

## Projeção do crescimento arbóreo em floresta estacional semidecidual submontana

A Mata Atlântica é um hotspot global para a conservação da biodiversidade devido à sua riqueza de espécies e endemismo, porém, as ações antrópicas ameaçam e desequilibram a dinâmica dos processos naturais do bioma. Assim, com o objetivo de contribuir com estudos sobre conservação em florestas tropicais, o presente estudo investigou o comportamento da projeção em diâmetro e altura, por meio de ferramentas de regressão e inteligência artificial, com a influência de índices de competição em um fragmento de floresta estacional semidecidual na área do Bioma Mata Atlântica no sudeste do Brasil. As análises foram realizadas de acordo a classificação em grupos ecológicos e quanto à exigência por luz. Foram ajustados quatro modelos de regressão, dois para estimar o diâmetro (DAP) e dois para estimar a altura (H). No processo de aprendizado das redes, selecionaram-se as quatro melhores Redes Neurais Artificiais (RNA), em que cada RNA estimou simultaneamente as variáveis DAP e H. Dentre as redes selecionada, foi definida a melhor RNA visando contrastar com os resultados dos modelos validados. A partir das estatísticas de precisão e análises gráficas, concluiu-se que projetar o crescimento dendrométrico por RNA foi mais eficiente que por modelos tradicionais.

**Palavras-chave:** Sucessão ecológica; Inteligência artificial; Competição florestal; Mata atlântica.

## Projection of tree growth in submontane semideciduous seasonal forest

The Atlantic Forest is a global hotspot for the conservation of biodiversity due to its richness of species and endemism, however, human actions threaten and unbalance the dynamics of the natural processes of the biome. Thus, with the objective of contributing to studies on conservation in tropical forests, the present study investigated the behavior of the projection in diameter and height, using regression tools and artificial intelligence, with the influence of competition indexes in a fragment of forest. Semideciduous season in the area of the Atlantic Forest Biome in southeastern Brazil. The analyzes were carried out according to the classification in ecological groups and regarding the requirement for light. Four regression models were fitted, two to estimate the diameter (DBH) and two to estimate the height (H). In the process of learning the networks, the four best Artificial Neural Networks (ANN) were selected, in which each ANN simultaneously estimated the variables DAP and H. Among the selected networks, the best ANN was defined in order to contrast with the results of the models validated. From the precision statistics and graphical analysis, it was concluded that projecting dendrometric growth by RNA was more efficient than by traditional models.


**Keywords:** Ecological succession; Artificial intelligence; Forest competition; Atlantic forest.


Topic: Ciências Florestais


Received: 04/04/2021


Approved: 01/05/2021


Reviewed anonymously in the process of blind peer.


**Ivan Medeiros Lustosa Junior**   
Instituto Federal de Brasília, Brasil  
<http://lattes.cnpq.br/4218161503948338>  
<http://orcid.org/0000-0002-3873-737X>  
[ivan.junior@ifb.edu.br](mailto:ivan.junior@ifb.edu.br)

**Renato Vinícius Oliveira Castro**   
Universidade Federal de São João Del Rei, Brasil  
<http://lattes.cnpq.br/2397768052594119>  
<http://orcid.org/0000-0001-9018-7793>  
[renatocastro@ufsj.edu.br](mailto:renatocastro@ufsj.edu.br)


**Ricardo de Oliveira Gaspar**   
Universidade de Brasília, Brasil  
<http://lattes.cnpq.br/7729328470427064>  
<http://orcid.org/0000-0002-2035-2180>  
[ricogaspar@unb.br](mailto:ricogaspar@unb.br)

**Juliana Baldan Costa Neves Araújo**   
Universidade de Brasília, Brasil  
<http://lattes.cnpq.br/7268495960930572>  
<http://orcid.org/0000-0003-3019-7345>  
[juliana.bcneves@gmail.com](mailto:juliana.bcneves@gmail.com)

**Fabiana de Gois Aquino**   
Empresa Brasileira de Pesquisa Agropecuária dos Cerrados (Embrapa), Brasil  
<http://lattes.cnpq.br/6715937519108538>  
<http://orcid.org/0000-0001-8177-7978>  
[fabiana.aquino@embrapa.br](mailto:fabiana.aquino@embrapa.br)

**Maisa Isabela Rodrigues**   
Universidade de Brasília, Brasil  
<http://lattes.cnpq.br/0157130804112993>  
<http://orcid.org/0000-0003-2654-8245>  
[maisaisabela@hotmail.com](mailto:maisaisabela@hotmail.com)

**Lidiomar Soares da Costa**  
Universidade de Brasília, Brasil  
<http://lattes.cnpq.br/2825724241808366>  
[lidiomar.ef@gmail.com](mailto:lidiomar.ef@gmail.com)

**Leonidas Soares Murta Júnior**   
Universidade de Brasília, Brasil  
<http://lattes.cnpq.br/612484007158396>  
<https://orcid.org/0000-0003-4848-780X>  
[murtajuniorls@gmail.com](mailto:murtajuniorls@gmail.com)

**Genilda Canuto Amaral**   
Universidade Federal do Espírito Santo, Brasil  
<http://lattes.cnpq.br/0868640938003832>  
<https://orcid.org/0000-0002-8601-7780>  
[genildacanuto@gmail.com](mailto:genildacanuto@gmail.com)



DOI: 10.6008/CBPC2179-6858.2021.005.0002

### Referencing this:

LUSTOSA JUNIOR, I. M.; CASTRO, R. V. O.; GASPAR, R. O.; ARAÚJO, J. B. C. N.; AQUINO, F. G.; RODRIGUES, M. I.; COSTA, L. S.; MURTA JÚNIOR, L. S.; AMARAL, G. C.. Projeção do crescimento arbóreo em floresta estacional semidecidual submontana. **Revista Ibero Americana de Ciências Ambientais**, v.12, n.5, p.14-28, 2021. DOI: <http://doi.org/10.6008/CBPC2179-6858.2021.005.0002>

## INTRODUÇÃO

Constituída por um complexo de ecossistemas, a Mata Atlântica é um bioma de floresta tropical que abriga uma porção significativa da biodiversidade mundial (STEHMANN et al., 2009). Por isso, é considerado um hotspot global para a conservação da biodiversidade, devido à sua riqueza de espécies e endemismo, apesar de ser um dos biomas mais explorados e mais ameaçados do mundo (ARAÚJO et al., 2015; FUNDAÇÃO SOS MATA ATLÂNTICA, 2017). No Brasil, a exploração da Mata Atlântica ocorre especialmente devido ao desenvolvimento econômico e expansão agrícola, comprometendo grande parte dos fragmentos (ALMEIDA et al., 2011; SERRANO et al., 2013). Com apenas 12,4% de sua vegetação nativa, as maiores ameaças ao bioma são o desmatamento e os incêndios florestais (FUNDAÇÃO SOS MATA ATLÂNTICA, 2020).

Em uma floresta, os padrões de diversidade, composição e características funcionais das espécies estão geralmente associadas a diferentes disponibilidades dos recursos naturais ao longo de um gradiente ambiental (McGILL et al., 2006), que por sua vez estrutura o crescimento da floresta (HUSCH et al., 1982). Ao longo do tempo, as variações no tamanho das árvores podem ser avaliadas por meio de técnicas específicas que envolvem aspectos matemáticos e biológicos do componente arbóreo. Sendo, a mensuração de crescimento florestal caracterizada por meio de variáveis como diâmetro, altura, volume, biomassa e área basal (STEPKA et al., 2012).

As estimativas de crescimento podem ser representadas por um ou mais modelos estatísticos, equações, tabelas ou gráficos, ou por um conjunto dos mesmos (CAMPOS et al., 2017). Essas estimativas são mais eficientes quando são considerados fatores do crescimento florestal, como densidade do povoamento, e as variáveis de competição que exercem influência sobre árvores vizinhas (CUNHA et al., 2016). Dentre as metodologias associadas às estimativas de projeção de crescimento florestal, destacam-se os modelos matemáticos que são tradicionalmente empregados na projeção do crescimento florestal (CLUTTER et al., 1983) e as Redes Neurais Artificiais (RNA) que são processadores paralelamente distribuídos, compostos por unidades de processamento simples (BINOTI et al., 2013), onde uma das principais vantagens é a possibilidade de agregar variáveis categóricas às estimativas.

A utilização da inteligência artificial ainda é recente nas ciências florestais, e os estudos são incipientes na mensuração e manejo florestal (GORGENS et al., 2014). Além disso, na literatura há uma lacuna de estudos avaliem a projeção do crescimento florestal em florestas naturais, isso ocorre em função da complexidade da composição de uma floresta nativa. Uma das razões seria o elevado número de espécies com diferentes características silviculturais, ecológicas, tecnológicas e edafoclimáticas (ZANON et al., 2010), além de poucas informações sobre o desenvolvimento das florestas naturais nos diferentes períodos de formação (SCHNEIDER et al., 2006). Assim, as técnicas de projeção do crescimento de árvores sob influência da competição precisam ser consideradas no desenvolvimento de pesquisas em florestas naturais, bem como as alterações das variáveis dendrométricas. Nesse contexto, o trabalho objetivou avaliar o emprego de modelos matemáticos e RNA na projeção do crescimento florestal sob influência da

competição.

## METODOLOGIA

O estudo foi realizado em um fragmento de Mata Atlântica caracterizado como Floresta Estacional Semidecidual Submontana, localizado no município de Caratinga (MG). O clima AW pela classificação de Köppen, com temperaturas entre 19,1°C e 28,3°C e precipitação anual média de 1.373 mm (VELOSO et al., 1991). Foram instaladas 22 parcelas permanentes com dimensões de 10 x 50 m (500 m<sup>2</sup>). Em cada parcela, foram identificados e mensurados altura total (H) e diâmetro a 1,3 m de altura (DAP) dos indivíduos com diâmetro maior ou igual a 5 cm. As espécies do fragmento florestal foram classificadas, segundo Gaspar (2014), nos seguintes grupos ecológicos: pioneiras, secundárias iniciais, secundárias tardias e clímax. Posterior à classificação, os grupos sucessionais foram organizados em duas categorias, atendendo a critérios da exigência por luz, em heliófilas e umbrófilas.

Os modelos matemáticos e RNA utilizados na projeção do crescimento arbóreo foram aplicados para todo o conjunto de espécies (Grupo I), assim como para os grupos sucessionais pioneiras (Grupo II), secundárias iniciais (Grupo III), secundárias tardias (Grupo IV) e clímax (Grupo V). A exigência por luz também foi um fator avaliado na projeção do crescimento arbóreo sob influência da competição ao classificar o conjunto de espécies em heliófilas (Grupo VI), e umbrófilas (Grupo VII).

A mensuração foi realizada em três períodos, nos anos de 2002, 2007 e 2012. Em cada medição, foram calculados Índices de Competição (IC) independentes e semidependentes da distância para os fustes mensurados. Os IC e as distâncias de influência dos raios foram selecionados previamente, com base nos resultados apresentados por Lustosa Junior et al. (2019) (Tabela 1).

**Tabela 1:** Índices de competição independentes e semidependentes da distância utilizados na modelagem do crescimento em diâmetro e em altura para o fragmento de floresta estacional semidecidual, MG.

Grupo	Autor(es)	Índice de competição selecionado para modelagem	Características do índice empregado
I	GLOVER e HOOL (1979)	$IC1 = \frac{dap_i^2 \cdot H_i}{d_n^2 \cdot H_n}$	Índice semidependente da distância, com raio de 4 metros de influência.
II	GLOVER e HOOL (1979)	$IC2 = \frac{H_i}{H_n}$	Índice semidependente da distância, com raio de 3 metros de influência.
III	GLOVER e HOOL (1979)	$IC3 = \frac{H_i}{H_n}$	Índice semidependente da distância, com raio de 4 metros de influência.
IV	STAGE (1973)	$IC4 = BAL_{ni}$	Índice semidependente da distância, com raio de 5 metros de influência.
V	STAGE (1973)	$IC5 = \frac{AS_i^2}{ASq^2}$	Índice independente da distância
VI	STAGE (1973)	$IC6 = BAL_i$	Índice independente da distância
VII	STAGE (1973)	$IC7 = BAL_{ni}$	Índice semidependente da distância, com raio de 5 metros de influência.

Em que:  $dapi$  = diâmetro com casca do fuste da árvore-objeto, medido a 1,30 m (cm);  $d$  = média aritmética dos diâmetros dos fustes da unidade amostral (cm);  $H_i$  = altura total do fuste da árvore-objeto (m);  $H$  = altura média dos fustes da unidade amostral (m);  $AS_i$  = área seccional do fuste da árvore-objeto, medido a 1,30 m de altura (m<sup>2</sup>),  $ASq$  = área seccional correspondente ao diâmetro médio ( $q$ ) dos fustes das árvores vizinhas (m<sup>2</sup>);  $BAL_i$  = somatório das áreas seccionais dos fustes das árvores vizinhas maiores que o

fuste da árvore-objeto;  $dn$  = média aritmética dos diâmetros dos fustes de  $n$  árvores próximas da árvore-objeto (cm), limitadas a um raio de competição de 3, 4, 5 m;  $H_n$  = altura média dos fustes de  $n$  árvores próximas da árvore-objeto (m), limitadas a um raio de competição de 3, 4, 5 m;  $ASqn$  = área seccional ( $m^2$ ) correspondente ao diâmetro médio ( $q$ ) dos fustes das árvores vizinhas, limitadas a um raio de competição de 3, 4, 5 m;  $BAL_n$  = Somatório de todos os indivíduos maiores que a árvore-objeto, limitadas a um raio de competição de 3, 4, 5 m. Foram retirado 30% da base de dados para ser utilizada no processo de validação (generalização) dos modelos matemáticos e RNA que apresentaram os melhores ajustes. Os dados da validação foram selecionados aleatoriamente e não fizeram parte da base de dados utilizada no ajuste dos modelos. As variáveis foram submetidas a teste de normalidade Shapiro-Wilk (SW), e as estimativas foram obtidas por meio do Método Mínimos Quadrados Ordinários (MQO) em quatro modelos de projeção (Tabela 2).

**Tabela 2:** Modelos empregados na estimação das variáveis dendrométricas.

Número	Modelos
(1)	$DAP_2 = \beta_0 + \beta_1 DAP_1 + \beta_2 H_1 + \beta_3 IC + \varepsilon$
(2)	$IPA_d = \beta_0 + \beta_1 DAP_1 + \beta_2 H_1 + \beta_3 IC + \varepsilon$
(3)	$H_2 = \exp(\beta_0 + \beta_1(1/DAP_1) + \beta_2 H_1 + \beta_3 IC) + \varepsilon$
(4)	$IPA_h = \beta_0 + \beta_1(1/DAP_1) + \beta_2 IC + \varepsilon$

Em que:  $DAP_1$  = Diâmetro a altura do peito observado;  $DAP_2$  = Diâmetro a altura do peito estimado;  $H_1$  = Altura total observada;  $H_2$  = Altura total estimada;  $IC$  = Índice de competição;  $IPA_d$  = Incremento periódico anual em diâmetro;  $IPA_h$  = Incremento periódico anual em altura;  $\beta$  = Coeficiente da regressão;  $\varepsilon$  = erro associado. Os modelos 1 e 3 foram utilizados para estimar o DAP e H do componente arbóreo, respectivamente. Os incrementos periódicos estimados em diâmetro e altura foram somados ao diâmetro e altura observados na primeira medição ( $DAP_1$  e  $H_1$ ), obtendo assim o diâmetro e a altura estimados ( $DAP_2$  e  $H_2$ ) representados pelos modelos 2 e 4. O processamento das RNA foi realizado por meio do *software* Statistica 8.0 (STATSOFT, 2008), sendo utilizada a ferramenta *Intelligent Problem Solver* (IPS) para o treinamento das redes.

No processo de construção e treinamento, foram empregados dois tipos de redes com diferentes arquiteturas: MLP (*Multilayer Perceptron*) e RBF (*Radial Basis Function*). Para as redes MLP, foram avaliadas combinações de quatro diferentes funções de ativação nas camadas intermediária e de saída (identidade, logística, tangencial e exponencial). Nas redes RBF, os neurônios da camada de saída são lineares (função identidade), e os neurônios da camada intermediária são função de base radial (função de ativação). As redes foram treinadas para projetar DAP e H como variáveis de saída, simultaneamente (Tabela 3). Os pesos das RNA foram gerados aleatoriamente. Sequencialmente, o valor individual de atualização evoluiu durante o processo de aprendizado, com base na função do erro.

Como fator de seleção, foram escolhidas as quatro RNA com estatísticas superiores na fase de treinamento. Depois de validadas as quatro RNA, definiu-se como superior a que apresentou melhores estimativas de qualidade. Para avaliar o desempenho em ambas as ferramentas de projeção do crescimento, foram calculadas as estatísticas de coeficiente de variação (Equação 1), coeficiente de

correlação (Equação 2), erro padrão das estimativas em porcentagem (Equação 3) e BIAS. Além das estatísticas de qualidade, o comportamento das estimativas foi aferido com base na análise gráfica entre os valores observados e estimados, assim como nos gráficos de resíduos entre os valores observados e o erro.

**Tabela 3:** Variáveis utilizadas no treinamento das RNA para projeção do diâmetro (DAP), altura total (H) de árvores individuais em uma Floresta Estacional Semidecidual Submontana, Caratinga - Minas Gerais. <sup>1</sup>

Número de redes treinadas	Tipo	Saídas	Entradas (numéricas)	Entradas (categóricas)
1000	MLP e RBF	DAP2, H2	DAP1, H1, IC	GE

$$CV\% = \frac{S}{\bar{Y}} * 100$$

Equação 1

S = desvio padrão e  $\bar{Y}$  = média dos dados

$$r = \frac{cov(Y, \hat{Y})}{\sqrt{var(Y).var(\hat{Y})}}$$

Equação 2

r = coeficiente de correlação linear;  
cov = covariância entre a altura Y observada e a altura estimada;  
var = variância da variável Y ou  $\hat{Y}$ .

$$s_{yx} = \sqrt{\frac{\sum(Y_i - Y_e)^2}{n-p}}$$

Equação 3

syx = erro padrão da estimativa;  
Yi = variável observada;  
Ye = variável estimada;  
n = número de observações;  
p = número de coeficientes do modelo matemático.

## RESULTADOS E DISCUSSÃO

As estatísticas obtidas a partir da projeção do crescimento arbóreo pelo ajuste dos modelos matemáticos (Tabela 4) mostraram que o Grupo I apresentou resultados de H2 inferiores quando comparados aos resultados apresentados para a variável DAP2. Este resultado pode ter ocorrido em função de uma limitação comum em áreas nativas, que é a pouca visibilidade do ápice da copa e da base da árvore no momento das medições em campo, gerando erros nas estimativas e causando super ou subestimativas (LINGNAU et al., 2009).

Ao inserir Índices de Competição (IC) nas fórmulas funcionais dos modelos, algumas considerações devem ser ponderadas na interpretação de um IC, uma vez que é notável a variação de acordo o método da competição empregado, assim como das variáveis que o estruturam (CUNHA, 2013). Desta forma, ao observar o comportamento dos modelos matemáticos com a agregação dos IC gerados previamente, exemplifica-se o grupo III, que foi empregado o IC proposto por Glover e Hool (1979), e se limitou a um raio de 4 m de influência ao considerar a variável H na sua composição.

Os modelos 3 e 4, que estimaram o crescimento em H, apresentaram estatísticas inferiores quando comparados aos modelos que estimaram a variável DAP. Uma análise paralela entre as estatísticas,


<sup>1</sup> Em que: MLP= *Multilayer Perceptron*; RBF= *redes Radial Basis Function*; DAP1 e DAP2 = diâmetros a 1,3 m (cm) atual e futuro, respectivamente; H1 e H2 = alturas totais (m) atual e futura, respectivamente; IC = índices de competição independentes e semidependentes da distância; GE= grupo ecológico.

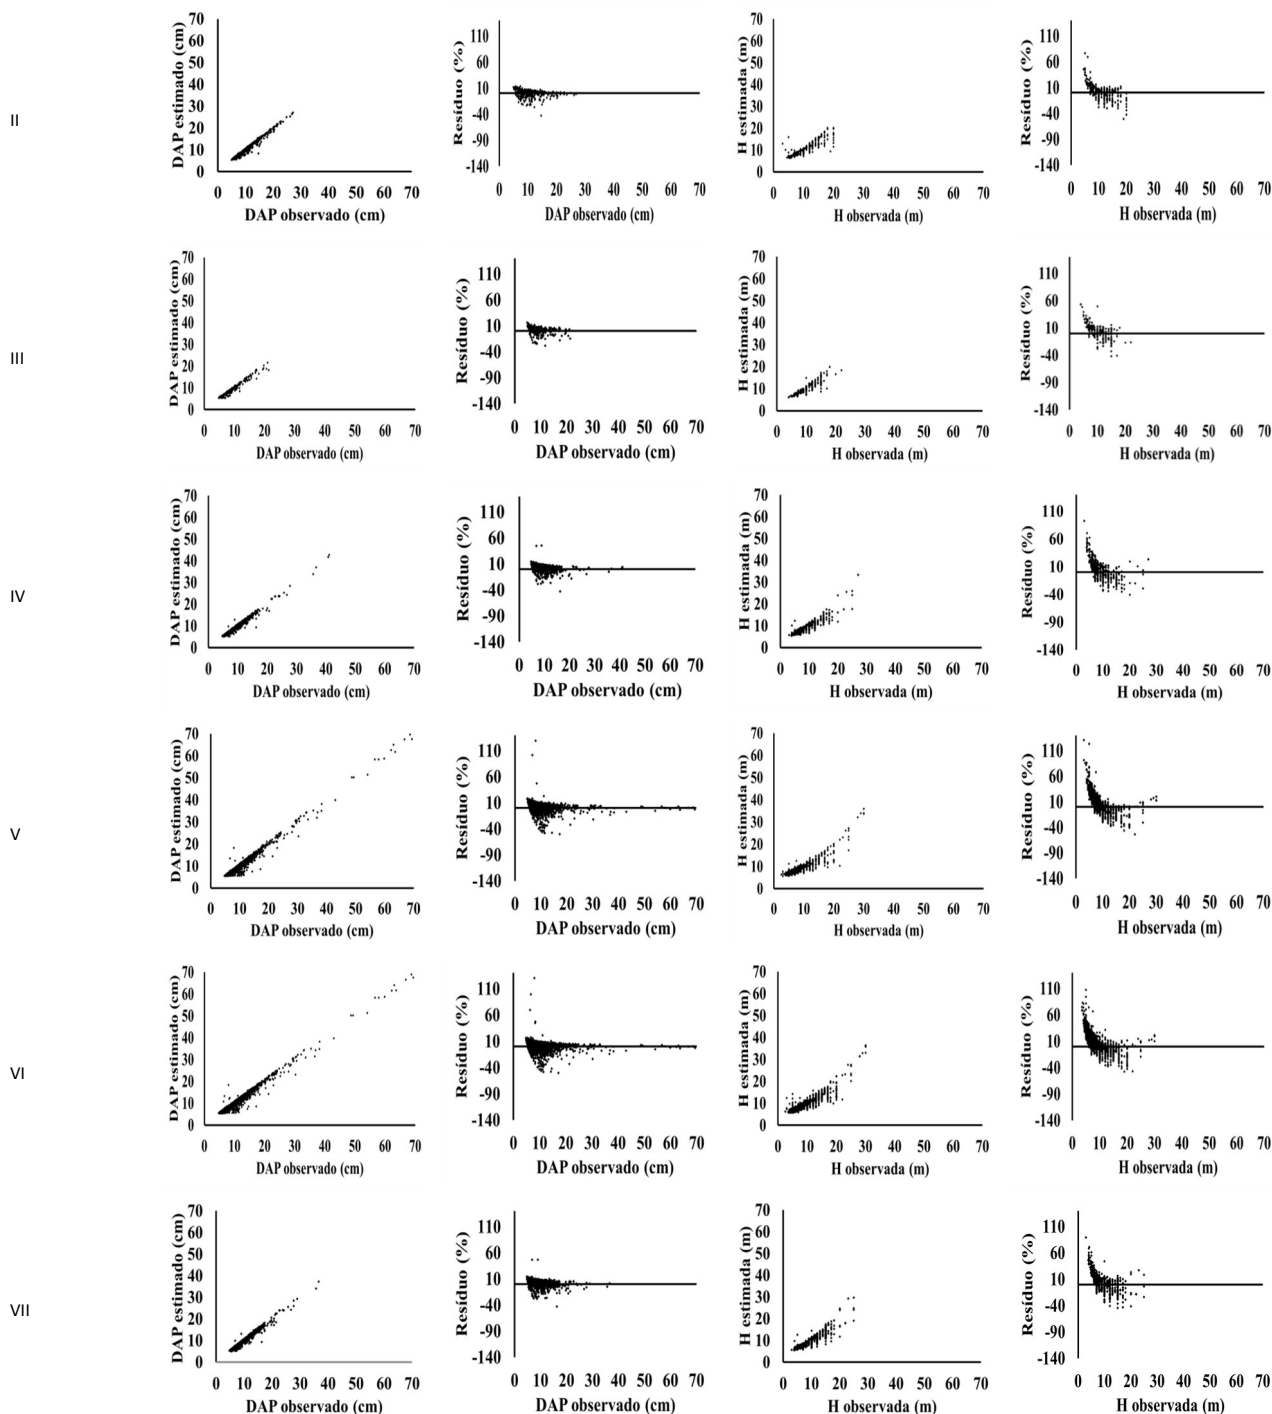
modelos e variáveis dos IC pode ser feita com base em Dimov et al. (2008), que recomendam a aplicação desse índice de competição em povoamentos homogêneos igualmente espaçados da mesma idade e tamanho.

**Tabela 4:** Estatísticas de qualidade obtidas nos ajustes dos quatro modelos tradicionais.

Grupos	Modelo	$\beta_0$	$\beta_1$	$\beta_2$	$\beta_3$	$S_{xy}\%$	CV (%)	Bias	R <sup>2</sup>
I	1	0,7870	1,0157	0,0063	-0,0129	0,5418	5,4271	-0,7853	0,9996
	2	0,1574	0,0031	0,0013	-0,0026	1,0366	9,5463	0,0000	0,9854
	3	1,9821	-2,5656	0,0548	0,0068	1,6638	16,9397	-0,0509	0,9013
	4	1,3250	-6,5099	0,0202	-	3,6063	36,7177	-3,0867	0,9180
II	1	1,0069	0,9795	-0,0083	-0,0102	0,7483	6,5440	0,0000	0,9838
	2	0,2014	-0,0041	-0,0017	-0,0020	0,9018	8,0825	0,0000	0,9759
	3	1,7436	-1,3567	0,0726	0,0020	1,6285	14,5725	0,0000	0,8833
	4	0,2148	-0,9307	0,0017	-	1,6543	14,8033	-0,0170	0,8779
III	1	0,7536	1,0161	-0,0060	0,0774	1,1609	10,5053	0,0000	0,9875
	2	0,1507	0,0032	-0,0012	0,0155	1,2013	11,2570	-0,6973	0,9847
	3	2,0278	-2,2428	0,0537	-0,0056	1,3977	14,7967	0,0000	0,9338
	4	0,3454	-1,4608	-0,0106	-	1,6918	17,9104	-0,0607	0,9016
VI	1	0,0844	1,0003	0,0403	0,3423	0,8214	8,2705	0,0000	0,9842
	2	0,0169	0,0001	0,0081	0,0685	3,1478	30,0500	-2,4679	0,9821
	3	2,1614	-2,7827	0,0724	-0,2471	1,4042	15,1311	0,0000	0,9281
	4	0,7028	-2,6422	-0,2223	-	1,6493	17,7720	-0,0551	0,9007
V	1	0,4550	1,0049	-0,0107	0,4018	0,7454	7,6556	0,0000	0,9782
	2	0,0910	0,0010	-0,0021	0,0804	3,1602	32,4456	-2,9787	0,9827
	3	1,9296	-1,7357	0,0739	-0,0987	0,8328	8,5532	-0,1258	0,9739
	4	0,7796	-2,2531	-0,3143	-	1,5150	14,3916	-0,0166	0,8868
VI	1	0,8547	1,0234	-0,0143	-0,0084	1,1130	9,9541	0,0000	0,9861
	2	0,1709	0,0047	-0,0029	-0,0017	3,5625	32,3088	-3,3139	0,9845
	3	2,0008	-2,5926	0,0531	0,0067	1,4573	14,8646	0,0000	0,9260
	4	0,2528	-1,2889	0,0043	-	1,6631	16,9637	-0,0526	0,9017
VII	1	0,3804	1,0156	0,0488	-0,0153	0,7852	7,9582	0,0000	0,9819
	2	0,0761	0,0031	0,0098	-0,0031	3,1613	30,8669	-2,9447	0,9804
	3	1,8195	-1,9399	0,0690	0,0039	1,4755	15,1541	0,0000	0,9159
	4	0,3162	-1,4768	0,0034	-	1,5816	16,2442	-0,0395	0,9027

Ao fazer um comparativo entre a projeção da variável DAP do Grupo I com os demais Grupos, observou-se que o R<sup>2</sup> apresentou o menor valor dentre os modelos empregados. Isso mostra que a correlação entre os indivíduos observados e estimados se tornou mais forte quando se projetou a variável DAP para o Grupo I. Em contrapartida, ao analisar o comportamento da estatística BIAS, ficou evidente que projetar a variável DAP por grupo ecológico e de acordo com a exigência por luz é mais eficiente do que projetar o crescimento para o grupo composto por todas as espécies. Tendência similar foi observada no erro padrão da estimativa. Pelos resultados da Tabela 4 observa-se que os modelos 1 e 3 apresentaram os melhores ajustes. Ao realizar a análise dos gráficos de dispersão entre dados observados e estimados e distribuição dos resíduos em relação à média (Figura 1), ficou evidente a superioridade dos modelos 1 e 3. Considerando a variável H, notou-se a superestimação dos valores para o modelo 3 em todos os grupos de classificação.





**Figura 1:** Gráficos da dispersão entre os valores observados e estimados e gráficos de distribuição dos resíduos dos modelos 1 e 3, respectivamente.

Ainda na (Figura 1), a análise dos gráficos de resíduos dos modelos tradicionais, observou-se a superestimação nas estimativas de H, principalmente para os indivíduos com menores alturas. Para as estimativas de projeção do DAP, os Grupos II e V apresentaram valores superiores quando comparados aos demais grupos. Dentre os grupos que seguem o critério de exigência ou não por luz, o Grupo VII apresentou comportamento semelhante aos grupos II e V. Os modelos matemáticos 1 e 3, apresentaram melhores estatísticas e distribuição pelos gráficos de dispersão e de resíduos, logo, os resultados apresentam uma superioridade quando contrastados com os demais modelos na projeção em DAP e H, respectivamente.

Alguns aspectos da vegetação devem ser considerados quando se pretende projetar as alterações dimensionais de árvores nativas (STEPKA et al., 2012). A classificação de espécies arbóreas em grupos

sucessionais é comum (SANTOS et al., 2004), principalmente quanto à exigência de luz (LEITÃO FILHO, 1993; JARDIM et al., 1996). A classificação das espécies em grupos ecológicos é uma ferramenta essencial para a compreensão da sucessão ecológica e facilita pesquisas de autoecologia das espécies (PAULA et al., 2004), além de subsidiar a definição de modelos para a recuperação e restauração florestal (KAGEYAMA e GANDARA, 2001).

Por apresentarem diferenças individuais, as árvores de florestas nativas se diferenciam em espécies por demandas de condições de solo, luz e competição. Por outro lado, árvores de plantios homogêneos da mesma espécie apresentam condições semelhantes e, conseqüentemente, o incremento segue tendência uniforme. Desta forma, é aconselhável o uso de índices de competição dependentes da distância para florestas mistas, pois o efeito de árvores vizinhas sob o crescimento da árvore objeto decresce com a distância (ZHAO et al., 2004)

Ao analisar o comportamento das variáveis estimadas no processo de validação, observou-se a mesma tendência na projeção das variáveis DAP e H (Tabela 5). Os resultados estatísticos do processo de validação confirmam os resultados obtidos no ajuste dos modelos. Logo, para a base de dados, é recomendado estratificar as espécies florestais em grupos ecológicos para projeção do crescimento em diâmetro, objetivando o aumento da precisão das estimativas.

**Tabela 5:** Estatísticas de qualidade geradas da validação dos modelos 1 e 3.

Grupos	Modelo	Erro Padrão	CV %	Bias	R <sup>2</sup>
I	1	0,9654	9,1009	0,0000	0,9721
	3	3,7441	37,8894	-3,1776	0,9073
II	1	1,1826	11,2566	-0,0076	0,9556
	3	1,6377	16,6938	-0,0248	0,8813
III	1	0,9789	9,0497	0,0000	0,9860
	3	1,6737	17,4580	-0,0365	0,8888
IV	1	1,1309	9,6316	0,0000	0,9873
	3	1,7438	16,3783	-0,0203	0,9165
V	1	0,5608	5,7529	0,0000	0,9942
	3	2,7967	28,6907	-0,0888	0,8610
VI	1	0,2576	2,4154	0,0000	0,9834
	3	0,4873	4,9468	-0,0254	0,9001
VII	1	1,0020	9,0106	0,0000	0,9893
	3	1,5583	15,2146	-0,0157	0,9295

Os modelos matemáticos embora eficientes, quando comparados com as RNA possuem precisão inferior, pois as RNA apresentam melhor desempenho nas relações entre fatores biologicamente dependentes ou não (VAHEDI, 2017). Muitos autores relataram esta eficiência das RNA ao avaliar a dinâmica e crescimento em florestas naturais (ASHRAF et al., 2015; REIS et al., 2016; ROCHA et al., 2018).

As arquiteturas das melhores redes obtidas no processo de treinamento (Tabela 6) mostraram que apenas a RNA 1 obteve número diferente de neurônios entre as camadas. A arquitetura adequada da rede neural depende de inúmeras tentativas (SILVA, 2009). Para gerar resultados mais satisfatórios, esse processo é aleatório, ou seja, o número de neurônios por camadas não se baseia em critérios, apenas em tentativas.

Outro aspecto que diferenciou as arquiteturas foi a função de ativação. Enquanto as RNA 1 e 2 apresentaram função de ativação tangente, as RNA 3 e 4 foram compostas pelas funções logística e



exponencial, respectivamente. A função de ativação, também chamada de função de transferência, é uma função matemática que, aplicada à combinação linear entre as variáveis de entrada e pesos que chegam a determinado neurônio, retorna um valor de saída (CASTRO, 2014). O desempenho das RNA é mais eficiente por possibilitar a modelagem de relações lineares e não lineares existentes entre variáveis dependentes e independentes. No processamento das redes, não há necessidade de conhecimento prévio destas relações, uma vez que a estrutura das RNA é considerada maciça e paralelamente distribuída em camadas, com capacidade de aprendizado e generalização (BINOTI, 2012).

**Tabela 6:** Arquitetura das Redes Neurais Artificiais empregadas no treinamento para obtenção do DAP e H.

Rede	Tipo	Função de ativação	Número de neurônios		
			Camada 1	Camada 2	Camada 3
1	MLP	Tangente	7	12	2
2	MLP	Tangente	7	9	2
3	MLP	Logística	7	9	2
4	MLP	Exponencial	7	9	2

As redes do processo de treinamento geraram estatísticas de qualidade para o grupo de todas as espécies, por grupo ecológico e quanto à exigência por luz (Tabela 7). Ao fazer o comparativo do comportamento das RNA dos grupos, verificou-se que a RNA1 apresentou as melhores estimativas para a projeção da variável DAP dos Grupos I, IV e V. Em contrapartida, para a variável H, a RNA 4 apresentou as melhores estimativas para o Grupo I.

**Tabela 7:** Estatísticas de qualidade das quatro melhores Redes Neurais Artificiais obtidas a partir do treinamento.

Grupos	RNA	Variáveis de saída	Erro Padrão (S <sub>xy</sub> %)	CV (%)	Bias	R <sup>2</sup>
I	1	DAP	1,1045	9,9780	0,1011	0,9864
		H	1,5049	16,1923	-0,0630	0,9348
	2	DAP	1,1177	10,0974	0,1476	0,9862
		H	1,5099	16,2459	-0,0616	0,9344
	3	DAP	1,1369	10,2712	0,1760	0,9861
		H	1,5131	16,2798	-0,0728	0,9342
	4	DAP	1,1531	10,4176	0,1893	0,9854
		H	1,5018	16,1591	-0,0655	0,9348
II	1	DAP	0,9381	8,9433	-0,3159	0,9703
		H	1,1779	10,8526	-0,0789	0,9400
	2	DAP	0,8947	8,5299	-0,3092	0,9728
		H	1,1994	11,0506	-0,1005	0,9390
	3	DAP	0,8877	8,4630	-0,3054	0,9731
		H	1,1836	10,9052	-0,0664	0,9404
	4	DAP	0,8881	8,4670	-0,3217	0,9718
		H	1,1610	10,6969	-0,0900	0,9397
III	1	DAP	1,1001	10,6516	-0,3675	0,9754
		H	1,4174	17,3235	0,0479	0,8058
	2	DAP	1,0372	10,0432	-0,2504	0,9765
		H	1,4127	17,2664	0,0528	0,8065
	3	DAP	1,0307	9,9801	-0,0855	0,9760
		H	1,4917	18,2318	0,1187	0,7929
	4	DAP	1,0605	10,2679	-0,1303	0,9745
		H	1,4115	17,2507	0,0309	0,8040
IV	1	DAP	1,1327	10,5610	-0,5830	0,9929
		H	1,2275	13,4378	0,2328	0,9628
	2	DAP	0,8323	7,7602	-0,3272	0,9935
		H	1,2132	13,2817	0,1597	0,9622
	3	DAP	0,2995	3,0604	-0,0651	0,9926
		H	1,5735	16,0891	0,1038	0,9391
	4	DAP	0,8125	7,5750	-0,2402	0,9929
		H	1,2272	13,4350	0,2274	0,9638
V	1	DAP	1,0122	10,3056	-0,8960	0,9902
		H	1,6802	15,2646	0,5666	0,8761
2	DAP	0,8579	12,1417	-0,5331	0,9906	

	H	1,5376	15,1235	0,3721	0,9775
	DAP	0,5630	5,2494	-0,0551	0,9934
3	H	0,5675	6,5037	0,0944	0,9834
	DAP	0,8438	28,0006	-0,7295	0,9987
4	H	1,7202	34,1700	0,5883	0,9864
	DAP	0,3685	3,5371	0,1089	0,9699
	H	0,4970	6,0320	-0,4890	0,8823
	DAP	0,3643	3,4973	0,0681	0,9712
	H	0,5025	6,0990	-0,4302	0,8879
VI	DAP	0,3712	3,5637	0,0645	0,9708
	H	0,4965	6,0256	-0,4725	0,8776
	DAP	0,3637	3,4913	0,1700	0,9697
	H	0,5016	6,0876	-0,4969	0,8841
	DAP	0,4338	4,5653	0,2487	0,9902
	H	0,8729	9,9459	-0,1467	0,9353
	DAP	0,8235	8,6671	0,2043	0,9901
	H	1,4236	16,2216	-0,0850	0,9358
VII	DAP	0,8314	8,7500	0,3822	0,9896
	H	1,4200	16,1804	-0,0820	0,9358
	DAP	0,9375	9,8665	0,3910	0,9894
	H	1,4044	16,0021	-0,1201	0,9372

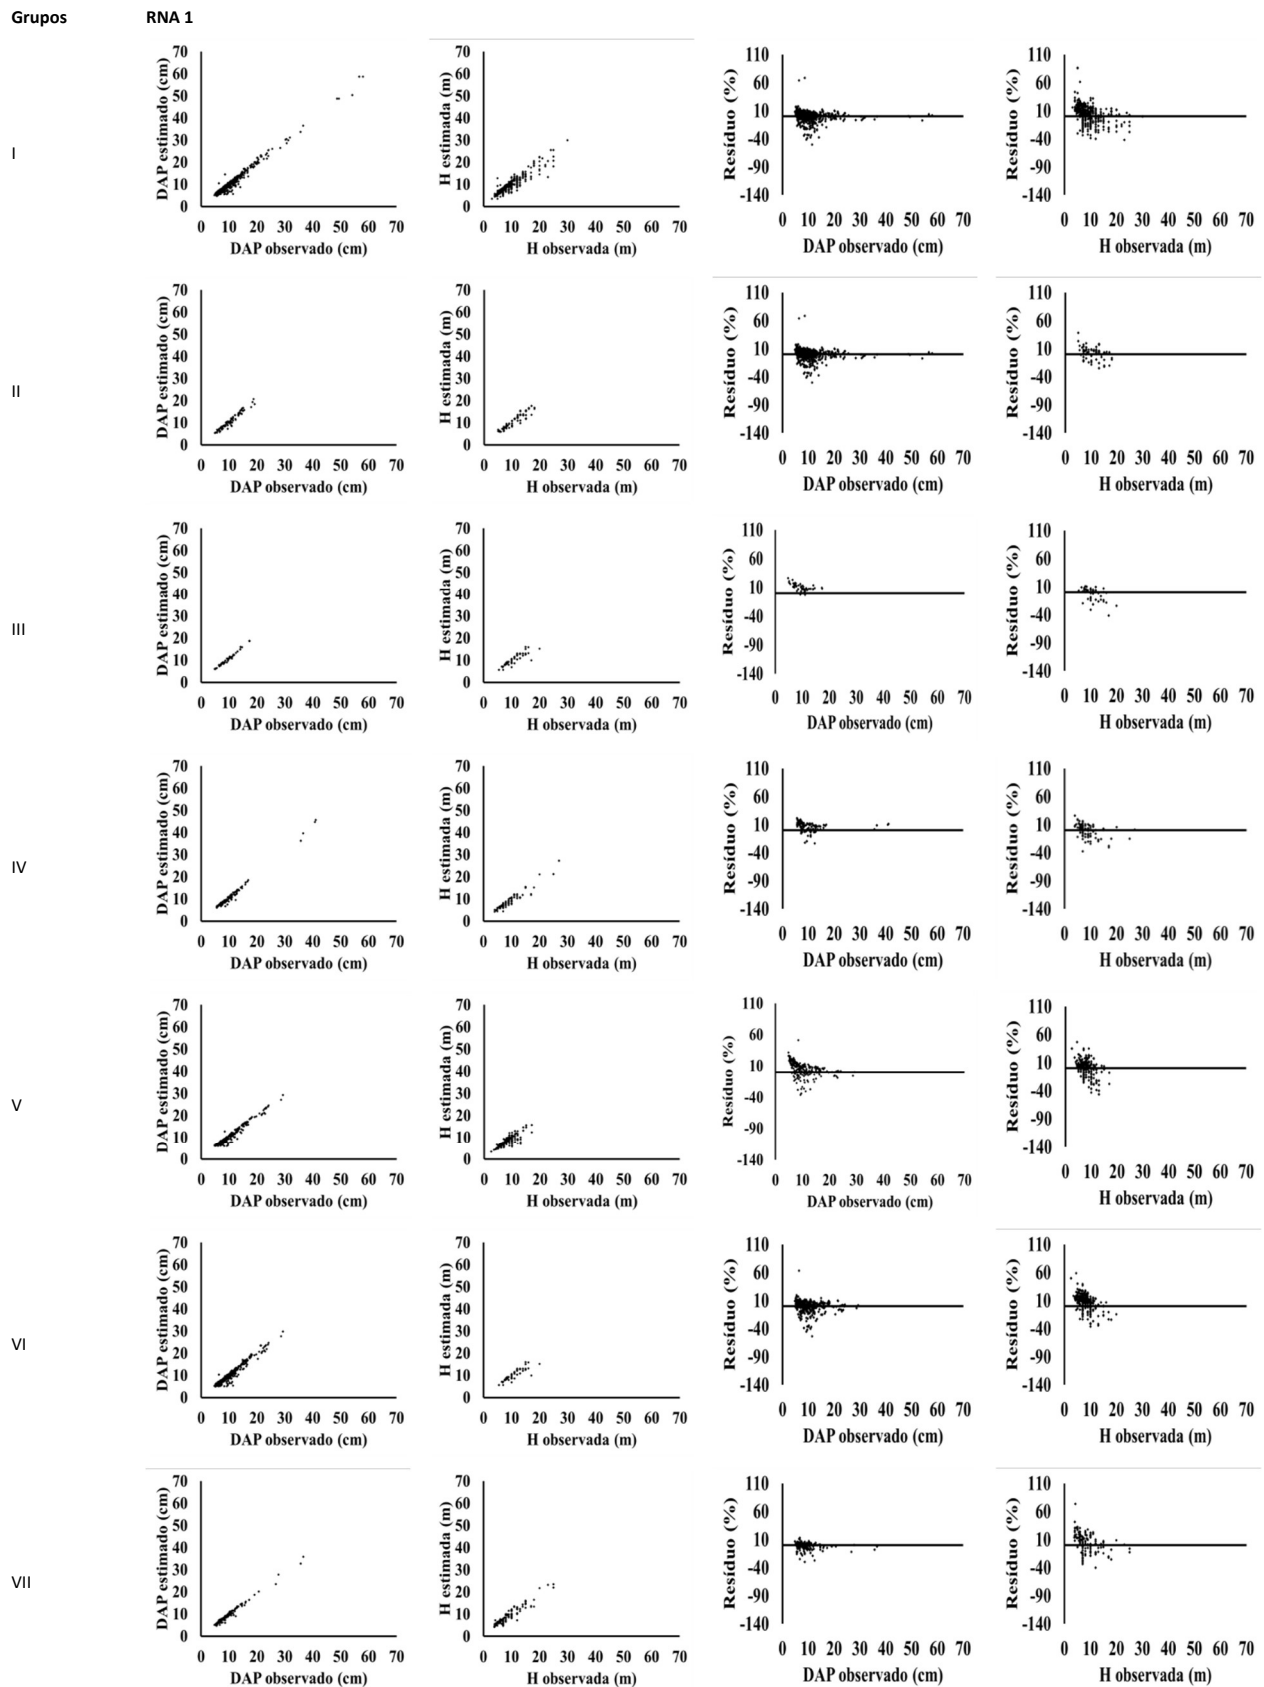
Para a variável DAP, os Grupos VI e VII apresentaram estatísticas de erro padrão e CV% mais satisfatórios que o Grupo I no processo de validação das RNA (Tabela 9). Ao analisar o R<sup>2</sup>, os Grupos IV, V e VII foram superiores ao Grupo I. Ao considerar a variável H, a estatística R<sup>2</sup> apresentou melhores resultados para os Grupos II, IV e VI. O grupo III forneceu melhores estatísticas de projeção das variáveis para os modelos tradicionais, enquanto os grupos V e VI apresentaram resultados superiores para a RNA 1 na projeção do DAP.

**Tabela 9:** Estatísticas de qualidade geradas da validação da melhor RNA.

Grupos		Erro Padrão	CV %	Bias	R <sup>2</sup>
I	DAP	1,1045	9,9780	0,1011	0,9864
	H	1,5049	16,1923	-0,0630	0,9348
II	DAP	0,9381	8,9433	-0,3159	0,9703
	H	1,1779	10,8526	-0,0789	0,9400
III	DAP	1,1001	10,6516	-0,3675	0,9754
	H	1,4174	17,3235	0,0479	0,8058
IV	DAP	1,1327	10,5610	-0,5830	0,9929
	H	1,2275	13,4378	0,2328	0,9628
V	DAP	1,0122	10,3056	-0,8960	0,9902
	H	1,6802	15,2646	0,5666	0,8761
VI	DAP	0,3685	3,5371	0,1089	0,9699
	H	0,4970	6,0320	-0,4890	0,8823
VII	DAP	0,4338	4,5653	0,2487	0,9902
	H	0,8729	9,9459	-0,1467	0,9353

Mesmo com a inserção da variável categórica “grupo ecológico” na camada de entrada no treinamento das redes, não houve diferenças abruptas quando a projeção foi realizada de forma generalizada ou de acordo a classificação por grupos. Não obstante aos modelos tradicionais, as estatísticas obtidas pelas RNA referentes às estimativas da variável H foram inferiores às encontradas para a variável DAP.

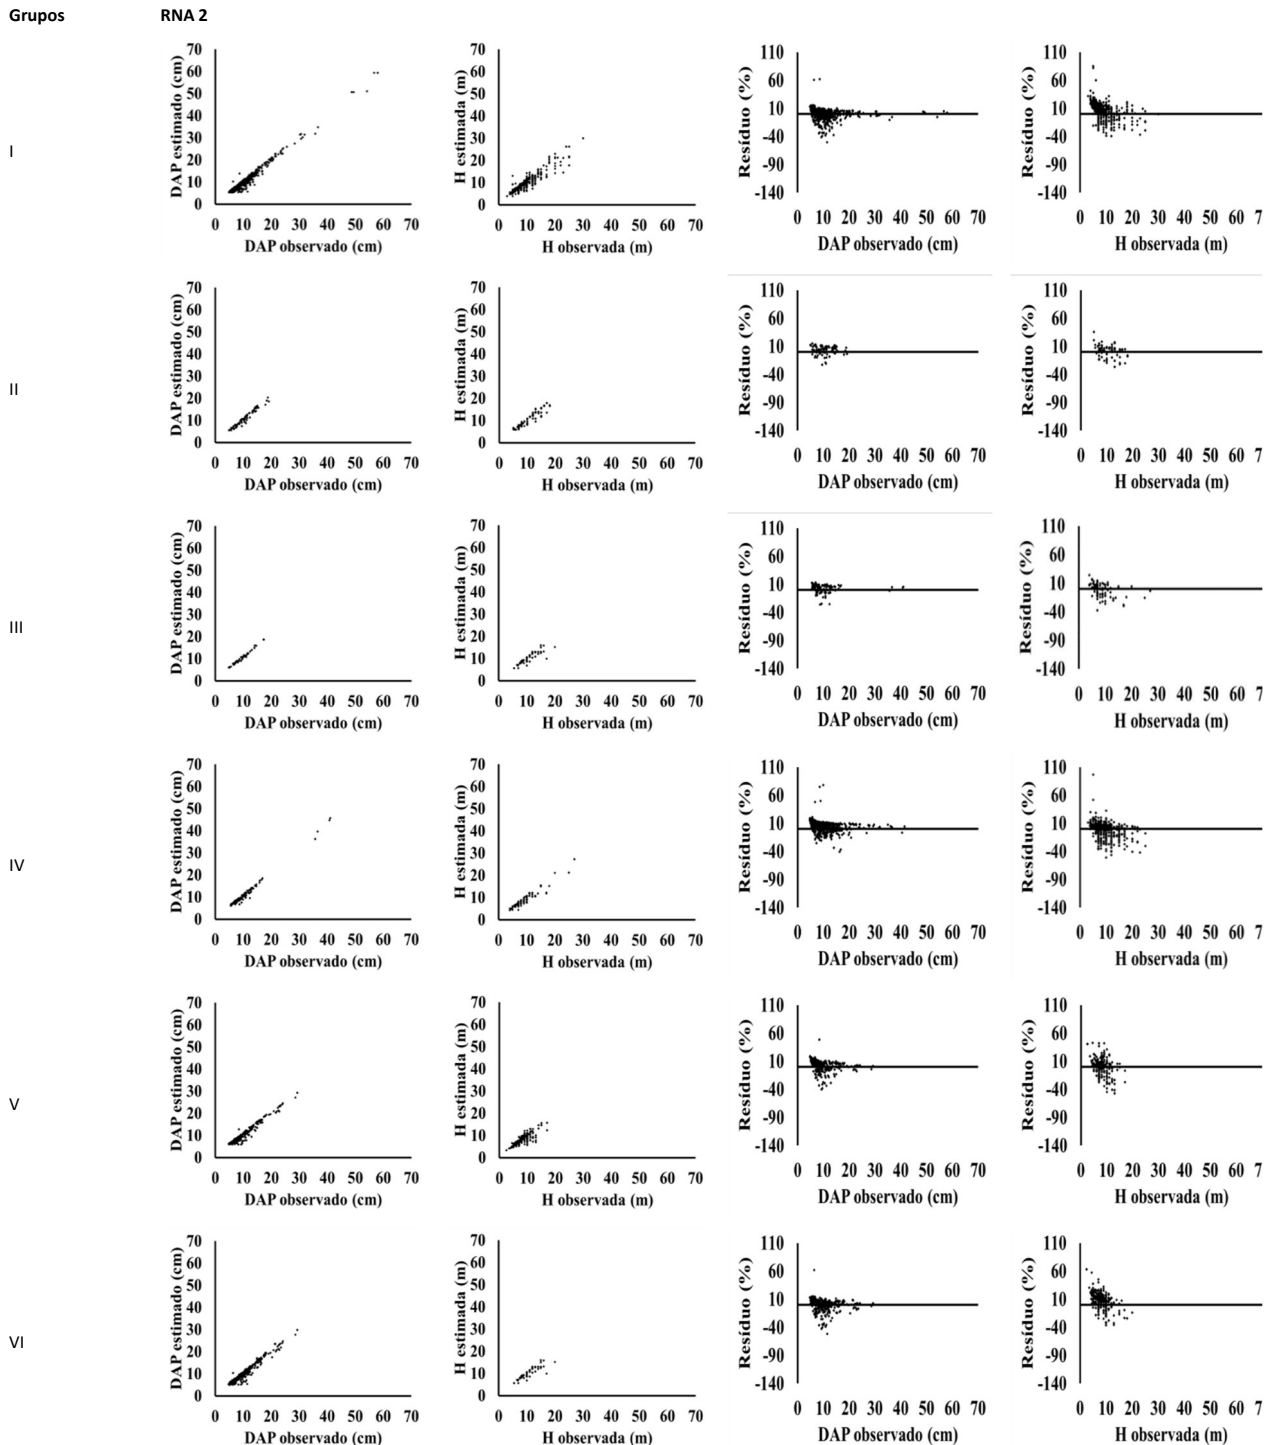
Para as técnicas de projeção empregadas, observou-se comportamento heterocedástico nos valores estimados em relação aos observados, bem como na dispersão dos resíduos (Figuras 2 e 3). A distribuição dos dados referentes à projeção das variáveis de DAP e H é consequência da diversidade de espécies característica de florestas naturais, que se apresentam como um ecossistema altamente complexo e surgem dificuldades para a obtenção de dados (GANDARA et al., 1998).




**Figura 2:** Gráficos da dispersão entre os valores observados e estimados e gráficos de resíduos nas estimativas de DAP e H da RNA1.

As estatísticas obtidas no processo de validação dos modelos tradicionais foram superiores às estatísticas geradas pela RNA1, com exceção do grupo I, cujas estatísticas foram mais satisfatórias quando

comparadas à primeira técnica. Seguindo o critério de classificação das espécies em grupos sucessionais, a partir da avaliação do comportamento das estatísticas constatou-se que a RNA1 é a melhor alternativa para a projeção do DAP e H para o crescimento florestal no período de cinco anos. Um dos motivos das RNA se mostrarem superiores aos modelos tradicionais de regressão é derivado das características ligadas à estrutura, bem como à distribuição paralela, celeridade no aprendizado e na habilidade de generalizar (LEAL et al., 2015).



VII

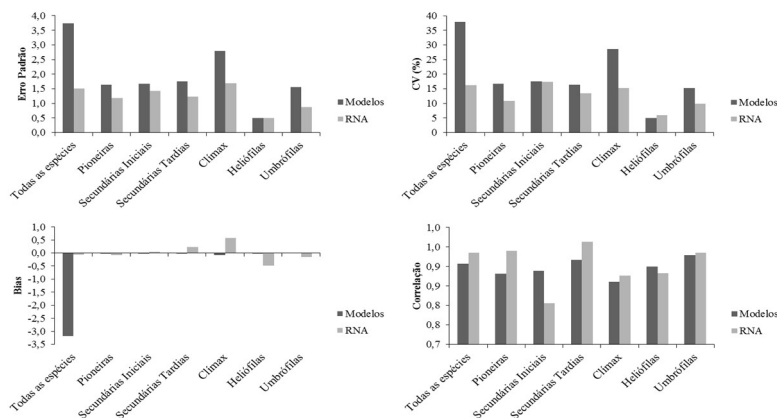


**Figura 3:** Gráficos da dispersão entre os valores observados e estimados e gráficos de resíduos nas estimativas de DAP e H da RNA2.

Uma importante característica das RNA no processo de validação é o emprego de dados distintos dos utilizados no processo de treinamento, fazendo com que a rede não fique enviesada. Outra característica é a praticidade de uso, uma vez que podem ser inseridas variáveis de entrada sem a necessidade de alterações na forma funcional do modelo. A inclusão dos índices de competição em redes neurais artificiais, visando avaliar o impacto da competição na classificação de mortalidade e sobrevivência de árvores em florestas naturais também foi aplicada por diversos autores (ALLEN et al., 2015; CAMINERO et al., 2018; McDOWELL et al., 2018). Ressalta-se que a avaliação da eficiência das RNA, assim como dos modelos tradicionais, não foi averiguada seguindo os critérios de classificação por grupos sucessionais e quanto à exigência por luz.

A comparação da projeção do crescimento em DAP e H no processo de validação, por meio das estatísticas de qualidade, indica que o emprego de RNA é superior aos modelos matemáticos tradicionais (Figura 4).

As metodologias foram adequadas para a projeção do crescimento, e a importância do emprego das redes neurais artificiais. Em alguns casos, pode substituir modelos hipsométricos com qualidade e eficiência (BINOTI, 2012). Face às vantagens da RNA como alternativa aos modelos de regressão, Haykin (2001) relatou que a ferramenta é adequada para solucionar problemas complexos e capaz de modelar uma gama de variáveis e suas relações não lineares, além da habilidade de aprender e generalizar, capacidade de modelagem com variáveis categóricas (qualitativas) e numéricas (quantitativas), de forma análoga à função neurológica.



**Figura 4:** Gráficos das estatísticas de qualidade para os modelos tradicionais de crescimento e RNA, ambos obtidos no processo de validação.

## CONCLUSÕES

A projeção do crescimento dendrométrico, principalmente para a variável diâmetro, foi mais eficaz quando analisado em grupos sucessionais. A projeção do crescimento em diâmetro e altura das árvores do fragmento de floresta semidecidual foi preciso pelas duas técnicas. Projetar o crescimento dendrométrico por RNA se mostrou mais eficiente.

## REFERÊNCIAS

- ALLEN, C. D.; BRESHEARS, D. D.; MCDOWELL, N. G.. On underestimation of global vulnerability to tree mortality and forest die-off from hotter drought in the Anthropocene. **Ecosphere**, v.6, p.1-55, 2015.
- ALMEIDA, F. S.; GOMES, D. S.; QUEIROZ, J. M.. Estratégias para a conservação da diversidade biológica em florestas fragmentadas. **Revista do Setor de Ciências Agrárias e Ambientais**, v.7, n.2, p.368-382, 2011. DOI: <https://doi.org/10.5777/ambiencia.2011.02.01rb>
- ARAUJO, L. S.; KOMONEN, A.; LOPES-ANDRADE C.. Influences of landscape structure on diversity of beetles associated with bracket fungi in Brazilian Atlantic Forest. **Biological Conservation**, v.191, p.659-666, 2015. DOI: <https://doi.org/10.1016/j.biocon.2015.08.026>
- BINOTI, D. H. B.. Redução dos custos em inventário de povoamentos equiâneos utilizando redes neurais artificiais. **Agrária**, v.8, p.125-129, 2012.
- BINOTI, M. L. M. 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.
- CAMINERO, L.; GÉNOVA, M.; CAMARERO, J. J.; SÁNCHEZ-SANGUERO, R.. Growth responses to climate and drought at the southernmost European limit of Mediterranean Pinus pinaster forests. **Dendrochronologia**, v.48, p.20-29, 2018.
- CAMPOS, J. C. C.; LEITE, H. G.. **Mensuração florestal: perguntas e respostas**. 5 ed. Viçosa: editora UFV, 2017.
- CASTRO, R.; SOARES, C.; LEITE, H.; SOUZA, A.; MARTINS, F.; NOGUEIRA, G.; OLIVEIRA, M.; SILVA, F.. Competição em nível de árvore individual em uma floresta estacional semidecidual. **Silva Lusitana**, p.43-66, 2014.
- CLUTTER, J. L.; FORTSON, J. C.; PIENAAR, L. V.; BRISTER, G. H.; BAILEY, R. L.. **Timber management: a quantitative approach**. New York: John Wiley & Sons, 1983.
- CORDEIRO, M. A.; PEREIRA, A. R. S.; BINOTI, D. H. B.; BINOTI, M. L. M. S.; LEITE, H. G.. Aplicação de redes neurais artificiais para quantificação volumétrica de árvores de eucalipto no estado do Amapá. **Revista de biologia e ciências da terra**, v.15, 2015.
- CUNHA, T. A.. **Crescimento de espécies florestais madeiráveis como subsídio para o manejo florestal na Amazônia Ocidental**. Tese (Doutorado em Engenharia Florestal) - Universidade Federal de Santa Maria, Santa Maria, 2013.
- CUNHA, T.; FINGER, C. A. G.; HASENAUER, H.. Tree basal area increment models for Cedrela, Amburana, Copaifera and Swietenia growing in the Amazon rain forests. **Forest Ecology and Management**, v.365, p.174-183, 2016.
- DIMOV, L. D.; CHAMBERS, J. L.; LOCKHART, B. R.. Five-year radial growth of red oaks in mixed bottomland hardwood stands. **Forest Ecology and Management**, v.255, p.2790-2800, 2008.
- Fundação SOS Mata Atlântica. **Desmatamento na Mata Atlântica cresce quase 30%**. 2020.
- GASPAR, R. O.. **Classificação de estágios sucessionais, estoque e crescimento em carbono de floresta estacional semidecidual, vale do rio doce, MG**. Tese (Doutorado em Ciência Florestal) - Universidade Federal de Viçosa, Viçosa, 2014.
- GLOVER G. R.; HOOL, J. N.. A basal area ratio predictor of loblolly pine plantation mortality. **Forest Science, Bethesda**, v.25, p.275-282, 1979.
- GORGENS, E. B.; LEITE, G. L.; GLERIANI, J. M.; SOARES, C. P. B.; CEOLIN, A.. Influência da arquitetura na estimativa de volume de árvores individuais por meio de redes neurais artificiais. **Revista Árvore**, v.38, n.2, p.289-295, 2014.
- HAYKIN S.. **Redes neurais: princípios e prática**. Porto Alegre: Bookman, 2001.
- HEATON J.. **Programming Neural Networks with Encog3 in Java**. 2 ed. St. Louis: Heat Research Incorporated, 2011.
- HUSCH, B.; MILLER, C. I.; BEERS, T. W.. **Forest Mensuration**. 3 ed. New York: John Wiley & Sons, 1982.
- GANDARA, F. B.; KAGEYAMA, P.. Indicadores de sustentabilidade de florestas naturais. **Série Técnica IPEF**, v.12, n.31, p.79-84, 1998.
- KAGEYAMA, P. Y.; GANDARA, F. B.. Recuperação de áreas ciliares. In: RODRIGUES, R. R.; LEITÃO-FILHO, H. F.. **Matas ciliares: conservação e recuperação**. São Paulo: Edusp, 2001.
- LEAL, F. A.; MIGUEL, E. P.; MATRICARDI, E. A. T.; PEREIRA, R. S.. Redes neurais artificiais na estimativa de volume em um plantio de eucalipto em função de fotografias hemisféricas e número de árvores. **Revista Brasileira de Biometria**, São Paulo, v.33, n.2, p.233-249, 2015.
- LINGNAU, C.; SILVA, M. N.; MACHADO, D. S. S.; LIMA, J. G. S.. Mensuração de alturas de árvores individuais a partir de dados laser terrestre. **Ambiência**, v.4, n.4, p.85-96, 2009.

LUSTOSA JUNIOR, I. M.; CASTRO, R. V. O.; GASPAR, R. O.; RIBEIRO, F. C.; ARAUJO, J. B. C. N.. Competition Indexes to Evaluate Tree Growth in a Semi-Deciduous Seasonal Forest. **Floresta e Ambiente**, v.26, p.1-12, 2019.

MCDOWELL, N.; ALLEN, C. D.; ANDERSON-TEIXEIRA, K.; BRANDO, P.; BRIENE, R.; CHAMBERS, J.; CHRISTOFFERSEN, B.; DAVIES, S.; DOUGHTY, C.; DUQUE, A.; ESPIRITO-SANTO, F.; FISHER, R.; FONTES, C. G.; GALBRAITH, D.; GOODSMAN, D.; GROSSIORD, C.; HARTMANN, H.; HOLM, J.; JOHNSON, D. J.; KASSIM, A. R.; KELLER, M.; KOVEN, C.; KUEPPERS, L.; KUMAGAI, T.; MALHI, Y.; MACMAHON, S. M.; MENCUCINI, M.; MEIR, P.; MOORCROFT, P.; MULLER-LANDAU, H. C.; PHILLIPS, O. L.; POWELL, T.; SIERRA, C. A.; SPERRY, J.; WARREN, J.; XU, C.; XU, X.. Drivers and mechanisms of tree mortality in moist tropical forests. **New Phytol**, v.1, p.1-9, 2018.

MCGILL, B. J.; ENQUIST, B. J.; WEIHER, E.; WESTOBY, M.. Rebuilding community ecology from functional traits. **Trends in Ecology and Evolution**, v.21, n.4, p.178-185, 2006. DOI: <https://doi.org/10.1016/j.tree.2006.02.002>

NASCIMENTO, R. G. M.; MACHADO, S. A.; FIGUEIREDO FILHO, A.; HIGUCHI, N.. Modelo de projeção por classe diamétrica para florestas nativas: enfoque na função probabilística de Weibull. **Pesq. Flor. Bras.**, Colombo, v.32, n.70, p.209-219, 2012.

PAULA, A.; SILVA, A. F.; MARCO JÚNIOR, P.; SANTOS, F. A. M.; SOUZA, A. L.. Sucessão ecológica da vegetação arbórea em uma floresta estacional semidecidual, Viçosa, MG, Brasil. **Revista Acta Botânica Brasileira**, v.18, n.3, p.407-423, 2004.

REIS, L. P.; SOUZA, A. L.; MAZZEI, L.; REIS, P. C. M.; LEITE, H. G.; SOARES, C. P. B.; TORRES, C. M. M. E.; SILVA, L. F.; RUSCHEL, A. R.. Prognosis on the diameter of individual trees on the eastern region of the amazon using artificial neural networks. **For. Ecol. Manag**, v.382, p.161-167, 2016.

ROCHA, S. J. S. S.. Artificial neural networks: Modeling tree survival and mortality in the Atlantic Forest biome in Brazil. **Science of the total environment**, Amsterdam, v.645, p.655-661, 2018.

ROITMAN, I.; VANCLAY, J. K.. Assessing size-class dynamics of a neotropical gallery forest with stationary models. **Ecological Modelling**, v.297, p.118-125, 2015.

SCHNEIDER, M. K.; LAW, R.; ILLIAN, J. B.. Quantification of neighborhood-dependent plant growth by Bayesian

hierarchical modelling. **Journal of Ecology**, v.94, p.310-321, 2006.

SERRANO, A. L.; GOLÇALVES, R. S.; GONÇALVES, A. O.. Avaliação do impacto de políticas públicas federais no processo de desmatamento na Amazônia. **Revista de Administração e Negócios da Amazônia**, v.5, n.1, p.1-19, 2013.

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

SOUZA, A. L.; ARAUJO, P. A.; CAMPOS, C. C.; NETO, F. P.. Dinâmica de crescimento em diâmetro de uma floresta primária sem interferência: uma análise pelo tempo de passagem entre classes diamétricas. **Revista Árvore**, v.17, n.2, p.2-16, 1993.

STATSOFT. **Statistica**: Data Analysis Software System. Version 8. 2008.

STEHMANN, J. R.; FORZZA, R. C.; SALINO, A.; SOBRAL, M.; COSTA, D. P.; KAMINO, L. H. Y.. **Plantas da Floresta Atlântica**, 2009.

STEPKA, T. F.; DIAS, N. A.; FIGUEIREDO FILHO, A.; MACHADO, S. A.; SAWCZUK, A. R.. Modelagem do incremento em diâmetro da Araucaria angustifolia em uma Floresta Ombrófila Mista no centro-sul do Paraná. **Floresta**, v.42, p.607-620, 2012.

VAHEDI, A. A.. Monitoring soil carbon pool in the Hyrcanian coastal plain forest of Iran: artificial neural network application in comparison with developing traditional models. **Catena**, v.152, p.182-189, 2017

VELOSO, H. P.; RANGEL FILHO, A. L. R.; LIMA, J. C. A.. **Classificação da vegetação brasileira, adaptada a um sistema universal**. Rio de Janeiro: IBGE, 1991.

ZANON, M. L. B.; FINGER, C. A. G.. Relação de variáveis meteorológicas com o crescimento das árvores de Araucaria angustifolia (Bertol.) Kuntze em povoamentos implantados. **Ciência Florestal**, v.20, n.3, p.467-476, 2010.

ZHAO, D.. Individual-tree diameter growth and mortality models for bottomland mixed-species hardwood stands in the lower Mississippi alluvial valley. **Forest Ecology and Management**, v.199, p.307-322, 2004.