

UNIVERSIDADE FEDERAL DE UBERLÂNDIA

GABRIEL FERNANDES BUENO

**REDES NEURAIAS ARTIFICIAIS APLICADAS NA MODELAGEM DE RELAÇÕES
DENDROMÉTRICAS E MORFOMÉTRICAS DE ESPÉCIES ARBÓREAS DO
CERRADO**

**MONTE CARMELO
2020**

UNIVERSIDADE FEDERAL DE UBERLÂNDIA

GABRIEL FERNANDES BUENO

**REDES NEURAIAS ARTIFICIAIS APLICADAS NA MODELAGEM DE RELAÇÕES
DENDROMÉTRICAS E MORFOMÉTRICAS DE ESPÉCIES ARBÓREAS DO
CERRADO**

Trabalho de Conclusão de Curso apresentado ao curso de Engenharia Florestal, Campus Monte Carmelo, da Universidade Federal de Uberlândia, como parte dos requisitos necessários para obtenção do grau de Bacharel em Engenharia Florestal.

Orientador: Prof. Dr. Emanuel Arnoni Costa

**MONTE CARMELO
2020**

GABRIEL FERNANDES BUENO

**REDES NEURAIAS ARTIFICIAIS APLICADAS NA MODELAGEM DE RELAÇÕES
DENDROMÉTRICAS E MORFOMÉTRICAS DE ESPÉCIES ARBÓREAS DO
CERRADO**

Trabalho de Conclusão de Curso
apresentado ao curso de Engenharia
Florestal, Campus Monte Carmelo, da
Universidade Federal de Uberlândia,
como parte dos requisitos necessários para
obtenção do grau de Bacharel em
Engenharia Florestal.

Monte Carmelo, __ de _____ de 20__.

Banca Examinadora

Prof. Dr. Emanuel Arnoni Costa
Orientador

Prof. Dr. Rodrigo Otávio Veiga de Miranda
Membro da Banca

Prof. Dr. Alvaro Augusto Vieira Soares
Membro da Banca

**MONTE CARMELO
2020**

AGRADECIMENTOS

A minha família, principalmente aos meus pais, Durval e Flávia, pelo amor, educação, carinho e incentivo nos estudos, além do auxílio na coleta dos dados.

Ao professor Emanuel Arnoni Costa, pela oportunidade e principalmente ensinamentos durante esta jornada. Aos professores Alvaro Augusto Vieira Soares, Rodrigo Otávio Veiga de Miranda, pelo suporte e contribuições para aprimoramento do trabalho. Ao técnico Lidiomar Soares da Costa por sua disponibilidade e apoio.

Ao Matheus Martins, a professora Kelly de Almeida Silva e demais colegas, pela expressiva contribuição na identificação botânica do trabalho.

Aos proprietários que permitiram a coleta dos dados em seus imóveis.

A Laura Viera Xavier, pelo apoio, incentivo e carinho. Aos meus amigos pela confiança, companheirismo e motivação ao longo desta etapa.

“When something is important enough, you do it even if the odds are not in your favor.”

(Elon Musk)

LISTA DE ILUSTRAÇÕES

Figura 1. Mapa das árvores amostradas no município de Iraí de Minas, MG.....	12
Figura 2. Arquitetura da rede de múltiplas camadas treinadas para descrever as relações dendrométricas e morfométricas de espécies arbóreas do Cerrado.	17
Figura 3. Dispersão de resíduos das variáveis dendrométricas e morfométricas para as duas configurações na camada de entrada da RNA no treinamento.....	29
Figura 4. Dispersão de resíduos das variáveis dendrométricas e morfométricas para as duas configurações na camada de entrada da RNA na validação.....	33

LISTA DE TABELAS

Tabela 1. Formas geométricas de copa utilizada para classificação qualitativa das árvores amostradas.	14
Tabela 2. Critérios estatísticos utilizados para avaliação das RNAs.	18
Tabela 3. Frequência, família botânica e nome popular das espécies amostradas.	20
Tabela 4. Classificação das formas de copa das espécies amostradas.	23
Tabela 5. Características das variáveis dendrométricas usadas no treinamento e validação das RNAs.	25
Tabela 6. Correlação de Spearman das variáveis estudadas.	26
Tabela 7. RNAs selecionadas e seus critérios estatísticos de treinamento.	27
Tabela 8. RNAs selecionadas e seus critérios estatísticos de validação.	32
Tabela 9. Pesos sinápticos das RNAs selecionadas.	35

RESUMO

O Cerrado possui uma alta biodiversidade de plantas. Porém, poucos estudos detalham as características dendrométricas e morfométricas do Cerrado, as quais permitem conhecer a competição e vitalidade das árvores, podendo auxiliar o monitoramento e a execução de práticas conservacionistas. Uma técnica alternativa para descrever essas relações se dá pelo uso de redes neurais artificiais (RNAs). Desta forma, o presente estudo teve como objetivo: i) identificar e caracterizar as árvores amostradas; ii) treinar RNAs para predição de relações dendrométricas e morfométricas; iii) avaliar a performance das RNAs com uso de variáveis qualitativas e quantitativas; iv) criar um algoritmo em linguagem R, para calcular as variáveis dendrométricas e morfométricas. Foram amostradas 200 árvores de crescimento livre em uma área de Cerrado, onde foram realizadas medições do diâmetro do tronco a diferentes alturas a partir solo e definiram-se as seguintes variáveis qualitativas: disposição dos galhos, forma geométrica da copa, pedregosidade do local, posição do terreno e vitalidade das árvores. Em casos de bifurcação foi usado o diâmetro equivalente (deq). Além disso, foi medida a altura total (h), altura de inserção de copa (hic), o diâmetro de copa (dc) e calcularam-se as variáveis morfométricas: proporção de copa (PC%), grau de esbeltez (GE), índice de abrangência (IA), índice de saliência (IS) e formal de copa (FC). Treinaram-se RNAs com diferentes configurações na camada de entrada: utilizando apenas o deq e, posteriormente, deq e a forma de copa. Foi usado o algoritmo de aprendizado *resilient propagation* - (RP-) com arquitetura *Multilayer Perceptron* (MLP). As árvores amostradas pertenceram à diferentes famílias botânicas. As RNAs utilizando apenas o deq apresentaram uma baixa performance na descrição das variáveis: FC, IS e IA. A inserção da variável categórica forma de copa proporcionou a RNA maior eficiência nas predições de todas as variáveis no treinamento. Os pesos sinápticos e o algoritmo criado em R podem ser utilizados para a predição das variáveis do presente estudo. Palavras-chave: Relações morfométricas, Mensuração florestal, Aprendizado de máquina.

ABSTRACT

The Cerrado has a high biodiversity of plants. However, few studies detail the Cerrado's dendrometric and morphometric characteristics, which allow to understand the competition and vitality of trees and can assist the monitoring and execution of conservation practices. An alternative technique to describe these relationships is the use of Artificial Neural Networks (ANNs). Thus, the present study aimed to: i) identify and characterize the sampled trees; ii) train ANNs to predict the dendrometric and morphometric relationship; iii) evaluate the performance of ANNs using qualitative and quantitative variables iii) create an algorithm in R language to calculate the dendrometric and morphometric variables. A total of 200 open grown trees were sampled in an area of Cerrado, where trunk diameter measurements were made at different levels above the ground and the following qualitative variables were defined: branch arrangement, geometric shape of the crown, stoniness, tree position on the relief and vitality. In cases of occurrence of more than one stem, the equivalent diameter (deq) was used. In addition, the total height (h), crown base height (cbh), crown diameter (dc) were measured and the morphometric variables were calculated: crown proportion (CP%), slenderness rate (SR), range index (RI), salience index (SI) and crown formal (CF). ANNs were trained with different configurations in the input layer: using only the deq and then the deq and the geometric shape of the crown. The *resilient propagation* - (RP-) learning algorithm with *Multilayer Perceptron* (MLP) architecture was used. The sampled trees belonged to different botanical families. ANNs using only deq presented a low performance in the description of the variables: CF, SI and RI. The insertion of the categorical variable crown shape provided the ANN with greater efficiency in the predictions of all variables in training. Synaptic weights and the algorithm created in R can be used to predict the variables of the present study.

Keywords: Morphometric relationship, Forest mensuration, Machine learning.

SUMÁRIO

1 INTRODUÇÃO.....	10
2 OBJETIVOS.....	11
2.1 OBJETIVOS ESPECÍFICOS	11
3 MATERIAIS E MÉTODOS.....	12
3.1 CARACTERIZAÇÃO DA ÁREA	12
3.2 LEVANTAMENTO DE DADOS	12
3.3 MODELAGEM MORFOMÉTRICA UTILIZANDO RNAS.....	16
3.4 CRITÉRIO DE AVALIAÇÃO DA PERFORMANCE DAS RNAS NO TREINAMENTO E VALIDAÇÃO	18
3.5 ANÁLISES ESTATÍSTICAS	19
4 RESULTADOS E DISCUSSÃO	19
4.1 DESCRIÇÃO DAS ÁRVORES.....	19
4.2 CORRELAÇÃO DAS VARIÁVEIS ESTUDADAS.....	26
4.3 TREINAMENTO DAS RELAÇÕES MORFOMÉTRICAS	27
4.4 VALIDAÇÃO DAS RELAÇÕES MORFOMÉTRICAS	31
4.5 PESOS SINÁPTICOS OBTIDOS PARA AS MELHORES RELAÇÕES MORFOMÉTRICAS.....	35
4.6 ALGORITMO DESENVOLVIDO PARA ESTIMAR AS RELAÇÕES MORFOMÉTRICAS.....	38
5 CONCLUSÃO.....	41
6 RECOMENDAÇÕES.....	41
REFERÊNCIAS	42

1 INTRODUÇÃO

O Cerrado é o segundo maior bioma brasileiro, ocupa cerca de 2 milhões de hectares, correspondendo a 23,98% do território nacional, menor apenas que a Amazônia (REIS; SHIMIELE, 2019). O bioma apresenta elevada riqueza de espécies e endemismo, possuindo mais de 11 mil espécies de plantas vasculares, número expressivo, que está relacionado a diversidade da vegetação (FERREIRA et al., 2017).

A elevada variedade de espécies de plantas proporciona uma ampla aptidão de uso sustentável, principalmente para a população tradicional na qual faz a utilização dos produtos oriundos do Cerrado diariamente, seja para alimentação, uso medicinal, fornecimento de energia e até mesmo matéria prima para construções, desta forma desempenham importante papel cultural e econômico para essas famílias (AFONSO; ÂNGELO, 2009).

Porém, segundo Klink e Machado (2005), toda a diversidade florística e faunística do Cerrado está ameaçada, uma vez que o avanço das atividades antrópicas ocasionou inúmeras transformações no bioma nos últimos anos, culminando na fragmentação dos habitats, erosão dos solos, e até possíveis mudanças do clima local. Visto o recorrente problema, é de suma importância o estudo de métodos de recuperação e práticas silviculturais sustentável para assegurar a integridade do Cerrado.

Para o monitoramento e preservação das espécies arbóreas é fundamental conhecer detalhadamente suas características dendrométricas e morfométricas. No entanto, apesar de tamanha importância, encontram-se poucos estudos sobre o tema.

Uma maneira para obter informações em relação a essas espécies é através do Inventário Florestal – IF (SANTOS et al., 2016). O IF permite a obtenção de diversas variáveis dendrométricas, tais como altura, diâmetro à altura do peito, volume de madeira e área basal. Contudo, usualmente não são realizadas medições em relação a copa das árvores e outras características para descrição das relações morfométricas (COSTA; FINGER; CUNHA, 2013).

As relações morfométricas de árvores livres, isto é, árvores que possuem espaço livre para se desenvolver, permitem o conhecimento do potencial de crescimento das espécies (SILVA et al., 2017). As características morfométricas das árvores se relacionam diretamente com a produtividade e grau de concorrência, o que possibilita definir para cada espécie uma estratégia de manejo para utilização sustentável de seus recursos (COSTA; FINGER; FLEIG, 2016).

Por exemplo, a variável dendrométrica, índice de abrangência (IA) pode indicar a necessidade de desbaste ao longo do tempo em um povoamento, o grau de esbeltez (GE)

permite conhecer a estabilidade da árvore, entre outras variáveis dendrométricas, tais como, índice de saliência (IS), proporção de copa (PC) e formal de copa (FC), que são importantes para tomada de decisões silviculturais (DA SILVA, 2020).

Para descrever as relações dendrométricas e morfométricas, pode-se utilizar redes neurais artificiais (RNAs). Esta técnica simula o neurônio biológico através de estruturas computacionais com objetivo de realizar o aprendizado de máquina para o reconhecimento de padrões (JAIN; MAO; MOHIUDDIN, 1996). As RNAs têm sido aplicadas em diversas áreas, devido a sua eficiente performance, capacidade de adaptação e generalização, além de permitir a inserção de variáveis qualitativas e quantitativas, um diferencial quando comparado à modelos lineares (SHANMUGANATHAN, 2016). Na Ciência Florestal, alguns autores utilizaram RNA em seus estudos como Campos et al. (2017) na descrição do perfil do tronco de árvores em plantios de diferentes espécies, Reis et al. (2018) para prognose da distribuição diamétrica de árvores na amazônia, Martins et al. (2020) para predição da altura de eucalipto e Costa et al. (2020) na modelagem de casca de *Araucaria angustifolia* (Bertol.) Kuntze, entre outros.

2 OBJETIVOS

Descrever relações dendrométricas e morfométricas de espécies nativas do Cerrado.

2.1 OBJETIVOS ESPECÍFICOS

Os objetivos específicos do presente estudo são:

- Identificar e caracterizar as árvores amostradas;
- Treinar RNAs para predição de relações dendrométricas e morfométricas;
- Avaliar a performance das RNAs com uso de variáveis qualitativas e quantitativas;
- Criar um algoritmo em linguagem R, para calcular as variáveis dendrométricas e morfométricas.

3 MATERIAIS E MÉTODOS

3.1 CARACTERIZAÇÃO DA ÁREA

O presente estudo foi realizado em 7 propriedades rurais localizadas no bioma Cerrado, no município de Iraí de Minas, MG. Segundo a classificação de Köppen, o clima é Cwa – subtropical úmido, apresenta temperatura anual média entre 20 e 22 °C e precipitação anual média de 1.300 a 1.600 mm (ALVARES et al., 2013).

3.2 LEVANTAMENTO DE DADOS

Foram amostradas 200 árvores livre de competição (Figura 1), as quais foram identificadas a nível de espécie.

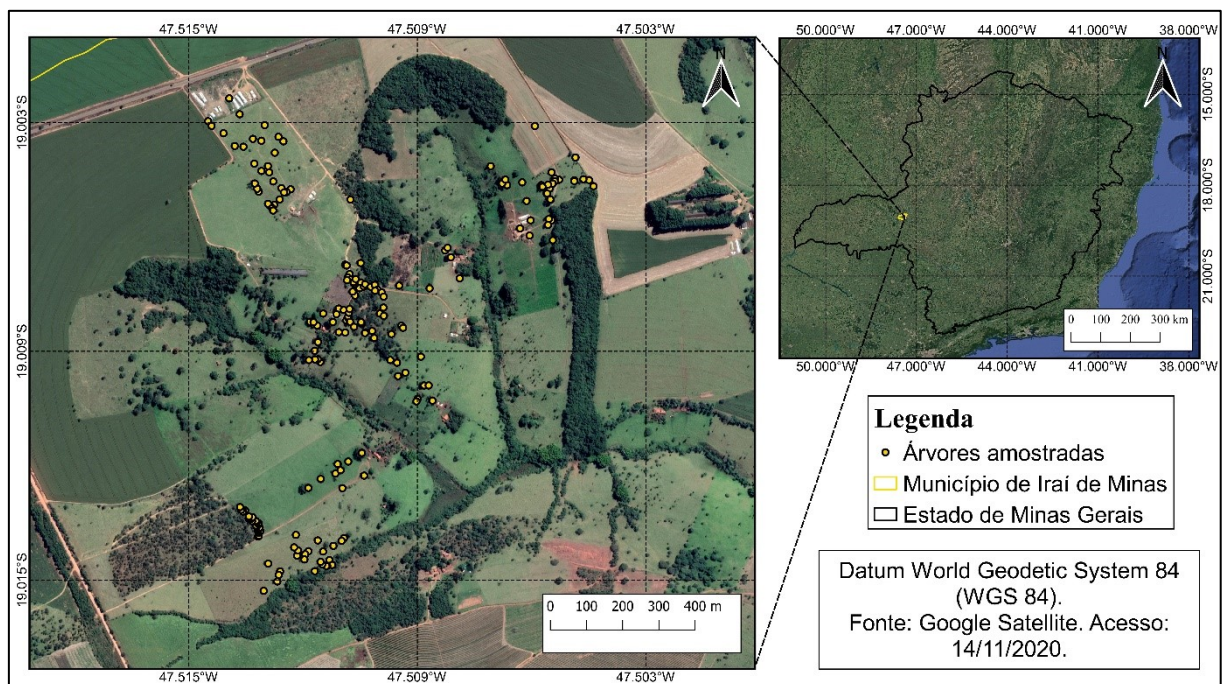


Figura 1. Mapa das árvores amostradas no município de Iraí de Minas, MG.

A medição da circunferência foi realizada à 0,3 m ($d_{0,3}$), 0,7 m ($d_{0,7}$), 1,3 m (DAP) e 1,6 m ($d_{1,6}$) acima no nível do solo utilizando fita métrica. Posteriormente, os valores de circunferência foram convertidos em diâmetro pela divisão por π (3,14159265359). Em casos de perfilhamento do fuste, foi calculado o diâmetro equivalente (d_{eq}) através da seguinte expressão:

$$deq = \sqrt{\sum_{i=1}^n d_i^2}$$

Em que: deq = diâmetro de equivalente (cm) e d = diâmetro (cm).

A estimativa da altura (h) e altura de inserção de copa (hic) foi obtida por um hipsómetro Haglöf ECII-D. Em casos de perfilamento, foram estimadas as h e hic de todos os fustes, e os maiores valores de h e hic foram utilizados na descrição da árvore. Para definição do diâmetro de copa (dc) da árvore, realizou-se medições nas 8 posições cardeais, e seu valor foi obtido pela expressão abaixo (PRETZSCH et al., 2015):

:

$$dc = 2 \times \sqrt{(rc_N^2 + rc_{NE}^2 + rc_L^2 + rc_{SE}^2 + rc_S^2 + rc_{SO}^2 + rc_O^2 + rc_{NO}^2)/8}$$

Em que: dc = diâmetro de copa, em m; rc = raio de copa nas respectivas posições cardeais (N = norte; NE = nordeste; L = Leste; SE = sudeste; S = sul; SO; sudoeste; O = Oeste; NO = Noroeste), em m.

Para cada árvore, foram definidas as seguintes variáveis dendrométricas (DURLO; DENARDI, 1998; KLEIN et al., 2017):

1. Proporção de copa:

$$PC = \frac{cc}{h} \times 100$$

2. Grau de esbeltez:

$$GE = \frac{h}{deq}$$

3. Índice de abrangência:

$$IA = \frac{dc}{h}$$

4. Índice de saliência:

$$IS = \frac{dc}{deq}$$

5. Formal de copa:

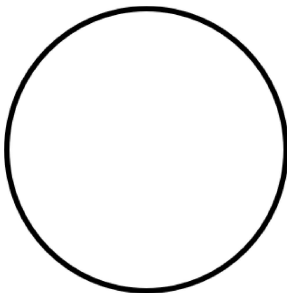

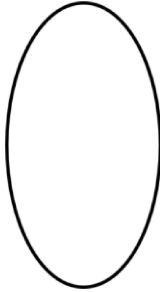

$$FC = \frac{dc}{cc}$$

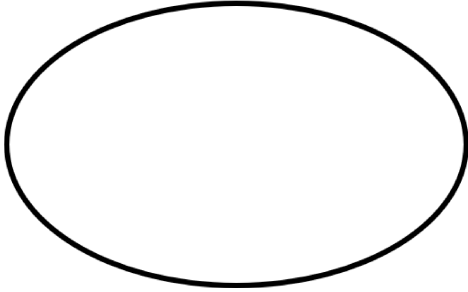

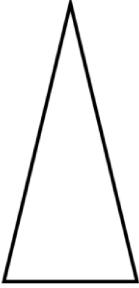

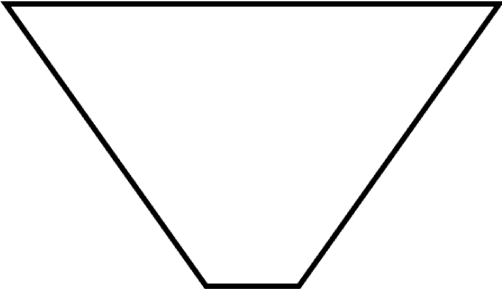

Em que: PC = Proporção de copa; cc = comprimento de copa; h = altura; GE = Grau de esbeltez; deq = diâmetro à 1,3m equivalente; IA = Índice de abrangência; dc = diâmetro de copa; IS = Índice de saliência e FC = formal de copa.

Foram coletadas as seguintes variáveis qualitativas (COSTA, 2011):

- Disposição dos galhos (DG): (1) galhos presentes em todos os quadrantes; (2) apenas em três quadrantes e (3) um ou dois quadrantes.
- Forma da copa (FDC): classificadas através das 5 formas geométricas abaixo:

Tabela 1. Formas geométricas de copa utilizada para classificação qualitativa das árvores amostradas.

Forma de copa	Forma geométrica	Exemplo
(1) Circular		
(2) Colunar		

Forma de copa	Forma geométrica	Exemplo
(3) Elíptica		
(4) Piramidal		
(5) Umbeliforme		

Fonte das imagens: Autor.

- Pedregosidade do local (PL) (em que a árvore está inserida): (1) com afloramento rochoso; (2) com leve presença de rochas; (3) com ausência de rochas.
- Posição do terreno (PT): (1) plano; (2) inclinação leve; (3) elevada inclinação.
- Vitalidade (VT): observou-se a coloração das folhas, a presença de patógenos ou não, assim como as deformações no fuste, classificando em: (1) vitalidade alta; (2) vitalidade média e (3) vitalidade baixa.

3.3 MODELAGEM MORFOMÉTRICA UTILIZANDO RNAS

Os dados dendrométricos e morfométricos foram subdivididos em 2 grupos, sendo 70% destinado ao treinamento das RNAs e os demais 30% para a validação. Para que os dados separados na etapa de treino sejam representativos, estes foram escolhidos manualmente ao longo da distribuição de frequências de classes de diâmetro, de forma que os dados de treinos tenham árvores presentes em todas as classes diamétricas.

A normalização dos dados foi realizada através da expressão:

$$\Delta = \frac{(I_{\text{mín}} - I_{\text{máx}})}{(X_{\text{máx}} - X_{\text{mín}})}$$

$$X_{\text{normalizado}} = I_{\text{mín}} - \Delta \times X_{\text{máx}} + \Delta \times X$$

Em que= Δ = delta; $I_{\text{mín}}$ = Intervalo mínimo da normalização; $I_{\text{máx}}$ = Intervalo máximo da normalização; $X_{\text{máx}}$ = Valor máximo a ser normalizado; $X_{\text{mín}}$ = Valor mínimo a ser normalizado e $X_{\text{normalizado}}$ = Valor normalizado.

Foi usado o algoritmo de aprendizado *resilient propagation* - (RP-), o critério utilizado de parada de aprendizado foi definido através do limiar de 0,01. A arquitetura de RNA utilizada foi do tipo *Multilayer Perceptron* (MLP), aplicando-se a seguinte configuração: k-n-1 (Figura 2), com 3 e 4 neurônios na camada oculta, o número de neurônios na camada oculta foi determinado pelo método de Fletcher-Gloss (SILVA; SPATTI; FLAUZINO, 2010):

$$2.k^{0,5} + N_2 \leq N_1 \leq 2.k + 1$$

Em que= k= número de variáveis de entradas na rede; N_1 = o número de neurônios na camada oculta e N_2 = o número de neurônios na camada de saída.

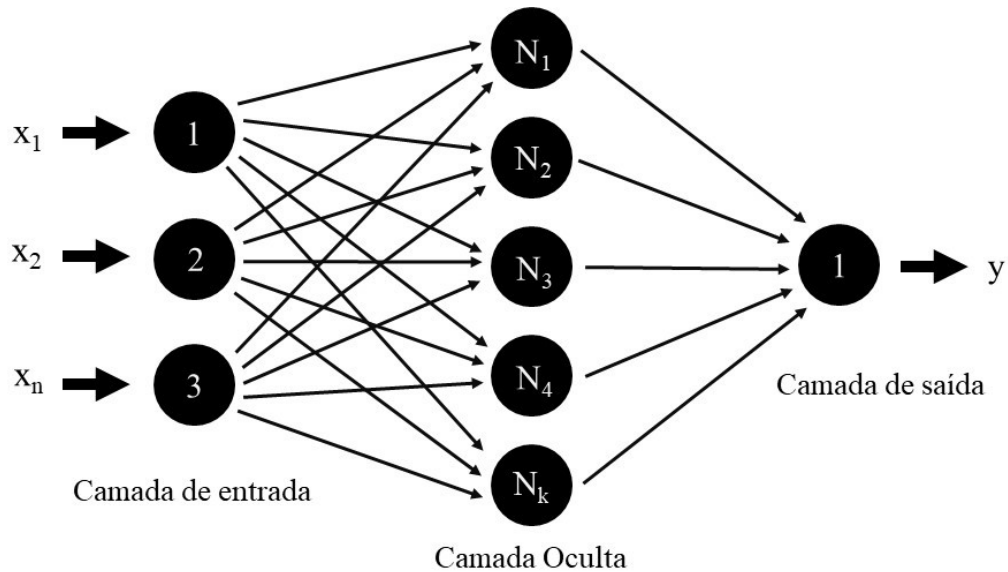


Figura 2. Arquitetura da rede de múltiplas camadas treinadas para descrever as relações dendrométricas e morfométricas de espécies arbóreas do Cerrado. Fonte: Autor.

Em que: x_1 = variável de entrada 1; x_2 = variável de entrada 2; x_n = n-ésima variável de entrada; N_1 = neurônio 1; N_2 = neurônio 2; N_3 = neurônio 3; N_4 = neurônio 4; N_k = k-ésimo neurônio e y = variável de saída (altura, diâmetro de copa, proporção de copa, grau de esbeltez, formal de copa, índice de abrangência e índice de saliência).

Foram treinadas 1400 RNAs, sendo 100 para cada umas das 2 configurações na camada de entrada para as 7 variáveis de saída: altura, diâmetro de copa, proporção de copa, grau de esbeltez, formal de copa, índice de abrangência e índice de saliência. Inicialmente foi utilizada apenas 1 variável de entrada, o diâmetro equivalente e, posteriormente, 2 variáveis de entrada, diâmetro equivalente e a forma da copa. Esta variável categórica foi escolhida uma vez que demonstrou maior número correlações significativas no presente trabalho.

A função de ativação utilizada na camada oculta foi a tangente hiperbólica:

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$$

Na camada de saída utilizou a função linear:

$$f(x) = x$$

A predição da RNA foi definida pelo teorema da aproximação universal, conforme a seguinte expressão (HAYKIN, 2001):

$$y = g \left(\theta + \sum_{j=1}^m v_j \left[\sum_{i=1}^m f(w_{ij}X_i + B_j) \right] \right)$$

Em que: y = variável de saída; g = função de ativação na camada de saída; θ = valor de bias de saída; v_j = peso da conexão do i -ésimo neurônio da camada oculta e saída; w_{ij} = peso da conexão do ij -ésimo neurônio da camada de entrada e oculta; X_i = valor da i -ésima variável de entrada e B_j = valor de bias do j -ésimo neurônio da camada oculta.

3.4 CRITÉRIO DE AVALIAÇÃO DA PERFORMANCE DAS RNAS NO TREINAMENTO E VALIDAÇÃO

Para a avaliação da performance das RNAs foram utilizados os seguintes critérios (MOSER; OLIVEIRA, 2017) expressos na Tabela 2.

Tabela 2. Critérios estatísticos utilizados para avaliação das RNAs.

Critérios	Fórmulas
Coeficiente correlação linear ($R_{\hat{y}y}$)	$R_{\hat{y}y} = \frac{cov(\hat{y}, y)}{\sqrt{s^2(\hat{y})s^2(y)}}$
Raiz do erro quadrático médio (RMSE)	$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}}$
Erro médio absoluto (MAE)	$MAE = \sum_{i=1}^n \frac{ y_i - \hat{y}_i }{n}$
Critério de Informação de Akaike (AIC)	$AIC = n \cdot \ln \left(\sum_{i=1}^n (Y_i - \hat{Y})^2 \right) - n \cdot \ln(n) + 2p$

Em que: cov = covariância; s^2 = desvio padrão; y_i = valores observados; \hat{y}_i = valores preditos; \bar{y} = média dos valores observados; n = número de observações da amostra; p = número de conexões sinápticas da RNA.

Para avaliação do treino das RNAs utilizou-se $R_{\hat{y}y}$, RMSE, MAE, AIC e análise gráfica de resíduos (resíduos = valores observados – valores estimados). Na validação foi utilizado os critérios estatísticos $R_{\hat{y}y}$, RMSE, MAE, teste t pareado ($\alpha = 5\%$) e análise gráfica de resíduos.

3.5 ANÁLISES ESTATÍSTICAS

A análise de correlação de Spearman foi usada para indicar o grau de associação entre as variáveis analisadas, onde os dados são divididos em postos (HOLLANDER; WOLFE; CHICKEN, 2013):

$$d_i = rgX_i - rgY_i$$

$$r_s = \frac{6 \sum_{i=1}^n D_i^2}{n(n^2 - 1)}$$

Em que: rgX_i = postos da observação 1; rgY_i = postos da observação 2; r_s = correlação de Spearman; d_i = é a diferença entre os dois postos de cada observação e n = número de observações.

As RNAs foram treinadas no programa R (R CORE TEAM, 2020), por meio do package Neural Net (FRITSCH; GUENTHER; WRIGHT, 2019). Para cálculo dos critérios estatísticos das RNAs e teste t pareado desenvolveram-se funções em linguagem R. Os gráficos foram confeccionados utilizando o Microsoft Excel 2019 (MICROSOFT CORPORATION, 2019).

4 RESULTADOS E DISCUSSÃO

4.1 DESCRIÇÃO DAS ÁRVORES

Ao todo, foram amostradas 61 espécies (Tabela 3), dentre as quais 57 foram identificadas a nível de espécie, 1 a nível de gênero e 3 não foram identificadas. Conhecida popularmente como pau-terra, a espécie *Qualea grandiflora* obteve a maior frequência com 25 árvores, seguida por *Bowdichia virgilioides* (sucupira-preta) e *Caryocar brasiliense* (pequi) com 17 e 13 árvores, respectivamente. As três espécies de maior frequência correspondem a 27,5% das árvores amostradas e 26 espécies apresentaram apenas um exemplar.

A família Fabaceae apresentou 11 espécies, compreendendo o maior número de árvores, seguida das famílias Bignoneaceae e Malvaceae com 5 espécies cada uma. Em relação ao número de fustes, 13 espécies mostraram ao menos dois fustes.

Tabela 3. Frequência, família botânica e nome popular das espécies amostradas.

Sequência	Família	Nome científico	Nome popular	Frequência	Média de fustes
1		<i>Astronium graveolens</i> Jacq.	Guaritá	1	1,00
2	Anacardiaceae	<i>Lithraea molleoides</i> (Vell.) Engl.	Aroeirinha	1	1,00
3		<i>Tapirira guianensis</i> Aubl.	Pau-pombo	3	1,33
4	Annonaceae	<i>Annona montana</i> Macfad.	Araticum	4	1,00
5		<i>Aspidosperma</i> sp.	-	1	1,00
6	Apocynaceae	<i>Aspidosperma macrocarpon</i> Mart.	Guatambu-do-Cerrado	1	1,00
7		<i>Aspidosperma parvifolium</i> A.DC.	Guatambu	4	1,25
8		<i>Hancornia speciosa</i> Gomes	Mangaba	2	1,00
9	Araliaceae	<i>Schefflera macrocarpa</i> (Cham. & Schltld.) Frodin	Mandiocão	1	1,00
10	Asteraceae	<i>Piptocarpha rotundifolia</i> (Less.) Baker	Candeia	1	1,00
11		<i>Cybistax antisiphilitica</i> (Mart.) Mart.	Ipê-verde	1	1,00
12		<i>Handroanthus albus</i> (Cham.) Mattos	Ipê-amarelo	6	1,00
13	Bignoniaceae	<i>Handroanthus avellanadae</i> (Lorentz ex Griseb.) Mattos	Ipê-roxo	2	1,00
14		<i>Zeyheria tuberculosa</i> (Vell.) Bureau ex Verl.	Ipê-tabaco	4	1,00
15		<i>Cordia trichotoma</i> (Vell.) Arráb. ex Steud.	Louro-pardo	3	1,00
16	Caryocaraceae	<i>Caryocar brasiliense</i> Cambess.	Pequi	13	2,08
17	Chrysobalanaceae	<i>Licania apetala</i> (E.Mey.) Fritsch	Ajuru	1	1,00
18	Combretaceae	<i>Terminalia argentea</i> Mart. & Zucc.	Capitão-do-campo	3	1,00
19		<i>Terminalia glabrescens</i> Mart.	Garrote	2	1,50
20	Ebenaceae	<i>Diospyros lasiocalyx</i> (Mart.) B.Walln.	Caqui-do-mato	1	1,00
21		<i>Anadenanthera macrocarpa</i> (Benth.) Brenan	Angico	6	1,00
22		<i>Bowdichia virgilioides</i> Kunth	Sucupira-preta	17	1,00
23	Fabaceae	<i>Copaifera langsdorffii</i> Desf.	Copaíba	3	1,00
24		<i>Dimorphandra mollis</i> Benth.	Faveira	2	1,00
25		<i>Enterolobium gummiferum</i> (Mart.) J.F.Macbr.	Tamboril	2	1,00
26		<i>Hymenaea stigonocarpa</i> Mart. ex Hayne	Jatobá	3	1,00

Sequência	Família	Nome científico	Nome popular	Frequência	Média de fustes
27		<i>Leptolobium dasycarpum</i> Vogel	Chapadinha	3	1,00
28		<i>Leptolobium elegans</i> Vogel	Perobinha	2	1,00
29		<i>Plathymenia reticulata</i> Benth.	Vinhático	11	1,00
30		<i>Senna multijuga</i> (Rich.) H.S.Irwin & Barneby	Pau-cigarra	1	1,00
31		<i>Stryphnodendron adstringens</i> (Mart.) Coville	Barba-timão	1	1,00
32	Lamiaceae	<i>Aegiphila integrifolia</i> Cham.	Tamanqueira	2	1,00
33	Lauraceae	<i>Ocotea spixiana</i> (Nees) Mez	Canela-cheirosa	2	1,00
34	Lecythidaceae	<i>Cariniana estrellensis</i> (Raddi) Kuntze	Bingueiro	1	1,00
35	Loganiaceae	<i>Strychnos pseudoquina</i> A.St.-Hil.	Quina	1	1,00
36	Lythraceae	<i>Lafoensia pacari</i> A.St.-Hil.	Dedaleiro	5	1,00
37	Malpighiaceae	<i>Byrsonima coccolobifolia</i> Kunth	Murici-do-Cerrado	1	2,00
38		<i>Ceiba speciosa</i> (A.St.-Hil.) Ravenna	Paineira	1	1,00
39		<i>Eriotheca gracilipes</i> (K.Schum.) A.Robyns	Paineira-da-mata	5	1,00
40	Malvaceae	<i>Eriotheca pubescens</i> (Mart. & Zucc.) Schott & Endl.	Embiruçu	1	1,00
41		<i>Luehea divaricata</i> Mart. & Zucc.	Açoita-cavalo	1	1,00
42		<i>Pseudobombax tomentosum</i> (Mart.) A.Robyns	Umburuçu	1	1,00
43	Meliaceae	<i>Cedrela fissilis</i> Vell.	Cedro	3	1,00
44	Moraceae	<i>Maclura tinctoria</i> (L.) D.Don ex Steud.	Moreira	4	1,50
45		<i>Eugenia dysenterica</i> (Mart.) DC.	Cagaita	1	1,00
46	Myrtaceae	<i>Myrcia tomentosa</i> (Aubl.) DC.	Goiabeira-do-mato	1	1,00
47	-	Nid 1	-	2	1,50
48	-	Nid 2	-	1	3,00
49	-	Nid 3	-	2	1,50
50	Primulaceae	<i>Myrsine gardneriana</i> A.DC.	Pororoca	11	1,09
51	Rhamnaceae	<i>Rhamnidium elaeocarpum</i> Reissek	Cafezinho	5	1,00
52		<i>Zanthoxylum rhoifolium</i> Lam.	Maminha-de-porca	3	1,00
53	Rutaceae	<i>Zanthoxylum riedelianum</i> Engl.	Tembetari	1	1,00

Sequência	Família	Nome científico	Nome popular	Frequência	Média de fustes
54	Sapindaceae	<i>Matayba guianensis</i> Aubl.	Camboatá	2	1,00
55	Sapotaceae	<i>Chrysophyllum marginatum</i> (Hook. & Arn.) Radlk.	Leiteiro	4	1,00
56		<i>Pouteria ramiflora</i> (Mart.) Radlk.	Guapeva	1	1,00
57	Solanaceae	<i>Solanum lycocarpum</i> A.St.-Hil.	Lobeira	1	1,00
58	Urticaceae	<i>Cecropia pachystachya</i> Trécul	Embaúba	1	1,00
59	Vochysiaceae	<i>Qualea grandiflora</i> Mart.	Pau-terra	25	1,16
60		<i>Qualea multiflora</i> Mart.	Pau-terra-liso	1	1,00
61		<i>Qualea parviflora</i> Mart.	Pau-terrinha	4	1,00
Total	32	61		200	1,11 [0,33]

[] Desvio padrão dos fustes amostrados.

As espécies foram classificadas com as seguintes formas de copa (Tabela 4):

Tabela 4. Classificação das formas de copa das espécies amostradas.

Espécie	FDC	Frequência
<i>Aegiphila integrifolia</i> Cham.	Circular	2
<i>Anadenanthera macrocarpa</i> (Benth.) Brenan	Circular	5
	Umbeliforme	1
<i>Annona montana</i> Macfad.	Circular	3
	Colunar	1
<i>Aspidosperma macrocarpon</i> Mart.	Circular	1
<i>Aspidosperma parvifolium</i> A.DC.	Circular	4
<i>Aspidosperma</i> sp.	Circular	1
<i>Astronium graveolens</i> Jacq.	Umbeliforme	1
	Circular	2
<i>Bowdichia virgilioides</i> Kunth	Colunar	3
	Umbeliforme	12
	Circular	1
<i>Byrsonima coccolobifolia</i> Kunth	Circular	1
<i>Cariniana estrellensis</i> (Raddi) Kuntze	Circular	1
	Circular	1
<i>Caryocar brasiliense</i> Cambess.	Colunar	1
	Piramidal	1
	Umbeliforme	10
	Umbeliforme	1
<i>Cecropia pachystachya</i> Trécul	Umbeliforme	1
	Circular	2
<i>Cedrela fissilis</i> Vell.	Colunar	1
	Circular	1
<i>Ceiba speciosa</i> (A.St.-Hil.) Ravenna	Circular	1
	Circular	1
<i>Chrysophyllum marginatum</i> (Hook. & Arn.) Radlk.	Eliptica	1
	Piramidal	1
	Umbeliforme	1
	Circular	1
<i>Copaifera langsdorffii</i> Desf.	Eliptica	1
	Umbeliforme	1
	Circular	2
<i>Cordia trichotoma</i> (Vell.) Arráb. ex Steud.	Piramidal	1
	Piramidal	1
<i>Cybistax antisiphilitica</i> (Mart.) Mart.	Piramidal	1
<i>Didymopanax macrocarpus</i> (Cham. & Schltldl.) Frodin	Umbeliforme	1
<i>Dimorphandra mollis</i> Benth.	Circular	2
<i>Diospyros lasiocalyx</i> (Mart.) B. Walln.	Circular	1
<i>Enterolobium gummiferum</i> (Mart.) J.F.Macbr.	Umbeliforme	2
	Circular	1
<i>Eriotheca gracilipes</i> (K.Schum.) A.Robyns	Colunar	1
	Umbeliforme	3
	Circular	1
<i>Eriotheca pubescens</i> (Mart. & Zucc.) Schott & Endl.	Circular	1
<i>Eugenia dysenterica</i> (Mart.) DC.	Eliptica	1
<i>Hancornia speciosa</i> Gomes	Eliptica	2
<i>Handroanthus albus</i> (Cham.) Mattos	Circular	4
	Colunar	1

Espécie	FDC	Frequência
	Piramidal	1
<i>Handroanthus avellanedae</i> (Lorentz ex Griseb.) Mattos	Circular	1
	Umbeliforme	1
<i>Hymenaea stigonocarpa</i> Mart. ex Hayne	Circular	3
<i>Lafoensia pacari</i> A.St.-Hil.	Circular	1
	Colunar	1
	Umbeliforme	3
<i>Leptolobium dasycarpum</i> Vogel	Eliptica	1
	Umbeliforme	2
<i>Leptolobium elegans</i> Vogel	Umbeliforme	2
<i>Licania apetala</i> (E.Mey.) Fritsch	Circular	1
<i>Lithraea molleoides</i> (Vell.) Engl.	Eliptica	1
<i>Luehea divaricata</i> Mart. & Zucc.	Colunar	1
<i>Maclura tinctoria</i> (L.) D.Don ex Steud.	Circular	3
	Eliptica	1
<i>Matayba guianensis</i> Aubl.	Circular	1
	Colunar	1
<i>Myrcia tomentosa</i> (Aubl.) DC.	Eliptica	1
<i>Myrsine gardneriana</i> A.DC.	Circular	5
	Colunar	4
	Eliptica	1
	Piramidal	1
Nid 1	Circular	1
	Eliptica	1
Nid 2	Colunar	1
Nid 3	Circular	1
	Colunar	1
<i>Ocotea spixiana</i> (Nees) Mez	Circular	1
	Umbeliforme	1
<i>Piptocarpha rotundifolia</i> (Less.) Baker	Umbeliforme	1
<i>Plathymenia reticulata</i> Benth.	Circular	2
	Colunar	1
	Umbeliforme	8
<i>Pouteria ramiflora</i> (Mart.) Radlk.	Circular	1
<i>Pseudobombax tomentosum</i> (Mart.) A.Robyns	Eliptica	1
<i>Qualea grandiflora</i> Mart.	Circular	15
	Colunar	2
	Eliptica	1
	Piramidal	2
	Umbeliforme	5
<i>Qualea multiflora</i> Mart.	Umbeliforme	1
<i>Qualea parviflora</i> Mart.	Circular	2
	Colunar	1
	Umbeliforme	1
<i>Rhamnidium elaeocarpum</i> Reissek	Circular	4
	Eliptica	1
<i>Senna multijuga</i> (Rich.) H.S.Irwin & Barneby	Eliptica	1

Espécie	FDC	Frequência
<i>Solanum lycocarpum</i> A.St.-Hil.	Eliptica	1
<i>Strychnos pseudoquina</i> A.St.-Hil.	Circular	1
<i>Stryphnodendron adstringens</i> (Mart.) Coville	Circular	1
<i>Tapirira guianensis</i> Aubl.	Circular	3
<i>Terminalia argentea</i> Mart. & Zucc.	Circular	3
<i>Terminalia glabrescens</i> Mart.	Umbeliforme	2
<i>Zanthoxylum rhoifolium</i> Lam.	Circular	2
	Colunar	1
<i>Zanthoxylum riedelianum</i> Engl.	Circular	1
	Circular	2
<i>Zeyheria tuberculosa</i> (Vell.) Bureau ex Verl.	Colunar	2

Em que: FDC = forma de copa.

As estatísticas descritivas apresentam uma variabilidade expressiva, o que indica que houve uma boa representação das características da vegetação nativa (Tabela 5).

Tabela 5. Características das variáveis dendrométricas usadas no treinamento e validação das RNAs.

Variáveis	Grupo	Un	Mín	Q1	Méd	Mdn	Q3	Máx	DP	CV%
d _{0,3}		cm	6,50	22,23	39,81	30,40	45,90	226,00	33,26	83,54
d _{eq,0,7}		cm	5,90	20,40	36,14	28,80	42,08	226,00	30,02	83,05
d _{eq.}		cm	5,10	19,10	33,97	27,55	39,35	226,00	28,34	83,43
d _{eq,1,6}		cm	4,80	18,80	33,42	26,65	38,90	219,30	27,70	82,91
d _{maior0,7}		cm	5,90	20,40	35,68	28,05	41,55	226,00	29,77	83,44
d _{maior}		cm	5,10	19,03	33,12	26,90	37,25	226,00	28,15	84,99
d _{maior1,6}	Ajuste	cm	4,80	18,10	32,12	25,80	36,03	219,30	27,50	85,61
h	[140]	m	2,30	6,20	10,03	8,70	12,70	27,50	5,35	53,29
h _{ic}		m	1,00	2,40	3,42	3,00	3,80	10,40	1,56	45,45
dc		m	1,30	4,30	7,39	6,55	9,23	29,80	4,60	62,21
IS			0,12	0,19	0,24	0,22	0,28	0,75	0,08	32,69
IA			0,28	0,56	0,75	0,70	0,92	1,45	0,25	33,92
PC			0,29	0,57	0,63	0,64	0,70	0,89	0,11	18,17
GE			0,12	0,26	0,35	0,33	0,42	0,84	0,13	36,85
FC			0,40	0,95	1,23	1,15	1,44	4,14	0,49	39,57
d _{0,3}		cm	5,90	18,63	31,65	29,50	41,73	91,40	17,83	56,32
d _{eq,0,7}		cm	5,60	17,73	28,24	25,80	38,53	75,10	16,14	57,14
d _{eq.}	Validação	cm	5,30	17,25	27,59	25,75	35,23	71,90	15,48	56,11
d _{eq,1,6}	[60]	cm	4,60	17,88	28,35	25,55	37,38	70,00	16,23	57,27
d _{maior0,7}		cm	5,60	17,13	27,71	25,30	34,68	75,10	15,55	56,13
d _{maior}		cm	5,30	16,80	26,34	23,95	32,98	71,90	14,90	56,56

$d_{\text{maior}1,6}$	cm	4,60	16,03	26,93	24,45	35,85	70,00	15,79	58,65
h	m	3,20	5,50	8,43	7,30	10,85	20,20	4,02	47,69
h_{ic}	m	0,20	2,30	3,08	2,70	3,35	8,50	1,46	47,30
dc	m	1,40	3,88	6,30	5,60	8,60	14,80	3,20	50,78
IS		0,10	0,19	0,25	0,22	0,29	0,59	0,08	34,01
IA		0,29	0,55	0,77	0,74	0,95	1,53	0,29	37,24
PC		0,33	0,54	0,61	0,61	0,69	0,95	0,12	19,77
GE		0,13	0,23	0,37	0,33	0,44	1,26	0,19	52,14
FC		0,42	0,87	1,31	1,25	1,50	3,52	0,60	45,73

Em que: Un = unidade; Mín = mínimo; Q1 = quartil 1; Méd = média; Mdn = mediana; Q3 = quartil 3; Máx = máximo; DP = desvio padrão; CV% = coeficiente de variação em porcentagem; $d_{0,3}$ = diâmetro à 0,3 m; $d_{\text{eq},0,7}$ = diâmetro equivalente à 0,7 m; d_{eq} = diâmetro equivalente à 1,3m; $d_{\text{eq},1,6}$ = diâmetro equivalente à 1,6m; $d_{\text{maior}0,7}$ = diâmetro maior à 0,7; d_{maior} = diâmetro maior à 1,3m; $d_{\text{maior}1,6}$ = diâmetro maior à 1,6m; h = altura; h_{ic} = altura de inserção de copa; dc = diâmetro de copa; IS = índice de saliência; IA = índice de abrangência; PC = proporção de copa; GE = grau de esbeltez e FC = formal de copa.

4.2 CORRELAÇÃO DAS VARIÁVEIS ESTUDADAS

As correlações de Spearman das variáveis estudadas (Tabela 6) demonstram alta correlação do diâmetro em diversos pontos de medição com todas as variáveis, exceto o FC. Dentre as variáveis qualitativas, destaca-se a forma de copa (FDC) que apresentou correlações ao mínimo 0,01 de significância com todas as variáveis de saída, exceto a h.

Tabela 6. Correlação de Spearman das variáveis estudadas.

Variáveis	dc	h	IS	IA	PC	GE	FC
d_{eq}	0,86***	0,77***	-0,37***	0,37***	0,58***	-0,62***	0,06
d_{maior}	0,87***	0,80***	-0,32***	0,35***	0,60***	-0,57***	0,02
$d_{0,3}$	0,84***	0,75***	-0,36***	0,37***	0,56***	-0,61***	0,06
$d_{\text{eq},0,7}$	0,85***	0,77***	-0,35***	0,35***	0,57***	-0,58***	0,02
$d_{\text{maior}0,7}$	0,85***	0,78***	-0,34***	0,34***	0,58***	-0,57***	0,02
$d_{\text{eq},1,6}$	0,88***	0,79***	-0,30***	0,37***	0,59***	-0,58***	0,05
$d_{\text{maior}1,6}$	0,88***	0,83***	-0,27***	0,32***	0,62***	-0,51***	-0,01
FDC	-0,35***	-0,08	-0,19**	-0,50***	-0,22**	0,33***	-0,37***
PL	-0,05	-0,08	-0,14*	0,04	-0,11	-0,13	0,13
PT	0,02	0,17*	-0,03	-0,20**	0,08	0,24***	-0,19**
VT	-0,15	-0,12	-0,13	-0,08	0,01	-0,04	-0,10
DG	-0,16*	-0,06	-0,18*	-0,19**	-0,24***	0,05	-0,02***

Em que: $d_{0,3}$ = diâmetro à 0,3 m; $d_{\text{eq},0,7}$ = diâmetro equivalente à 0,7 m; d_{eq} = diâmetro equivalente à 1,3m; $d_{\text{eq},1,6}$ = diâmetro equivalente à 1,6m; $d_{\text{maior}0,7}$ = diâmetro maior à 0,7; d_{maior} = diâmetro maior à 1,3m; $d_{\text{maior}1,6}$ = diâmetro maior à 1,6m; FDC = forma de copa; PL = pedregosidade do local; PT = posição do terreno; VT = vitalidade; DG = disposição dos galhos; h = altura; dc = diâmetro de copa; IS = índice de saliência; IA = índice de abrangência; PC = proporção de copa; GE = grau de esbeltez e FC = formal de copa. P-valor: '***' <0,001; '**' <0,01; '*' <0,05.

A maior correlação da FDC foi para IA com probabilidade de -0,50, as demais variáveis com maior número de correlações significativas foram disposição dos galhos (DG) e posição do terreno (PT). As variáveis qualitativas vitalidade (VT) e pedregosidade do local (PL) apresentaram o menor número de correlações significativas.

4.3 TREINAMENTO DAS RELAÇÕES MORFOMÉTRICAS

No treinamento das relações dendrométricas e morfométricas (Tabela 7), ao utilizar apenas o deq como variável de entrada, o dc obteve os melhores critérios de avaliação, seguido da h. As variáveis PC e IA apresentaram os piores valores dos critérios de avaliação, com valores de R^2 inferiores à 0,4000.

A inserção da variável de entrada FDC juntamente ao deq proporcionou melhores estimativas para todas as variáveis de saída, destacando-se o FC, no qual resultou ganho de 0,1856 para R^2 , correspondente a 112%. Para predição do IS e IA, a inserção da variável categórica gerou um ganho de 59,90% e 55,35% para a R^2 , respectivamente.

Tabela 7. RNAs selecionadas e seus critérios estatísticos de treinamento.

Saída	Entrada	Arquitetura	RNA	R^2	RMSE	MAE	AIC
h	deq	1-3-1	77	0,8664	2,6608	2,0775	293,4
	deq; FDC	2-4-1	52	0,8863	2,4679	1,8602	289,4
dc	deq	1-3-1	83	0,9260	1,7298	1,3759	172,8
	deq; fdc	2-4-1	9	0,9392	1,5725	1,2273	163,2
PC	deq	1-3-1	57	0,6455	0,0866	0,0647	-665,8
	deq; fdc	2-4-1	13	0,7270	0,0778	0,0592	-678,5
GE	deq	1-3-1	36	0,6534	0,0967	0,0766	-634,7
	deq; fdc	2-4-1	36	0,7449	0,0852	0,0671	-653,0
FC	deq	1-3-1	9	0,1657	0,4774	0,3377	-187,7
	deq; fdc	2-4-1	40	0,3513	0,4532	0,2976	-185,2
IS	deq	1-3-1	60	0,4044	0,0717	0,0524	-718,6
	deq; fdc	2-4-1	86	0,6467	0,0598	0,0449	-752,4
IA	deq	1-3-1	37	0,3854	0,2334	0,1843	-388,0
	deq; fdc	2-4-1	46	0,5987	0,2026	0,1525	-410,6

Em que: h = altura; dc = diâmetro de copa; IS = índice de saliência; IA = índice de abrangência; PC = proporção de copa; GE = grau de esbeltez; FC = formal de copa; deq = diâmetro equivalente à 1,3m; FDC = forma de copa; RNA = rede neural artificial; R^2 = coeficiente de correlação; RMSE = raiz do erro quadrático médio; MAE = média do erro absoluto e AIC = critério de informação de Akaike.

O ganho em performance com a adição da variável FDC para as variáveis de saída FC, IS e IA podem ter ocorrido devido estas variáveis serem expressas por relações com o dc. O FC, é expresso pela relação do dc e cc, uma árvore com a forma de copa elíptica apresenta um

valor de dc superior à cc , o inverso ocorre para uma copa colunar, isto é, um dc menor e cc maior. Logo o FDC confere uma importante descrição sobre os atributos morfométricos das espécies.

Outros autores obtiveram ganhos em precisão com a inserção de variáveis categóricas nas RNAs em seus estudos na Ciência Florestal, como o uso RNAs para estimar a altura de povoamentos equiâneos de eucalipto empregando a variável categórica tipo de clone, os autores obtiveram R^2 de 0,9986 no treino para predição da altura, concluindo que, além de eficiente, a metodologia empregada reduz a necessidade de medir um número maior de indivíduos, visto que, devido ao ganho de precisão a amostragem pode ser menor (BINOTI; BINOTI; LEITE, 2013).

Campos et al. (2017) utilizaram as variáveis categóricas gênero, espécie e a rotação atual, juntamente a variáveis quantitativas para estimar o diâmetro ao longo do fuste. O método foi eficiente principalmente para espécies com diferentes condições de crescimento.

Vendrusculo et al. (2018) utilizaram em seu estudo para estimativa da altura em um povoamento misto e equiâneo, a variável categórica espécie, a inserção dela mostrou eficiência nas predições, no qual os autores concluíram como um fator de destaque no uso da técnica.

Costa et al. (2020) utilizaram as variáveis categóricas vitalidade, posição sociológica, pedregosidade, posição do terreno e distribuição dos galhos em seu estudo para modelagem da casca de Araucária, obtendo bons resultados, ressaltando a importância e benefícios da utilização de variáveis qualitativas em técnicas de inteligência artificial.

Os gráficos de resíduos (Figura 3) evidenciam o valor de erro entre ± 8 e $-7,5$ m para ambas RNAs na predição da h . A RNA 52 demonstrou que a inserção da FDC conferiu maior concentração dos resíduos próximos a 0, quando comparada à RNA 77.

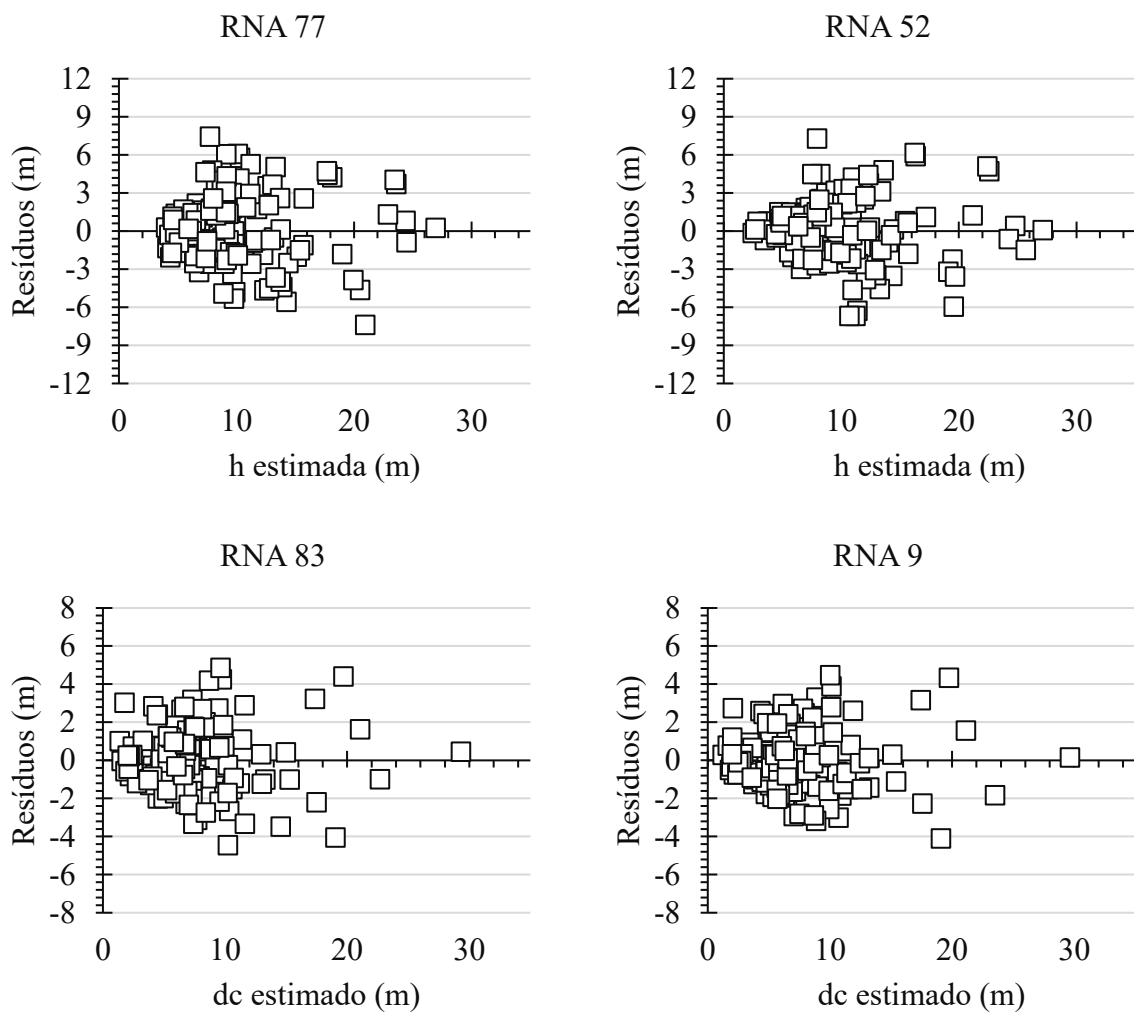
Os resíduos do dc estão distribuídos entre ± 5 e $-4,5$ m utilizando apenas 1 variável de entrada. Com o acréscimo da variável categórica, o intervalo distribuição do erro se manteve, porém, ocorreu leve redução na dispersão dos erros.



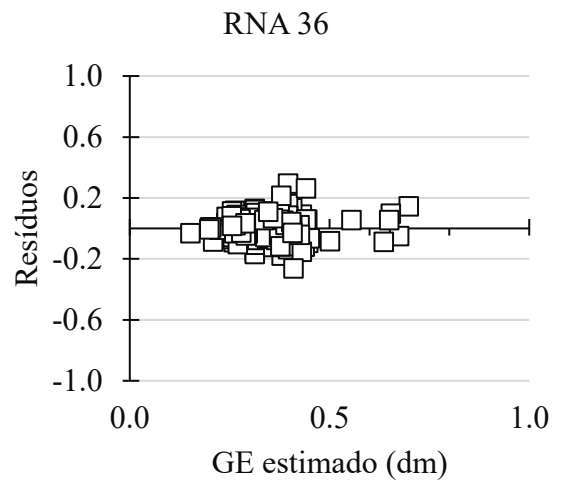

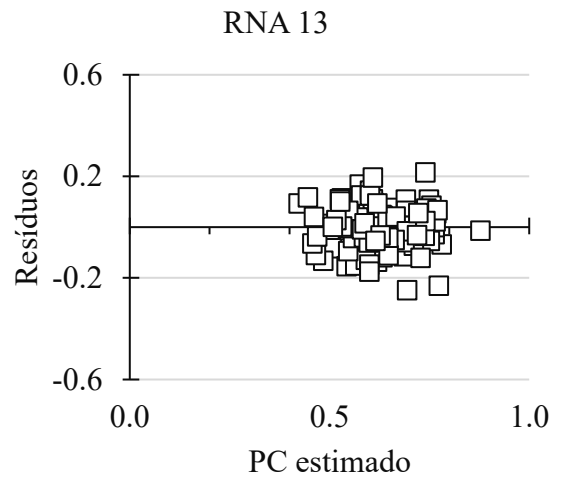

Na predição da PC, a RNA 57 apresentou erros nas estimativas entre $\pm 0,3$ e $-0,3$. A RNA 13, usando também a variável FDC, apresentou distribuição dos resíduos mais homogênea com valores entre $\pm 0,22$ e $-0,25$. A PC pode indicar que uma árvore com maior porcentagem possui mais vitalidade e produtividade (ROMAN; BRESSAN; DURLO, 2009).

Os erros dos valores estimados estão entre $\pm 0,35$ e $-0,25$ para ambas RNAs na predição do GE. Essa variável indica que quanto maior seu valor, maior a estabilidade da árvore, e um menor valor indica maior desenvolvimento da árvore em diâmetro do que em altura (DA SILVEIRA et al., 2014).

Na predição do FC, os resíduos apresentaram distribuição predominantemente homogênea, principalmente para RNA 40. Essa variável indica a presença de copas colunares para menores valores de FC e formas arredondadas possuem maiores valor de FC (ROMAN; BRESSAN; DURLO, 2009).

Para o IS e IA, houve distribuição dos resíduos mais homogênea na predição com a adição da variável FDC na RNA. Segundo Durlo e Denardi (1998) o índice de saliência (IS) indica o espaço necessário para árvore atingir determinado diâmetro e o índice de abrangência (IA) pode ser indicado para definir o número de indivíduos em um hectare, demonstrando quando haverá ou não a necessidade de intervenção silvicultural.





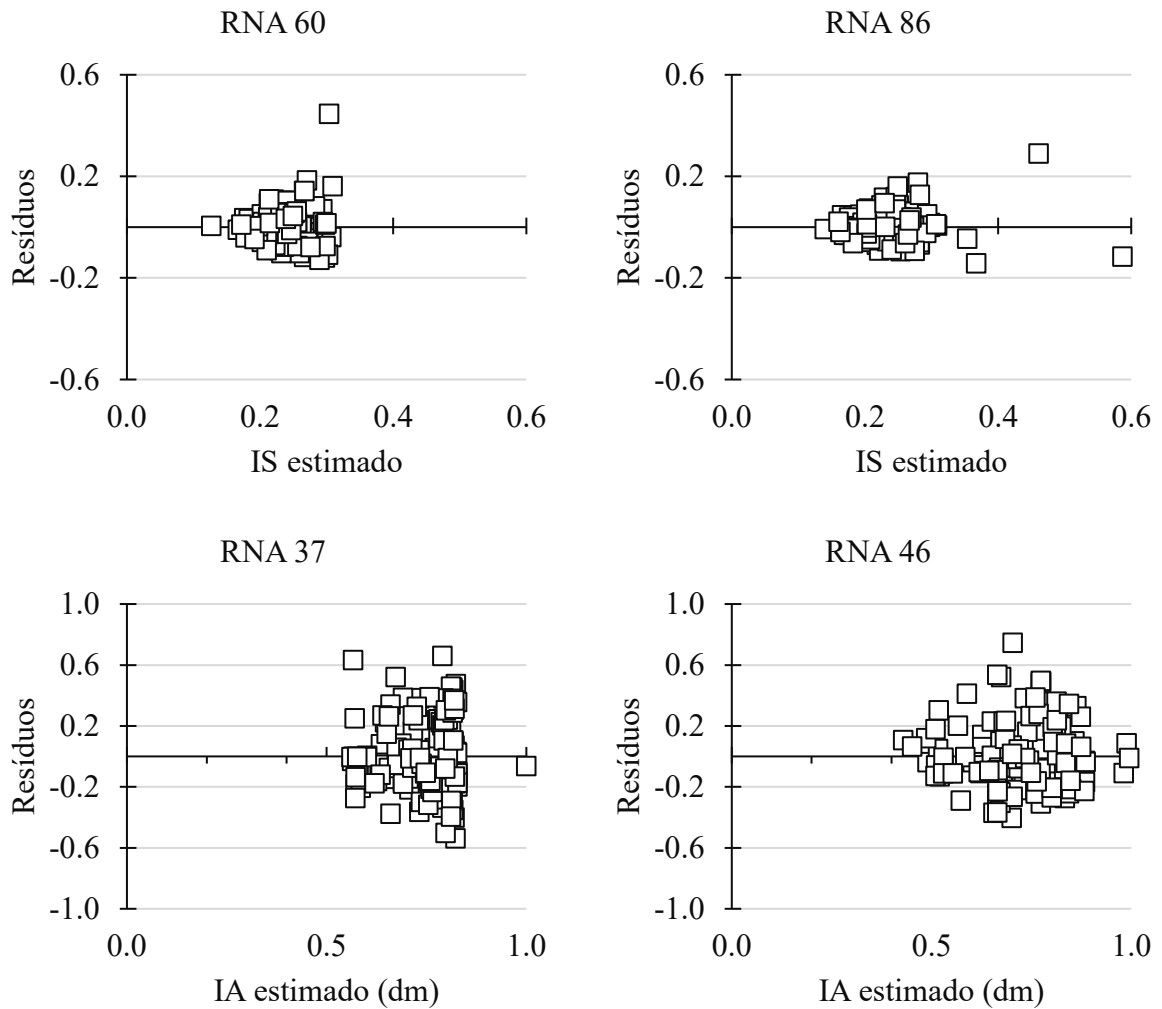


Figura 3. Dispersão de resíduos das variáveis dendrométricas e morfométricas para as duas configurações na camada de entrada da RNA no treinamento.

4.4 VALIDAÇÃO DAS RELAÇÕES MORFOMÉTRICAS

A validação das RNAs (Tabela 8) utilizando apenas o deq como variável de entrada destacou-se o dc com a melhor performance, assim como o h e GE, que apresentam alta correlação. O FC apresentou a pior performance, com $R_{\hat{y}} = 0,0575$.

O acréscimo da variável de entrada FDC proporcionou melhores estatísticas para a h, FC e IA e piores para dc, PC, IS e GE quando comparada as RNAs utilizando apenas o deq.

O teste t, evidencia que para todas as variáveis a 5% de significância os valores observados e estimados não diferiram estatisticamente, ressaltando a eficiência das RNAs na predição de tais variáveis.

Vendrusculo et al. (2015) utilizaram RNAs e regressões não lineares para predição da altura de eucalipto, segundo o teste t pareado na validação, não houve diferença estatística entre

os valores observados e estimados ao nível de 95% de probabilidade. Os autores concluíram que as RNAs foram eficientes e apresentaram leve superioridade nos critérios de avaliação.

Tabela 8. RNAs selecionadas e seus critérios estatísticos de validação.



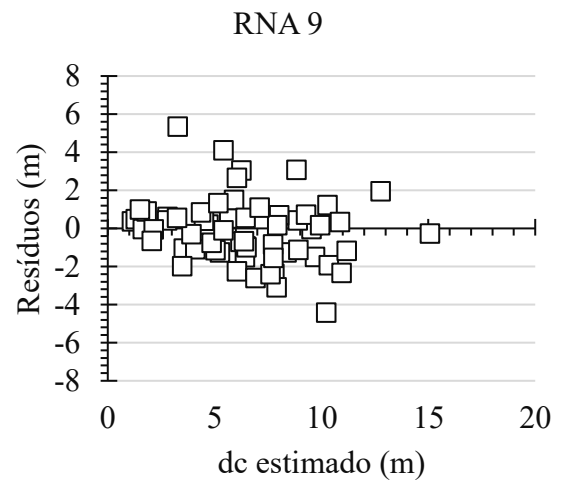
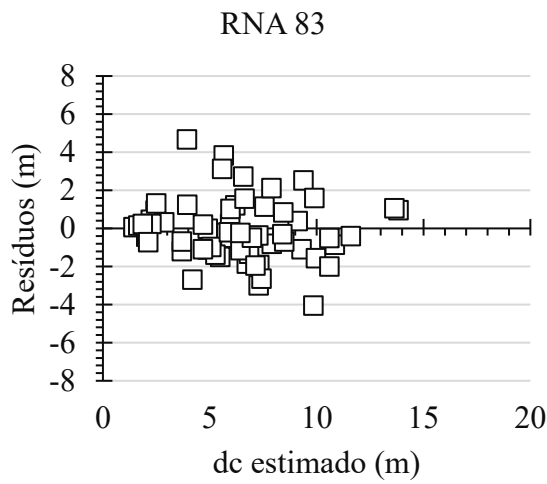


Saída	Entrada	Arquitetura	RNA	R $\hat{y}y$	RMSE	MAE	Teste t (p-value)
h	deq	1-3-1	77	0,6573	3,1698	2,3480	0,0719
	deq; fdc	2-4-1	52	0,7277	2,9105	2,0308	0,0738
dc	deq	1-3-1	83	0,8637	1,6088	1,2343	0,3278
	deq; fdc	2-4-1	9	0,8513	1,7035	1,2850	0,2842
PC	deq	1-3-1	57	0,3627	0,1151	0,0847	0,4534
	deq; fdc	2-4-1	13	0,2841	0,1269	0,0949	0,6078
GE	deq	1-3-1	36	0,6734	0,1445	0,0959	0,4378
	deq; fdc	2-4-1	36	0,6057	0,1533	0,1007	0,7691
FC	deq	1-3-1	9	0,0575	0,5969	0,4233	0,8334
	deq; fdc	2-4-1	40	0,2877	0,5702	0,3921	0,7598
IS	deq	1-3-1	60	0,4240	0,0755	0,0531	0,4613
	deq; fdc	2-4-1	86	0,3704	0,0810	0,0582	0,4259
IA	deq	1-3-1	37	0,4723	0,2548	0,1935	0,8410
	deq; fdc	2-4-1	46	0,6281	0,2230	0,1589	0,8752




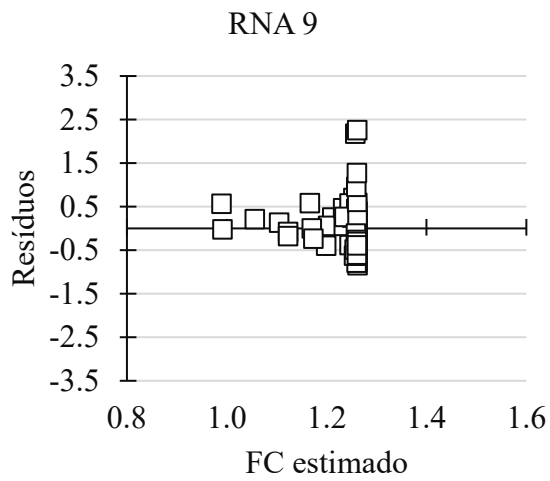

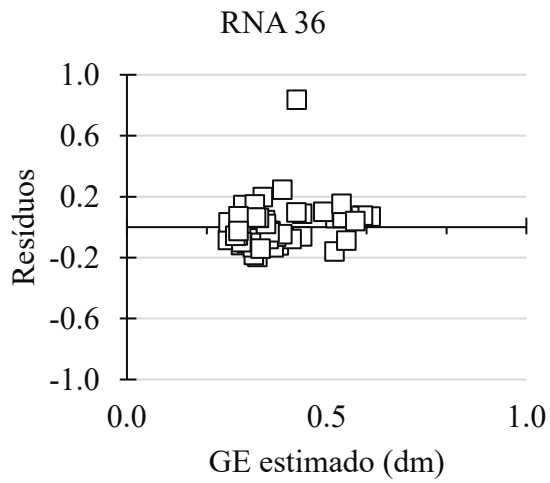
Em que: h = altura; dc = diâmetro de copa; IS = índice de saliência; IA = índice de abrangência; PC = proporção de copa; GE = grau de esbeltez; FC = formal de copa; deq = diâmetro equivalente à 1,3m; FDC = forma de copa; RNA = rede neural artificial; R $\hat{y}y$ = coeficiente de correlação linear; RMSE = raiz do erro quadrático médio; MAE = média do erro absoluto e AIC = critério de informação de Akaike.

O gráfico de resíduos das RNAs na validação (Figura 4) apresenta uma menor dispersão dos erros para as estimativas da altura com a inserção da variável categórica (RNA 52). O mesmo ocorre para o FC e IA, com a inserção da variável FDC, RNA 40 e 46, respectivamente.

A variáveis dc, GE, PC e IS a RNA treinada utilizando apenas o diâmetro deq apresentou menor dispersão dos erros nas estimativas quando comparada a segunda configuração da arquitetura da RNA, utilizando deq e FDC na camada de entrada.

Embora sejam raros estudos que abordem técnicas de inteligência artificial aplicadas à modelagem morfométrica, Lafetá et al. (2020) utilizaram máquinas de suporte de vetor na modelagem morfométrica de *Licania tomentosa* (Benth.) Fritsch, no Vale do Rio Doce em Minas Gerais. Esses autores obtiveram estimativas com precisão, os quais recomendaram o uso da técnica utilizando o diâmetro à altura do peito como variável de entrada.








Figura 4. Dispersão de resíduos variáveis dendrométricas e morfométricas para as duas configurações na camada de entrada da RNA na validação.

4.5 PESOS SINÁPTICOS OBTIDOS PARA AS MELHORES RELAÇÕES MORFOMÉTRICAS

Os pesos sinápticos das RNAs selecionadas estão presentes na Tabela 9, e podem ser utilizados para cálculo das variáveis dendrométricas e morfométricas.

Tabela 9. Pesos sinápticos das RNAs selecionadas.

Variável	Descrição	Simbologia	Entrada		
			deq	deq; fdc	
h	Pesos	w_{11}	0,62964608	-3,13386101	
		w_{12}	-8,25618978	-6,31831622	
		w_{13}	0,43414178	0,06552876	
		w_{14}		-0,15477400	
		w_{21}		0,63352525	
		w_{22}		-5,51982467	
		w_{23}		-1,86166897	
		w_{24}		3,02460524	
	Bias	β_1		-0,61714155	-0,55745954
		β_2		4,88557983	3,58119194
β_3			-0,05407932	0,66125268	
β_4				-1,46032129	
Pesos de conexão	v_1		1,23628337	-0,74313736	
	v_2		0,56022243	-0,22462378	
	v_3		3,20111381	-0,73506052	
	v_4			-0,58773445	
Erro	θ		0,35983157	-0,20233283	
	w_{11}		0,87683289	0,53342259	

Variável	Descrição	Simbologia	Entrada	
			deq	deq; fdc
dc	Pesos	w ₁₂	-8,62017414	-6,81428828
		w ₁₃	1,44445872	0,77101100
		w ₁₄		1,83496652
		w ₂₁		0,12131686
		w ₂₂		-0,32384846
		w ₂₃		0,08328024
		w ₂₄		-0,32547217
		Bias	β ₁	1,40619486
	β ₂		-0,97157148	-1,17374629
	β ₃		-0,27923438	-0,05726277
	β ₄			-0,48266653
	Pesos de conexão	v ₁	0,14533243	-1,41183083
		v ₂	-0,34431477	-0,94443513
		v ₃	0,80475904	0,60901684
		v ₄		0,46004695
	Erro	θ	-0,16513757	0,57597786
PC	Pesos	w ₁₁	-6,70718201	-96,60281768
		w ₁₂	0,21655409	-0,19909600
		w ₁₃	20,53361856	1,30536192
		w ₁₄		296,74885823
		w ₂₁		-4,02906671
		w ₂₂		0,93582448
		w ₂₃		-1,23443747
		w ₂₄		8,18424422
	Bias	β ₁	-1,05218050	25,09931650
		β ₂	-0,44217856	-0,98657105
		β ₃	-2,22668130	0,80472108
		β ₄		-1,51308750
	Pesos de conexão	v ₁	-0,87121745	0,13552761
		v ₂	1,12032878	3,78621404
		v ₃	0,08031824	2,60914791
		v ₄		-0,83174445
Erro	θ	0,19834052	2,28143841	
GE	Pesos	w ₁₁	0,76924162	-7,13107133
		w ₁₂	0,30684065	-248,26810076
		w ₁₃	13,56713732	5,97379296
		w ₁₄		-3,85513016
		w ₂₁		-75,78089426
		w ₂₂		74,83858121
		w ₂₃		2,85269230
		w ₂₄		-1,66373530
	Bias	β ₁	0,15465401	-0,13179427
		β ₂	-1,21041813	-10,81503924
		β ₃	0,79380680	-1,66621787
		β ₄		0,56023290
	Pesos de conexão	v ₁	-0,65398936	-1,46094628
		v ₂	0,68205674	0,05946745

Variável	Descrição	Simbologia	Entrada		
			deq	deq; fdc	
FC		v ₃	-1,12824925	1,13538191	
		v ₄		2,28852640	
	Erro	θ	2,10303894	-0,20801995	
	Pesos	w ₁₁	0,01770148	-3,88245665	
		w ₁₂	-16,81699468	3,60344260	
		w ₁₃	-14,86064914	0,64204008	
		w ₁₄		0,84655516	
		w ₂₁		-1,38506110	
		w ₂₂		4,48236678	
		w ₂₃		0,80246918	
		w ₂₄		-3,23446985	
	Bias	β_1	0,85408828	1,55268181	
		β_2	3,49040705	-1,53654648	
		β_3	7,90265028	-0,24288611	
		β_4		-0,45809241	
	Pesos de conexão	v ₁	1,83379744	0,18120208	
		v ₂	0,04037851	0,07908438	
		v ₃	-0,06695962	0,15596299	
		v ₄		0,38905842	
	Erro	θ	-1,01403043	0,42181114	
	IS	Pesos	w ₁₁	5,50306055	-1,89853504
			w ₁₂	-1,04455889	-0,46523461
			w ₁₃	0,52000873	33,72256459
			w ₁₄		-63,82659444
w ₂₁				-0,61715571	
w ₂₂				0,08864877	
w ₂₃				2,04427393	
w ₂₄				-4,83892776	
Bias		β_1	0,76279031	-0,30968785	
		β_2	1,16420603	-2,02863174	
		β_3	-1,43926377	-0,21606327	
		β_4		3,25275012	
Pesos de conexão	v ₁	-0,45003419	0,48984236		
	v ₂	-0,04498889	-0,74874430		
	v ₃	-0,95126106	-1,19151480		
	v ₄		-0,20018777		
Erro	θ	-0,22251780	0,76662851		
IA	Pesos	w ₁₁	-0,59434381	-1,82587675	
		w ₁₂	-18,86102409	-20,25823585	
		w ₁₃	-12,99356416	0,72156770	
		w ₁₄		-15,96482719	
		w ₂₁		7,37114246	
		w ₂₂		-1,48243794	
		w ₂₃		-2,88976839	
		w ₂₄		-0,73597383	
	Bias	β_1	0,49626221	-1,81693041	
		β_2	1,20561975	2,50118606	

Variável	Descrição	Simbologia	Entrada	
			deq	deq; fdc
		β_3	7,06014960	0,39142952
		β_4		2,10357764
	Pesos de conexão	v_1	1,00372073	0,15105878
		v_2	-0,17079301	-0,41003965
		v_3	-0,35074307	0,59243276
		v_4		0,37607155
	Erro	θ	0,27135065	0,54919495

Em que: $w_{11}, w_{12}, w_{13}, w_{14}, w_{21}, w_{22}, w_{23}, w_{24}$ = pesos sinápticos entre a camada de entrada e oculta; $\beta_1, \beta_2, \beta_3, \beta_4$ = bias; v_1, v_2, v_3, v_4 = pesos sinápticos entre a camada oculta e saída e θ = erro.

4.6 ALGORITMO DESENVOLVIDO PARA ESTIMAR AS RELAÇÕES MORFOMÉTRICAS

- A seguir será apresentado a função realizada em linguagem R para predição da altura das árvores, o mesmo procedimento serve para as demais variáveis modeladas, utilizando como variável de entrada o diâmetro:

```
alturaRNA1 = function(deq){
# normalizando o valor de entrada
deqmin = 5.1
deqmax = 226
htmin = 2.3
htmax = 27.5
delta_input = (1-0)/(deqmax-deqmin)
deqNormalizado = 0 - delta_input*deqmin+delta_input*deq
# pesos
w11 = 0.629646078545507
w12 = -8.25618977746673
w13 = 0.434141780160177
b1 = -0.617141552132877
b2 = 4.88557983079968
b3 = -0.0540793166542885
v1 = 1.23628337142903
v2 = 0.560222429394717
v3 = 3.20111381112449
erro = 0.359831565705823
#somatório
x1=v1*((
(exp(w11*deqNormalizado+b1))-
(exp(-(w11*deqNormalizado+b1))))/
((exp(w11*deqNormalizado+b1))+
(exp(-(w11*deqNormalizado+b1))))))
x2=v2*((
(exp(w12*deqNormalizado+b2))-
(exp(-(w12*deqNormalizado+b2))))/
```

```

    ((exp(w12*deqNormalizado+b2))+
     (exp(-(w12*deqNormalizado+b2))))))
x3=v3*((
  (exp(w13*deqNormalizado+b3))-
  (exp(-(w13*deqNormalizado+b3)))))/
  ((exp(w13*deqNormalizado+b3))+
   (exp(-(w13*deqNormalizado+b3))))))
somax=x1+x2+x3
#função de ativação g
g=somax+erro
# retornando valor a unidade original
delta_output=(1-0)/(htmax-htmin)
output=(g-0+delta_output*htmin)/delta_output
return(output)
}

```

- Função para predição da altura utilizando o diâmetro equivalente e forma de copa como variáveis de entrada:

```

alturaRNA2=function(deq,FormaCopa){
# definindo valor de copa
Copa=function(FormaCopa){
  if (FormaCopa== 'eliptica') {
    (ValorCopa = 1)
  } else if (FormaCopa == 'circular') {
    (ValorCopa = 2)
  }
  else if (FormaCopa == 'umbeliforme') {
    (ValorCopa = 3)
  }
  else if (FormaCopa == 'colunar') {
    (ValorCopa = 4)
  }
  else if (FormaCopa == 'piramidal') {
    (ValorCopa = 5)
  }
}
FormaCopa=Copa(FormaCopa)
# normalizando o valor de entrada
deqmin = 5.1
deqmax = 226
htmin = 2.3
htmax = 27.5
formamax=5
formamin=1
delta_input1 = (1-0)/(deqmax-deqmin)
delta_formaNormalizado = (1-0)/(formamax-formamin)
deqNormalizado = 0 - delta_input1*deqmin+delta_input1*deq

```



```

formaNormalizado = 0 -
delta_formaNormalizado*formamin+delta_formaNormalizado*FormaCopa
# pesos
w11 = -3.13386100796787
w12 = -6.31831621797076
w13 = 0.0655287635383767
w14 = -0.154773995829567
w21 = 0.633525246695924
w22 = -5.51982467334818
w23 = -1.86166896863695
w24 = 3.02460523824039
b1 = -0.557459544760908
b2 = 3.58119193532789
b3 = 0.661252681873634
b4 = -1.46032129005692
v1 = -0.743137360465464
v2 = -0.224623780069328
v3 = -0.735060519162883
v4 = -0.587734447437104
erro = -0.202332833205394
#somatório
x1=v1*((
  (exp(w11*deqNormalizado+w21*formaNormalizado+b1))-
  (exp(-(w11*deqNormalizado+w21*formaNormalizado+b1))))/
  ((exp(w11*deqNormalizado+w21*formaNormalizado+b1))+
  (exp(-(w11*deqNormalizado+w21*formaNormalizado+b1)))))
x2=v2*((
  (exp(w12*deqNormalizado+w22*formaNormalizado+b2))-
  (exp(-(w12*deqNormalizado+w22*formaNormalizado+b2))))/
  ((exp(w12*deqNormalizado+w22*formaNormalizado+b2))+
  (exp(-(w12*deqNormalizado+w22*formaNormalizado+b2)))))
x3=v3*((
  (exp(w13*deqNormalizado+w23*formaNormalizado+b3))-
  (exp(-(w13*deqNormalizado+w23*formaNormalizado+b3))))/
  ((exp(w13*deqNormalizado+w23*formaNormalizado+b3))+
  (exp(-(w13*deqNormalizado+w23*formaNormalizado+b3)))))
x4=v4*((
  (exp(w14*deqNormalizado+w24*formaNormalizado+b4))-
  (exp(-(w14*deqNormalizado+w24*formaNormalizado+b4))))/
  ((exp(w14*deqNormalizado+w24*formaNormalizado+b4))+
  (exp(-(w14*deqNormalizado+w24*formaNormalizado+b4)))))
somax=x1+x2+x3+x4
#função de ativação g
g=somax+erro
# retornando valor a unidade original
delta_output=(1-0)/(htmax-htmin)
output=(g-0+delta_output*htmin)/delta_output
return(output)
}

```

5 CONCLUSÃO

As árvores amostradas pertenceram à diferentes famílias botânicas e possuíram diferentes distribuições diamétricas. As RNAs apresentam eficiência na predição das relações dendrométricas e morfométricas, principalmente para o diâmetro de copa (dc) e altura (h).

A inserção da variável forma de copa (FDC), além da sua fácil obtenção em um curto intervalo de tempo aprimorou ainda mais a eficiência da predição das RNAs. Tais informações podem proporcionar melhorias nas atividades silviculturais dessas espécies.

Os pesos sinápticos disponibilizados permitem o cálculo das variáveis morfométricas e dendrométricas, assim como o algoritmo criado em linguagem R, o qual pode ser utilizado para calcular as variáveis morfométricas das árvores isoladas do presente estudo, utilizando somente diâmetro equivalente (deq) ou diâmetro equivalente (deq) e forma de copa (FDC).

6 RECOMENDAÇÕES

O presente estudo demonstra que o uso das RNAs pode proporcionar eficiência na descrição de variáveis dendrométricas e morfométricas. Logo, para aprimorar e utilizar a técnica corretamente na Ciência Florestal é extremamente importante estudos que abordem não só apenas o uso de RNA, mas que descrevam sua configuração como um todo, a estrutura, a quantidade ideal de número de neurônios na camada oculta, função de ativação, algoritmo de aprendizado, dentre outros.

É essencial a condução de estudos sobre variáveis qualitativas para descrição das características das morfométricas e dendrométricas, visto que, a obtenção delas é simples e prática, acarretando melhores performance das RNAs.

REFERÊNCIAS

- AFONSO, S. R.; ÂNGELO, H. Mercado dos produtos florestais não-madeireiros do Cerrado brasileiro. **Ciência Florestal**, v. 19, n. 3, p. 315–326, 2009.
- ALVARES, C. A. et al. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711–728, 2013.
- BINOTI, M. L. M. DA S.; BINOTI, D. H. B.; LEITE, H. G. Aplicação de redes neurais artificiais para estimação da altura de povoamentos equiâneos de eucalipto. **Revista Árvore**, v. 37, n. 4, p. 639–645, 2013.
- CAMPOS, B. P. F. et al. Descrição do perfil do tronco de árvores em plantios de diferentes espécies por meio de redes neurais artificiais. **Pesquisa Florestal Brasileira**, v. 37, n. 90, p. 99, 2017.
- COSTA, E. A. et al. Understanding bark thickness variations for *Araucaria angustifolia* in southern Brazil. **Journal of Forestry Research**, v. 1, n. 0123456789, p. 1–11, 2020.
- COSTA, E. A. A Influência de variáveis dendrométricas e morfométricas da copa no incremento periódico de *Araucaria angustifolia* (Bertol.) Kuntze, Lages, SC. **Universidade Federal de Santa Maria**. Dissertação (Mestrado em Engenharia Florestal), 2011.
- COSTA, E. A.; FINGER, C. A. G.; CUNHA, T. A. Influência da posição social e do número de raios na estimativa da área de copa em araucária. **Floresta**, v. 43, n. 3, p. 429–438, 2013.
- COSTA, E. A.; FINGER, C. A. G.; FLEIG, F. D. Influência da posição social nas relações morfométricas de *Araucaria angustifolia*. **Ciência Florestal**, v. 26, n. 1, p. 225–234, 2016.
- CUNHA NETO, E. M. et al. Redes neurais artificiais e regressão na estimativa da altura em povoamento experimental misto e equiâneo. **Caderno de Ciências Agrárias**, v. 10, n. 3, p. 60–68, 2018.
- DA SILVA, J. A. G. et al. Morfometria de plantios de *Dipteryx odorata* Aubl Willd (Cumaru) no Oeste do Pará. **Advances in Forestry Science**, v. 7, n. 3, p. 1171-1180, 2020.
- DA SILVEIRA, B. D. et al. Relação da morfometria e competição com o crescimento de *Trichilia clausenii* em um fragmento de floresta semidecidual, RS. **Floresta**, v. 45, n. 2, p. 373-382, 2014.

- DURLO, M. A.; DENARDI, L. Morfometria de *cabralea canjerana*, em mata secundaria nativa do Rio Grande do Sul. **Ciência Florestal**, v. 8, n. 1, p. 55–66, 1998.
- FERREIRA, F. G. et al. Diversity and indicator species in the Cerrado biome, Brazil. **Australian Journal of Crop Science**, v. 11, n. 08, p. 1042–1050, 2017.
- FRITSCH, S.; GUENTHER, F.; WRIGHT, N. M. **neuralnet: Training of Neural Networks**. R package version 1.44.2. <https://CRAN.R-project.org/package=neuralnet>. 2019
- HAYKIN, S. **Redes Neurais - Princípios e Prática**. 2. ed. Porto Alegre: Bookman, p. 235, 2001.
- HOLLANDER, M.; WOLFE, D. A.; CHICKEN, E.. **Nonparametric statistical methods**. John Wiley & Sons, 2013.
- JAIN, A. K.; MAO, J.; MOHIUDDIN, K. M. Artificial neural networks: A tutorial. **Computer**, v. 29, n. 3, p. 31–44, 1996.
- KLEIN, D. R. et al. Relações morfométricas para *Araucaria angustifolia* (Bertol.) Kuntze Em Santa Catarina. **Floresta**, v. 47, n. 4, p. 501–512, 2017.
- KLINK, C. A.; MACHADO, R. B. A conservação do Cerrado brasileiro. **MEGADIVERSIDADE**, v. 1, n. 2, p. 43–51, 2005.
- LAFETÁ, B. O. et al. Modelagem morfométrica de *Licania tomentosa* (Benth .) por regressão logística e máquinas vetor de suporte. **Scientia Plena**, v. 16, p. 1–11, 2020.
- MARTINS, M. T. et al. Estimação da altura de plantios florestais de eucalipto por regressão e redes neurais artificiais. **BIOFIX Scientific Journal**, v. 5, n. 1, p. 141–152, 2020.
- MICROSOFT CORPORATION. Microsoft Excel 2019. 2018. Disponível em: <<https://office.microsoft.com/excel>>. Acesso em: 2020.
- MOSER P.; OLIVEIRA L. Z. **Regressão aplicada à dendrometria: Uma introdução e iniciação à linguagem R**. Blumenau: Edifurb, p. 152, 2017.
- ROMAN, M.; BRESSAN, D. A.; DURLO, M. A. Variáveis morfométricas e relações interdimensionais para *Cordia trichotoma* (Vell.) Arrab. ex Steud. **Ciência Florestal**, v. 19, n. 4, p. 473-480, 2009.
- PRETZSCH, H. et al. Crown size and growing space requirement of common tree species in urban centres, parks, and forests. **Urban Forestry and Urban Greening**, v. 14, n. 3, p. 466–

479, 2015.

R CORE TEAM. R: A language and environment for statistical computing. **R Foundation for Statistical Computing**. Vienna, 2020. Disponível em: <https://www.Rproject.org/>

REIS, A. F.; SCHMIELE, M. Características e potencialidades dos frutos do Cerrado na indústria de alimentos. **Braz. J. Food Technol.**, Campinas , v. 22, 2019.

REIS, L. P. et al. Prognose da distribuição diamétrica na amazônia utilizando redes neurais artificiais e autômatos celulares. **Floresta**, v. 48, n. 1, p. 93–102, 2018.

SHANMUGANATHAN, S. Artificial Neural Network Modelling: An Introduction. **Springer International Publishing**, p. 369–376, 2016.

SHENG, W. et al. An adaptive memetic algorithm with rank-based mutation for artificial neural network architecture optimization. **IEEE Access**, v. 5, n. 1, p. 18895–18908, 2017.

SILVA, F. A. et al. Caracterização de índices morfométricos para *Araucaria angustifolia* plantada na Região Norte do Rio Grande do Sul. **Advances in Forestry Science**, v. 4, n. 3, p. 143–146, 2017.

SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. **Redes Neurais Artificiais: Para Engenharia e Ciências Aplicadas**. São Paulo: ARTLIBER, 2010.

VENDRUSCOLO, D. G. S. et al. Estimativa da altura de eucalipto por meio de regressão não linear e redes neurais artificiais. **Revista Brasileira de Biometria**, v. 33, n. 4, p. 556-569, 2015.