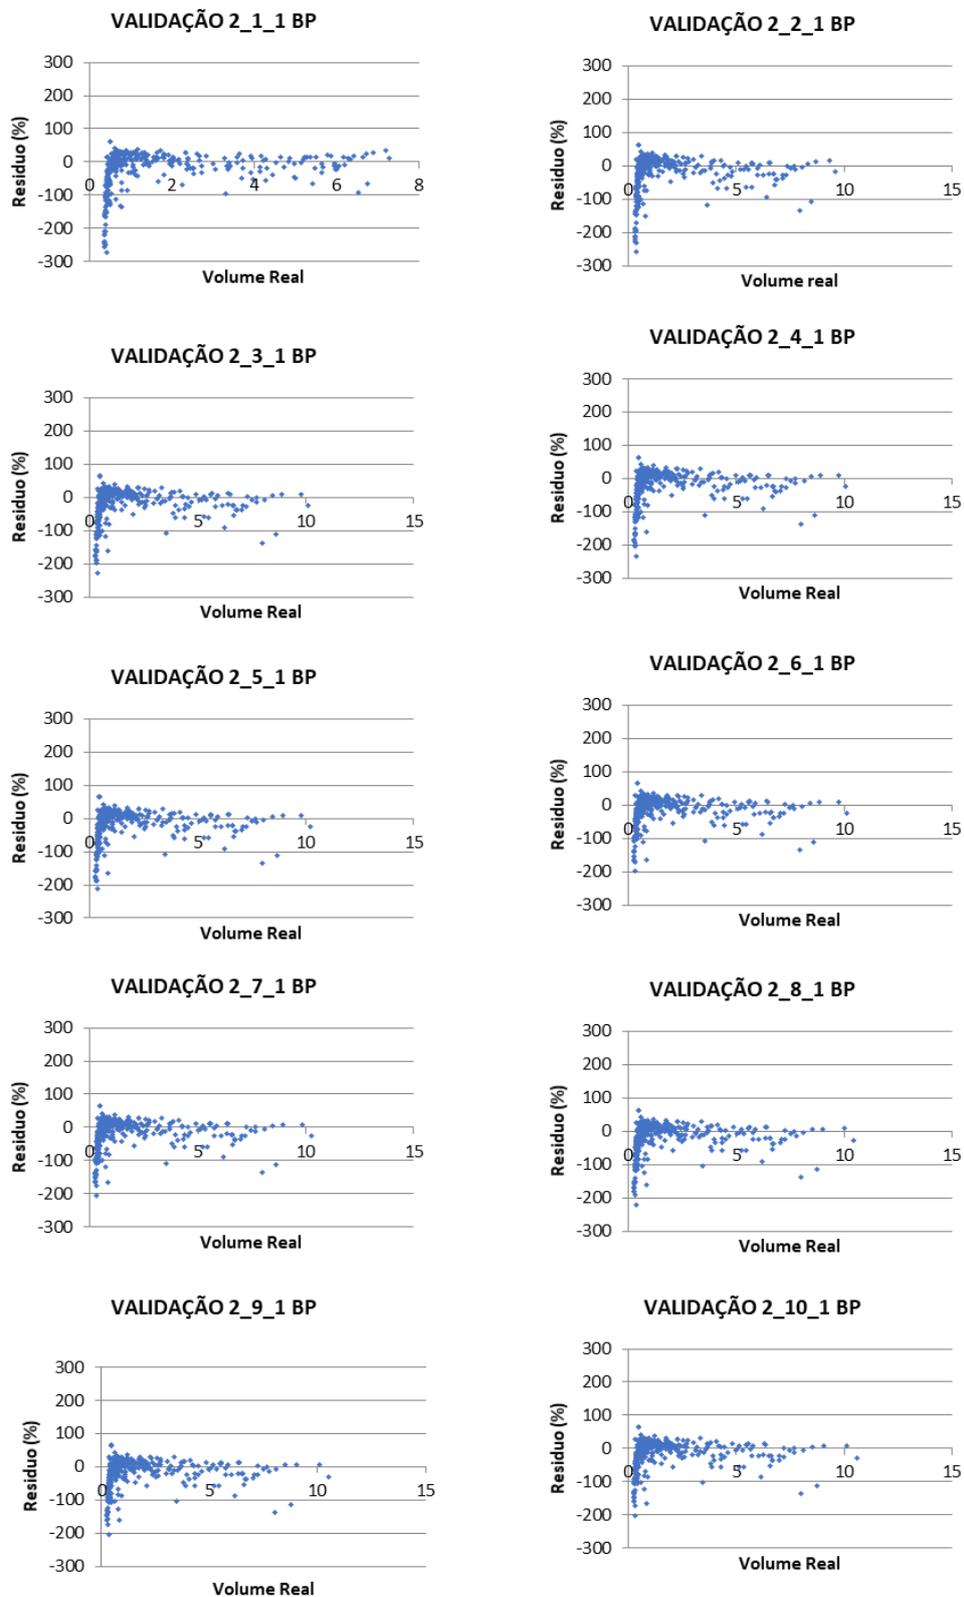


Figura 4. Gráficos de Validação do algoritmo *Backpropagation*, representando as camadas de entrada (DAP e Altura), as camadas ocultas variando de 1 a 10 e a camada de saída (Volume).



Divulgação

Este artigo é inédito e não está sendo considerado para qualquer outra publicação. O(s) autor(es) e revisores não relataram qualquer conflito de interesse durante a sua avaliação. Logo, a revista *Scientia Amazonia* detém os direitos autorais, tem a aprovação e a permissão dos autores para divulgação, deste artigo, por meio eletrônico.

Referências

- ATANAZIO, K.A.; VUADEN, E.; KREFTA, S.M.; SCHORR, L.P.B.; OLIVEIRA, G.S.; KREFTA, S.C. Ajustes de modelos volumétricos para *Pinus taeda* L. em Enéas Marques (PR). *Acta Biológica Catarinense*, v. 7, n. 2, p. 4-14, 2020.
- BEZERRA, Eduardo. Introdução à aprendizagem profunda. **Artigo-31º Simpósio Brasileiro de Banco de Dados-SBBD2016-Salvador**, 2016.
- BINOTI, M. L. M. da S. EMPREGO DE REDES NEURAIAS ARTIFICIAIS EM MENSURAÇÃO E MANEJO FLORESTAL. TESE (Doctor Scientiae) Pós-Graduação em Ciências Florestais, Universidade Federal de Viçosa. Viçosa, 2012.
- BINOTI, M. L. M. S. Redes neurais artificiais para prognose da produção de povoamentos não desbastados de eucalipto. 54f. Dissertação (Mestrado) - Curso de Ciência Florestal, Universidade Federal de Viçosa. Viçosa, 2010.
- BRAGA, A. de P.; CARVALHO, A. P. de L. F. de; LUDEMIR, T. B. *Redes Neurais Artificiais: Teoria e Aplicações*. Editora LTC. 262 p. Rio de Janeiro, 2000.
- BRUNIALTI, L. F.; PERES, S. M.; SILVA, V.F.; LIMA, C. A. M. Aprendizado de máquina em sistemas de recomendação baseados em conteúdo textual: uma revisão sistemática. **Anais..** Porto Alegre: Sociedade Brasileira de Computação - SBC, 2015.
- BULLINARIA, J. A. Introduction to neural computation: notas de aula. Disponível em: <<http://www.cs.bham.ac.uk/~jxb/inc.html>>. Acesso em: 10 dez. 2018.
- CAMPOS, B. P. F.; SILVA, G. F.; BINOTI, D. H. B.; MENDONÇA, A. R.; LEITE, H. G. Predição da altura total de árvores em plantios de diferentes espécies por meio de redes neurais artificiais. *Pesquisa Florestal Brasileira, Colombo*, v.36, n.88, p.375-385, 2016.
- comerciais, em florestas de Paragominas. **Revista Ceres**, 61:631-636, 2014.
- GORGENS, E. B., LEITE, H. G., SANTOS, H. D. N. E GLERIANI, J. M. Estimacão do volume de árvores utilizando redes neurais artificiais. **Revista Árvore**, 33:1141- 1147. 2009.
- HIDALGO, CAJO, I.M.; YASACA-PUCUNA, S.; HIDALGO-CAJO, B.G.; HIDALGO-CAJO, D.P.; LATORRE-BENALCÁZAR, M. B. Estudio comparativo de los algoritmos backpropagation (bp) y multiple linear regression (mlr) a través del análisis estadístico de datos aplicado a redes neuronales artificiales. *Revista Boletín Redipe*, v. 9, n. 3, p. 144-152, 2020.
- INSTITUTO ESTADUAL DE FLORESTAS DO AMAPÁ - IEF. Plano anual de outorga florestal do estado do Amapá – PAOF 2017. Macapá, AP: IEF, 2017. Disponível em: <<https://ief.portal.ap.gov.br/dados.php?d=756&a=460>>. Acesso em: 8 Ago. 2018.
- LEITE, H. G; BINOTI, D. H. B; OLIVEIRA NETO, R. R. de; LOPES, P. F; CASTRO, R. R. de; PAULINO, E. J; MAYRA LUIZA MARQUES DA SILVA BINOTI, M. L. M. da S; COLODETTE, J. L. Redes Neurais Artificiais para Estimacão de Densidade Básica da Madeira. **Scientia Forestalis**, v. 44, n. 109, p. 149-154. Piracicaba, 2016.
- LIMA, R. B. APARÍCIO, P. A. FERREIRA, R. L. C. SILVA, W. C. da. GUEDES, M. C. OLIVEIRA, C. P. de. SILVA, D. A. S. da. BATISTA, A. P. B. Volumetria e classificacão da capacidade produtiva para *Mora paraenses* (Ducke) no estuário amapaense. **Scientia Forestalis**, v. 42, n. 101, Piracicaba, 2014.
- LOPES, L. S. S.; RODE, R.; PAULETTO, D.; BALONEQUE, D.D.; dos SANTOS, F.G.; SILVA, A.R.; BINOTI, D.H.B.; LEITE, H.G. Uso de regressão e redes neurais artificiais na estimativa do volume de *Khaya ivorensis*. **Embrapa Amazônia Oriental-Artigo em periódico indexado (ALICE)**, 2020.
- MICHELL, T.M. *Machine Learning*. McGraw-Hill, Inc., New York, NY, USA, 1 edition, 1997.
- NAZARENO, L. S. Q. Estratégias de estimativa de volume de madeira em área de transição caatinga/cerrado. 2020. Dissertação (Mestrado).



Ciências Agrárias

Programa de Pós-Graduação em Ciências Agrárias, Universidade Federal do Piauí, Piauí, 2020.

NEUROFOREST. Disponível em: <<http://neuroforest.ucoz.com/>>. Acesso em: 08 Ago. 2018.

PEREIRA, G.H.A.; CENTENO, J.A.S. Avaliação do tamanho de amostras de treinamento para redes neurais artificiais na classificação supervisionada de imagens utilizando dados espectrais e laser scanner. **BCG- Boletim de Ciências Geodésicas**, v.23, n.2, p.268- 283. Curitiba, 2017.

RODRÍGUEZ, R. P. Redes Neuronales Artificiales. Conceptos básicos y algunas aplicaciones en Energía. 2017.

SILVA, E.M.; Santana A.C. Modelos de regressão para estimação do volume de árvores

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

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

ZHAN, S. H., LIN, J., ZHANG, Z. J.; ZHONG, Y. W. List-based simulated annealing algorithm for traveling salesman problem. *Computational intelligence and neuroscience*, v. 2016, 2016.