

UNIVERSIDADE ESTADUAL DO SUDOESTE DA BAHIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS FLORESTAIS

**REDES NEURAS ARTIFICIAIS PARA ESTIMATIVA DE VOLUME DE  
ESPÉCIES DA CAATINGA ARBÓREA**

**SILVIO HENRIQUE MENEZES GOMES**

VITÓRIA DA CONQUISTA  
BAHIA - BRASIL  
ABRIL - 2017

**SILVIO HENRIQUE MENEZES GOMES**

**REDES NEURAS ARTIFICIAIS PARA ESTIMATIVA DE VOLUME DE  
ESPÉCIES DA CAATINGA ARBÓREA**

Dissertação apresentada à Universidade Estadual do Sudoeste da Bahia, como parte das exigências do Programa de Pós-Graduação em Ciências Florestais, para a obtenção do título de Mestre.

**Orientador: Prof. Christian Dias Cabacinha (UFMG/Montes Claros)**

VITÓRIA DA CONQUISTA  
BAHIA - BRASIL  
ABRIL - 2017

G617r Gomes, Silvio Henrique Menezes .  
Redes Neurais Artificiais para estimativa de volume de espécies da caatinga arbórea. / Silvio Henrique Menezes Gomes, 2017. 112f.  
Orientador (a): Dr. Christian Dias Cabacinha .  
Dissertação (mestrado) – Universidade Estadual do Sudoeste da Bahia, Programa de Pós-graduação em Ciências Florestais , Vitória da Conquista, 2017.  
Inclui referências. 103 - 106.  
1. Caatinga arbórea – Estado da Bahia. 2. Redes Neurais artificiais – RNA. 3. Computação evolutiva. 4. Inteligência artificial I. Cabacinha, Christian Dias . II. Universidade Estadual do Sudoeste da Bahia, Programa de Pós- Graduação Ciências Florestais. III. T.

CDD: 634.97354

*Catálogo na fonte:* Juliana Teixeira de Assunção – CRB 5/1890  
UESB – Campus Vitória da Conquista - BA

**SILVIO HENRIQUE MENEZES GOMES**

**REDES NEURAIS ARTIFICIAIS PARA ESTIMATIVA DE VOLUME DE  
ESPÉCIES DA CAATINGA ARBÓREA**

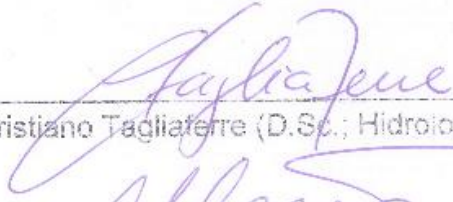
Dissertação apresentada à Universidade Estadual do Sudoeste da Bahia, como parte das exigências do Programa de Pós-Graduação em Ciências Florestais, para a obtenção do título de Mestre.

Aprovada em 4 de abril de 2017.


Comissão Examinadora:



Prof. Carlos Alberto Araújo Júnior (D.Sc., Ciências Florestais) – UFMG



Prof. Cristiano Tagliaferre (D.Sc., Hidrologia Florestal e Manejo de Água) – UESB



Prof. Alessandro de Paula (D.Sc., Ecologia e Recursos Naturais) – UESB  
Coorientador



Prof. Christian Dias Cabacinha (D.Sc., Ciências Ambientais) – UFMG  
Orientador

Dedico este trabalho aos meus pais, queridos  
irmãos e sobrinha, pelo carinho.

Aos eternos amigos.

*“Ser aquele eterno menino que carregava água na peneira. Que se entusiasma mais com o vazio do que com o cheio. E, diariamente, aprende a dar flor em cada pedra no caminho.”*

## AGRADECIMENTOS

À UESB, pela concessão da bolsa de estudos durante todo o processo de construção deste trabalho, bem como o suporte estrutural que foi imprescindível para a concretização deste documento. À UFMG, pela estrutura laboratorial que foi decisiva para todo o processamento dos dados, além de seu corpo docente.

Agradeço aos meus pais, João José e Ângela Maria, em especial à minha mãe, a qual estimo como minha maior mentora e exemplo a ser seguido. Às minhas irmãs, Giselle e Nalini, pelas palavras de conforto, paciência e aquela mãozinha, mesmo distante. À minha sobrinha Dalila. Um obrigado de coração aos demais familiares “Menezes”, em destaque à minha tia Ana Maria por sempre acreditar no meu potencial.

Ao orientador Dr. Christian Cabacinha, pelo seu conhecimento profissional e acadêmico repassados sublimemente, pelos conselhos, pela vivência e o acolhimento de braços abertos durante esses dois anos. Ao professor Dr. Carlos Araújo, por toda atenção despendida e pelas sugestões que foram de grande importância na execução deste trabalho. Aos Drs. Alessandro de Paula e Cristiano Tagliaferre, por terem participado da banca e pela contribuição para o enriquecimento do documento.

A todos aqueles que viveram as expedições na FLONA (Contendas do Sincorá) e se debruçaram, mesmo que por poucos dias, aos trabalhos de campo na Caatinga: Aline, Vanessa, Mariana, Alana Katiussya, Flávia, Rômulo, Kelly (UFMG), Carmela, Priscila, Paulo Monroe e Walleska. Ao Inkamauta, pela inestimável contribuição na identificação das espécies, e Willyam Charles, pelos trabalhos que subsidiaram esta dissertação. Ao pessoal do ICMbio, brigadistas e demais funcionários da FLONA, em especial a Plínio, pelo total suporte. À Prof.<sup>a</sup> Dr.<sup>a</sup> Patrícia, pelas orientações fornecidas às viagens a campo.

Aos colegas da querida Conquista durante toda a etapa do mestrado: Marcos, Saad, Danúsia, Juliana e Danilo, Milena e Paulo Gabriel. A Juliano e Marcel, os melhores *homemates* que alguém poderia conviver, e à Tereza. À Maida, pela parceria na “princesinha do norte” mineiro e pelos trabalhos em conjunto na UFMG.

Aos amigos de Aracaju, pelo carinho e amizade, em especial à Leila, Livia e Francineide, por sempre acreditarem em mim, além das sábias palavras ditas nos momentos certos. À Bruna Pligher, pelos melhores momentos que alguém poderia

desejar, tornando-se uma grande amiga, companheira, conselheira e conquistando minha admiração em tão pouco tempo. À Karen Villanova, pelo suporte nos minutos finais.

A todos aqueles que realmente acreditam naquilo que fazem para mudar positivamente a vida das pessoas, seja pela ciência ou qualquer outro meio. Um forte abraço.



## SUMÁRIO

1. INTRODUÇÃO GERAL .....	1
2. REVISÃO DE LITERATURA .....	4
2.1. Volumetria de espécies nativas .....	4
2.2. Volumetria de espécies da Caatinga .....	8
2.3. Redes Neurais Artificiais (RNA) .....	9
2.3.1. Aspectos gerais .....	9
2.3.2. Tipos de RNA .....	10
2.3.3. Redes <i>Multilayer Perceptron</i> (MLP) .....	10
2.3.3.1. <i>Resilient propagation</i> (Rprop) .....	12
2.3.3.2. Redes com <i>Skip-layer connections</i> .....	14
2.3.3.3. <i>Neuroevolution of Augmenting Topologies</i> (NEAT) .....	15
2.3.4. <i>Radial Basis Function</i> (RBF) .....	18
2.3.5. Redes neurais artificiais em pesquisas florestais .....	19
3. REFERÊNCIAS .....	23
CAPÍTULO 1 .....	30
PARAMETRIZAÇÃO DE REDES NEURAS PARA ESTIMATIVA DE VOLUME EM CAATINGA ARBÓREA .....	30
RESUMO .....	30
1. INTRODUÇÃO .....	31
2. MATERIAL E MÉTODOS .....	34
2.1. Caracterização da área .....	34
2.2. Área amostral e critérios de inclusão .....	35
2.3. Critérios para cubagem .....	36
2.4. Base de dados .....	36
2.5. Redes Neurais Artificiais .....	37
2.6. Critérios estatísticos para avaliação do desempenho das RNA .....	39
3. RESULTADOS E DISCUSSÃO .....	40
4. CONCLUSÕES .....	61
5. REFERÊNCIAS .....	62
CAPÍTULO 2 .....	65
ACURÁCIA DA ESTIMATIVA DE VOLUME COMERCIAL DE ESPÉCIES DA CAATINGA ARBÓREA ARBUSTIVA COM RNA .....	65
RESUMO .....	65
1. INTRODUÇÃO .....	67
2. MATERIAL E MÉTODOS .....	69
2.1. Caracterização da área .....	69

<b>2.2. Área amostral e critérios de inclusão .....</b>	<b>70</b>
<b>2.3. Critérios para cubagem.....</b>	<b>71</b>
<b>2.4. Base de dados .....</b>	<b>71</b>
<b>2.5. Equações de volume .....</b>	<b>73</b>
<b>2.6. Redes evolutivas com <i>Neuroevolution of Augmenting Topologies (NEAT)</i>....</b>	<b>74</b>
<b>2.7. Critérios estatísticos para avaliação do desempenho das técnicas .....</b>	<b>75</b>
<b>2.7.1. Teste da falta de ajuste (<i>lack-of-fit</i>).....</b>	<b>76</b>
<b>2.7.2. Avaliação da acurácia das estimativas de volume obtidas pelo teste de identidade entre diferentes métodos e teste F de Graybill.....</b>	<b>78</b>
<b>3. RESULTADOS E DISCUSSÃO .....</b>	<b>80</b>
<b>3.1. Avaliação dos modelos de volume .....</b>	<b>80</b>
<b>3.2. Redes evolutivas e modelos de regressão para estimativa de volume .....</b>	<b>90</b>
<b>4. CONCLUSÕES .....</b>	<b>102</b>
<b>5. REFERÊNCIAS .....</b>	<b>103</b>
<b>CONCLUSÕES GERAIS .....</b>	<b>107</b>
<b>APÊNDICE.....</b>	<b>109</b>

## RESUMO

GOMES, Silvio Henrique Menezes, M.Sc., Universidade Estadual do Sudoeste da Bahia, abril de 2017. **Redes Neurais Artificiais para estimativa de volume de espécies da Caatinga arbórea.** Orientador: Christian Dias Cabacinha. Coorientador: Alessandro de Paula.

A quantificação do estoque volumétrico das vegetações naturais em nosso país é uma das principais atividades que contemplam qualquer procedimento amostral nos inventários. Nesse sentido, são utilizadas técnicas de regressão e outras tecnologias baseadas nos conceitos de inteligência artificial para subsidiar a elaboração dos planos de manejo. Assim, o presente trabalho teve como objetivo geral avaliar o desempenho de dois tipos de redes (*Multilayer Perceptron* e *Radial Basis Function*) quanto às estimativas de volume comercial para espécies da Caatinga arbórea no estado da Bahia. Para isso, foi realizado o processo de parametrização de todos os tipos para escolha da melhor rede e, assim, comparar as estimativas aos modelos de regressão. Para as *Multilayer*, foram avaliados os algoritmos *Resilient propagation (Rprop+)*, *Skip-layer connections*, *Neuroevolution of Augmenting Topologies (NEAT)* e redes do tipo *Radial Basis Function (RBF)*. Foram utilizados dados de cubagem de 300 árvores da Caatinga arbórea, dos quais 70% para treinamento e 30% para validação. Considerou-se seis combinações das variáveis diâmetro a 1,3 m (*DAP*), diâmetro a 0,3 m (*DAS*) e altura total (*HT*), cinco funções de ativação e diferentes números de ciclos. Para validar o desempenho das redes, os critérios estatísticos adotados foram a Raiz do Erro Quadrático Médio (RMSE%), a correlação linear entre o volume estimado e o observado ( $r_{yy'}$ %) e seu gráfico, além do histograma de frequência dos erros percentuais. Para os modelos volumétricos, foram adotados os mesmos critérios estatísticos, além do teste da falta de ajuste do modelo (*lack-of-fit*), o *Akaike Information Criterion (AIC)*, avaliação da acurácia das técnicas pelo teste de identidade entre diferentes métodos e F de Graybill. Nesse sentido, o *Rprop+* não obteve convergência ao utilizar as funções de ativação sigmoide e softmax. Os algoritmos *Rprop+* e *Skip-layer* obtiveram igual estabilidade de ciclos para melhor desempenho tanto na etapa de treinamento quanto na validação (a partir de 100 ciclos), diferentemente do NEAT (a partir de 1000 ciclos) e redes RBF (a partir de 500 ciclos). Observou-se que o algoritmo NEAT, com 1.000

indivíduos e densidade 0,1, apresentou o melhor desempenho dentre os algoritmos testados devido ao seu caráter dinâmico e por não possuir topologias fixas. Este foi o que obteve as melhores estimativas em comparação ao modelo de regressão de Schumacher & Hall (log), utilizando-se apenas a variável *DAP*. A variável *DAS*, trabalhada isoladamente, conferiu as piores estimativas às RNA treinadas. Portanto, redes *Multilayer* com o algoritmo NEAT devem ser utilizadas para estimar o volume comercial desta fitofisionomia.

**Palavras-chave:** parametrização, inteligência artificial, regressão, computação evolutiva.

## ABSTRACT

GOMES, Silvio Henrique Menezes, M.Sc., Universidade Estadual do Sudoeste da Bahia, april of 2017. **Artificial Neural Network to volume estimative of Caatinga tree species.** Adviser: Christian Dias Cabacinha. Co-Adviser: Alessandro de Paula.

The quantification of the volumetric stock of natural vegetation in our country is one of the main activities that contemplate any sample procedure in inventories. In this sense, regression techniques and other technologies based on the concepts of artificial intelligence are used to carry the elaboration of handling principles. The objective of this study was to evaluate the performance of two types of networks (Multilayer Perceptron and Radial Basis Function) in relation to commercial volume estimates for arboreal *Caatinga* species in the state of Bahia (Brazil). For this, a parameterization process of all types was carried out in order to select the best network and, thus, to compare to the regression models. The algorithms Resilient propagation (Rprop+), Skip-layer connections, Neuroevolution of Augmenting Topologies (NEAT) and Radial Basis Function (RBF) networks were evaluated. Data from 300 arboreal *Caatinga* trees were used: 70% for training and 30% for validation. Six combinations of the diameter variables at 1.3 m (DBH), diameter at 0.3 m (DSH) and total height (HT), five activation functions and different cycle numbers were considered. In order to validate the performance of the networks, the statistical criteria adopted were the Root Mean Square Error (RMSE%), the linear correlation between the estimated and observed volume ( $r_{yy}'\%$ ) and its graph as well as the percentage error frequency histogram. For the volumetric models, the same statistical criteria was adopted, in addition to the lack-of-fit test, the Akaike Information Criterion (AIC) and the accuracy of the techniques by the test of identity and Graybill's methods. In this sense, Rprop+ did not achieve convergence when using the functions of sigmoid and softmax activation. The Rprop+ and Skip-layer algorithms have the same cycle stability for better performance in both the training and the validation stages (from 100 cycles), unlike NEAT (from 1000 cycles) and RBF networks (from 500 cycles). It was observed that the NEAT algorithm, with 1,000 individuals and density 0.1, presented the best performance among the algorithms tested because of its dynamic character and because it does not have fixed topologies. The aforementioned algorithm was the one which obtained the best

estimates in comparison to the regression model of Schumacher & Hall (log), using the DBH variable only. The DSH variable when processed individually provided the worst estimates to trained RNA. Therefore, the NEAT algorithm should be used for this phyto-physiognomy.

**Keywords:** Parameterization, artificial intelligence, regression, evolutionary computation.

## 1. INTRODUÇÃO GERAL

A Caatinga apresenta uma área de 844.453 km<sup>2</sup>, correspondente a 10% do território nacional (SFB, 2013). Na Bahia, esta tipologia compreende faixas denominadas de agreste, também chamada de “mata de cipó”, que é uma zona de transição das vegetações encontradas a oeste, com manchas mais alongadas, onde as florestas são expressivas e os interiores mais secos (PRADO, 2003). Nesse sentido, a Caatinga arbórea, que é uma subdivisão deste bioma (RIZZINI, 1997), contém diversas espécies de interesse econômico, medicinal, para alimentação humana e animal, além da utilização de sua madeira para serraria e carvão, a exemplo da *Jatropha molíssima* (Pohl) Baill. (Pinhão), a *Ziziphus joazeiro* Mart. (Juazeiro) e *Myracrodruon urundeuva* Allemão (Aroeira), comumente destacadas em planos de manejo na região (IBAMA, 2006).

Para que tais planos sejam executados, é necessário considerar um conjunto de dados acerca da área florestal, tal como o volume de madeira, que é majoritário quando há necessidade de supressão dos indivíduos arbóreos para valoração e quantificação do que será explorado (SANQUETTA et al., 2014). Como cada fitogeografia contém elementos intrínsecos ao seu local de origem, é primordial obter informações a respeito do volume real que traduzam as variações das fitofisionomias daquele local para estimativas desta variável. Nesse caso, para cada tipo de situação aplicada se faz necessário gerar equações de volume ajustadas que abranjam essas variações, o que dificulta obter a estimativa mais próxima do estoque em volume na área, comprometendo o planejamento e uso futuro dos seus recursos.

Apesar do bom desempenho das equações para estas estimativas, os modelos volumétricos encontrados na literatura nem sempre conseguem explicar o comportamento do volume em florestas inequiâneas devido à alta variabilidade destas florestas (REZENDE et al., 2006). Assim, outras ferramentas têm sido utilizadas para sua quantificação com o objetivo de obter valores mais confiáveis e que expliquem com maior fidelidade sua heterogeneidade, a exemplo das Redes Neurais Artificiais (RNA).

As RNA são sistemas complexos e paralelos que tentam, através da entrada de dados, detectar padrões e funcionar similarmente a um cérebro humano. São

capazes de fazer interpolações e extrapolações de forma linear e não linear daquilo que aprenderam inicialmente, gerar cenários distintos em diferentes arquiteturas, com o uso de variados algoritmos, e do número de ligações entre os neurônios (HAYKIN, 2001; BRAGA et al., 2014), através do uso de variáveis de entrada e saída comuns no ramo florestal. O tipo de rede mais usual é a *Multilayer Perceptron* (BINOTI, 2010; BINOTI et al., 2013; 2014).

O uso das RNA para o manejo de florestas teve seu início no final da década de 1980 (COULSON et al., 1987), mas tem demonstrado resultados factíveis nos trabalhos comparativos sobre sua eficácia em relação aos modelos volumétricos tradicionais em plantios de florestas equiâneas nos tempos atuais. Nesse sentido, as redes se apresentaram como ferramenta mais precisa na estimativa do volume real em diferentes cenários e arquiteturas utilizadas (GORGENS et al., 2009; BINOTI, 2010; BINOTI et al., 2014).

Como a estimativa de volume em florestas nativas exige um grande volume de dados de cubagem para uma maior precisão nas estimativas, devido à sua alta heterogeneidade, as RNA são importantes por captarem com maior dinamismo as variações entre as espécies, de forma a desenvolver mecanismos para a resolução de problemas mais complexos, principalmente quando há necessidade de inclusão de outras variáveis associadas às já convencionais, a exemplo das variáveis categóricas. Outro aspecto é que elas dão maior subsídio na tomada de decisões e podem participar como elemento fundamental no manejo, com maior aproveitamento dos recursos para restabelecimento de forma sustentável da floresta (CASTELLANOS et al., 2007).

Com espécies nativas, apesar do menor número de trabalhos publicados, as RNA obtiveram melhor desempenho que as equações volumétricas convencionais em florestas inequiâneas no Pará (RODRIGUES et al., 2010) e em Minas Gerais (FRANCO, 2012). Na Caatinga, as RNA já demonstraram maior eficiência em comparação às equações de volume (LIMA, 2014), e o uso de variáveis categóricas, como classe de diâmetro, pode ser fundamental para uma maior acurácia nas estimativas em diversas fitofisionomias (ARAÚJO et al., 2015).

Apesar de resultados satisfatórios quanto ao seu uso em nativas, estas redes apresentam um caráter empírico predominante e com topologias fixas, o que exige do manejador um conhecimento prévio maior a respeito do problema a ser resolvido.



Nesse sentido, outros algoritmos com vias de codificação diferenciadas foram desenvolvidos com a premissa de resolver a problemática da rigidez das redes mais usuais, por exemplo, as redes treinadas com *Skip-layer connections* e *Neuroevolution of Augmenting Topologies* (NEAT). Estes algoritmos exigem, em partes, a obrigatoriedade do conhecimento profundo sobre o problema ao qual a rede deverá solucionar, e elaboram, de forma dinâmica, arquiteturas fundamentais a depender do caráter das informações inseridas (STANLEY e MIKKULAINEN, 2002) ou podem possuir vias alternativas para a resolução do problema ao inserir conexões diferenciadas que se ligam diretamente à camada de saída (RIPPLEY, 1996; VELTEN, 2009). No entanto, apesar do aspecto livre desses algoritmos, eles necessitam de parametrizações prévias quanto às configurações iniciais às quais a rede deverá iniciar.

Portanto, este trabalho teve como objetivo geral avaliar o desempenho de dois tipos de redes quanto às estimativas de volume comercial para espécies da Caatinga arbórea no estado da Bahia. No primeiro capítulo, objetivou-se parametrizar dois tipos de redes quanto à melhor configuração inicial, a qual deverá ser adotada como ponto de partida para o segundo capítulo. Esse, por sua vez, avaliou o desempenho do melhor algoritmo escolhido através da etapa de parametrização e comparou as estimativas de volume realizadas com a melhor rede neural e o melhor modelo de regressão ajustado para estimativa de volume.

## 2. REVISÃO DE LITERATURA

### 2.1. Volumetria de espécies nativas

No Brasil, a volumetria para espécies nativas ainda é escassa, principalmente pela vasta diversidade e variabilidade genética da flora brasileira e devido também às variações topográficas do território nacional. Quando há, essas informações são pouco divulgadas em alguns estados (COLPINI et al., 2009; SANTOS et al., 2012), como na Bahia, especialmente.

Existem várias formas para a obtenção do volume, a exemplo dos métodos de cubagem absolutos e relativos, sendo estes os mais usuais, como também pela técnica por deslocamento da água através da construção de xilômetros (MACHADO et al., 2006). Estes dados são utilizados para o ajuste de equações para um grupo de espécies com características similares, o que é convencionado, ou para algumas espécies importantes, a depender do interesse em termos de planos de manejo, baseado no objetivo econômico proposto (SCOLFORO et al., 2008; SANQUETTA et al., 2011; SOARES et al., 2011a; SANTOS et al., 2012).

A obtenção do volume da árvore consiste em uma das fases nos inventários florestais e deve ser realizado seguindo-se alguns critérios, como: a definição do diâmetro mínimo de inclusão e a primeira seção na qual o processo de cubagem será iniciado. Para florestas nativas são sugeridos intervalos de medição das seções de 0,30; 0,70; 1,30; 2,00 e, posteriormente, de metro em metro até o ápice da árvore, geralmente com medições iniciadas acima de 0,1 m do solo (SCOLFORO et al., 1994; SOARES et al., 2011a)

Entretanto, o comprimento das seções pode diminuir a depender das características dendrométricas do bioma, a exemplo do trabalho de Alves Júnior (2010) com espécies da Caatinga, atribuindo intervalos de 0,30; 0,50; 0,70; 0,90; 1,10; 1,30; 1,50; 1,70; 2,30 m, e de metro em metro até o final da árvore. Miranda et al. (2013) sugeriram ainda que, ao atribuir o método de Smalian como base comparativa para o volume real em nativas e obter assim uma maior exatidão, as seções das toras devem apresentar comprimentos curtos, compreendidos entre 20 e 30 cm.

No momento da cubagem devem ser definidos, em termos de planejamento, seus componentes, como: a inclusão de galhos, a determinação da altura comercial do fuste, diâmetro mínimo de inclusão, sua distribuição diamétrica e, por fim, a forma do tronco para o uso de modelos, fórmulas empíricas ou de *taper* (CAMPOS e LEITE, 2009; SOARES et al., 2011a).

O fuste da árvore não apresenta a forma de um cilindro perfeito, que seria a estrutura ideal exigida em grande parte dos subprodutos da madeira. Assim, as formas convencionais do fuste podem apresentar características distintas, o que interfere na escolha do melhor método absoluto de cubagem, através das fórmulas propostas por Huber, Newton e Smalian para o cálculo de volume (MACHADO et al., 2006; SOARES et al., 2011a; MIRANDA et al., 2013), sendo esta última mais aplicada em estudos com espécies nativas (SCOLFORO et al., 1994; EISFELD et al., 2008; THAINES et al., 2010; SANTOS et al., 2012) e mais utilizada também devido à praticidade operacional na coleta dos dados em campo (CABACINHA, 2003; SOARES et al., 2011a).

Miranda et al. (2013), comparando os métodos de cubagem absolutos para a espécie *Mezilaurus itauba*, em sessões menores e maiores, observaram que os três métodos de cubagem avaliados (Smalian, Huber e Newton) comparados com a testemunha (Smalian com seções curtas de 20 a 30 cm) não diferiram estatisticamente. Os mesmos autores inferiram que o método de Smalian apresentou uma leve tendência à superestimação do volume conforme os comprimentos das toras aumentavam e sugeriu o método de Huber como mais prático em campo. Machado et al. (2006), comparando três métodos de cubagem contra o xilômetro, observou que o método de Smalian apresentou as piores estimativas de volume e que o método de Huber, foi o que apresentou o melhor resultado na estimativa de volume na base do fuste e que diferentes comprimentos das seções não alteram os volumes nas diferentes classes de diâmetro.

Antes de qualquer planejamento em termos de mensuração do volume em florestas inequiâneas, deve-se adotar um critério de amostragem que represente com fidelidade a população estudada. A amostra deve apresentar características comuns que representem a fitofisionomia, com maior cuidado quando esta é largamente heterogênea (PÉLLICO NETTO e BRENNNA, 1997; SOARES et al., 2011a). Nesse caso, alguns autores enfatizaram a necessidade de selecionar

indivíduos por classes diamétricas, a fim de incluir um número representativo de árvores cubadas para uma melhor amplitude do volume no ajuste do modelo (SCOLFORO et al., 2008; COLPINI et al., 2009; SANTOS et al., 2012).

Segundo Campos e Leite (2009), os valores coletados das árvores devem levar em consideração todas as classes de diâmetro (a 1,3 m do solo) a partir de um diâmetro de inclusão mínimo e, preferencialmente, uma mesma frequência por classe através de uma amplitude estabelecida. Colpini et al. (2009), avaliando modelos de volume em floresta ombrófila no Mato Grosso, considerou uma amplitude de classe de 10 cm, sendo que a escolha das árvores foi atribuída de forma aleatória e observou que cada árvore da amostra deveria estar representada na diagonal de todas as classes de diâmetro. Esta mesma amplitude de classe foi utilizada por Barros e Silva Júnior (2009), em floresta tropical densa, no Pará. Já para Santos et al. (2012), em estudo com *Ocotea porosa*, foram utilizadas sete classes definidas em função da média e do desvio padrão dos diâmetros. Já para florestas em estágio inicial ou secundário de regeneração, recomenda-se uma amplitude de classe de 5 cm (SOUZA e SOARES, 2013).

A determinação do volume para uma espécie ou para um grupo delas, sítio ou região, é importante para a estimativa precisa da capacidade volumétrica de uma floresta (ROLIM et al., 2006; EISFELD et al., 2008; RUFINI et al., 2010). Através desses dados são utilizadas equações para o planejamento, já que cumpre o papel de estimador de sua capacidade produtiva, sobretudo para o uso correto dos recursos naturais em se tratando de manejo florestal, principalmente quando o recurso utilizado advém de espécies nativas (SCOLFORO et al., 1994; SANTOS et al., 2012). Entretanto, são necessários estudos localizados para determinar o melhor modelo para um determinado sítio ou generalizado para uma determinada região (SCOLFORO et al., 1994; ROLIM et al., 2006).

Apesar da importância do uso de equações de volume para estimativas mais precisas da quantificação em termos produtivos em florestas inequiâneas, o uso do fator de forma é preponderante devido à escassez de informações para algumas espécies de interesse econômico (FIGUEIREDO et al., 2009). No país, o uso desses fatores é determinado pelas redes de manejo instaladas em cada região, com o objetivo de monitorar a dinâmica das florestas naturais, fomentar o intercâmbio de informações entre redes e direcionar os estudos referentes à formulação de planos

de manejo para cada especificidade dos biomas (SOUZA e SOARES, 2013). Esses fatores de forma visam, em conjunto com a fórmula do cilindro, compensar o volume de determinada espécie com base em ajustes prévios determinados por estudos de cubagem, sendo uma relação entre o volume do cilindro e o volume cubado (VAN LAAR e AKÇA, 2007; CAMPOS e LEITE, 2009; WEST, 2009; SOARES et al., 2011a).

Os volumes totais, comercial ou de partes da árvore são variáveis de grande interesse a serem estimadas em florestas sujeitas à prática do manejo florestal sustentável. Estimando-se estes volumes com precisão, os planos de manejo, as análises de investimento e as tomadas de decisão também serão mais precisos (RUFINI et al., 2010).

Soares et al. (2011b) comentaram que as relações hipsométricas, de volume e de *taper*, são importantes para estudos de inventários florestais, já que determinam o estoque volumétrico em uma área voltada para um fim específico em se tratando de espécies nativas para uso comercial. As relações hipsométricas são utilizadas devido à problemática na aquisição da altura em campo e por ser estritamente relacionadas aos cálculos de volume nos modelos de regressão (SOARES et al., 2011b). Já nas equações de *taper*, sua utilização para obtenção da estimativa, mesmo de forma mais restrita, também pode ser usada para formulação do volume, por estimar qualquer diâmetro para obtenção da altura e volume comercial para multiprodutos da madeira (CAMPOS e LEITE, 2009; SOARES et al., 2011b).

Alguns estudos apontaram a importância na determinação da altura comercial de determinadas espécies nativas, sendo o critério utilizado a escolha do diâmetro mínimo de inclusão para determinar o volume nessas alturas a depender do produto desejado. Santos et al. (2012), em estudos com *Ocotea porosa*, atribuiu um diâmetro mínimo comercial de 4 cm na região do Rio Negro, PR. Este mesmo critério de limite comercial foi adotado por Campos et al. (1986) e Machado et al. (2006) para a *Mimosa scabrella* (Bracatinga) e para povoamentos de *Acacia mangium* (VEIGA et al., 2000). Van Laar e Akça (2007) comentaram que para grande parte das florestas tropicais, o diâmetro mínimo adotado foi de 10 cm.

## 2.2. Volumetria de espécies da Caatinga

Estudos referentes à aplicação da volumetria possuem ênfase quase que majoritária para espécies exóticas de maior interesse econômico para o país, a exemplo das espécies dos gêneros *Pinus* e *Eucalyptus* (COUTO e BASTOS, 1987; McTAGUE et al., 1989; FRANCO et al., 1997; MELLO e GONÇALVES, 2008; FERREIRA et al., 2011; LOUREIRO et al., 2012). Quando há, os esforços são concentrados no ajuste de equações para estimativas de biomassa do fuste e galhos (LIMA et al., 1996), biomassa da parte aérea (SAMPAIO e SILVA, 2005; MENDONÇA et al., 2013) ou equações de volume ajustadas para as diversas fisionomias de biomas (SOARES et al., 2011a).

Para espécies da Caatinga o trabalho pioneiro de Zákia (1992), ajustando equações para estimativa do peso verde para cálculo de volume de 10 espécies da Caatinga da região do Seridó-RN, utilizou a área seccional da base (0,3 m do solo) e a área basal a 1,3 m de altura como variáveis independentes. O autor observou que todos os modelos ajustados foram satisfatórios para os tipos de vegetação e espécies mensuradas, sendo o modelo linear simples (modelo de Spurr) o que obteve o maior coeficiente de determinação. Apesar do pioneirismo do trabalho, ele não avaliou a distribuição gráfica dos resíduos e não há detalhamentos quanto ao método de cubagem realizado.

Apesar da convenção quanto à utilização do diâmetro a 1,3 m de altura (DAP) como variável essencial para cálculos de volume (SOARES et al., 2011a), em espécies da Caatinga, o uso do diâmetro a altura do solo (diâmetro a 0,3m de altura, ou DAS) é também contabilizado devido ao comportamento intrínseco de grande parte das espécies em possuir dois, três ou mais fustes na altura de 1,3 m, sendo esta variável utilizada para distribuição por classe diamétrica, com diâmetro de inclusão mínimo de 5 cm (SILVA, 2006).

Silva (2006), utilizando o método de cubagem pela fórmula de Smalian com espécies da Caatinga, atribuiu intervalos das seções de um em um metro, tanto para o fuste quanto para galhos, até um valor mínimo aproveitável de 1,5 cm de diâmetro. Para Alves Júnior (2010), ao utilizar o método de Smalian, as seções no fuste devem apresentar intervalos mais curtos, iniciando de 0,30; 0,50; 0,70; 0,90; 1,10; 1,30; 1,50; 1,70; 2,30 m, e de metro em metro até o final da árvore e, para galhos, toretes

com seções de um em um metro (CAP mínimo de 6 cm). O mesmo autor constatou que o modelo de Schumacher & Hall para estimativas de volume foi o que apresentou maior confiabilidade e que o ajuste de equações por grupos de espécie confere maior acurácia nas estimativas.

## **2.3. Redes Neurais Artificiais (RNA)**

### **2.3.1. Aspectos gerais**

As Redes Neurais Artificiais (RNA), em termos conceituais, consistem em um sistema paralelo composto por unidades especializadas (chamadas de nodos) com a função de calcular funções matemáticas (lineares e não lineares), sendo estas unidades interligadas por uma gama de conexões, associadas a pesos, que cumprem a função de armazenar o conhecimento adquirido através da entrada inicial de dados, assemelhando-se ao cérebro humano (SILVA et al., 2010). Essas redes tentam exprimir e detectar padrões de comportamento através da comunicação entre esses “nodos” (neurônios), e a partir do aprendizado gerar respostas para solucionar problemas para dados não conhecidos, semelhante a um sistema biológico, utilizando-se de um algoritmo de aprendizagem (BRAGA et al., 2000; 2014; HAYKIN, 2001; 2009).

Em um processo de treinamento, essas redes têm a capacidade de aprender com exemplos e, a partir disso, extrair informações importantes. Esta etapa atribui à rede a possibilidade de fazer interpolações e extrapolações daquilo que aprenderam inicialmente, gerando um processo iterativo de ajuste de parâmetros, dando pesos às conexões entre as unidades de processamento, que guardam, ao final do processo, o conhecimento que a rede adquiriu do ambiente em que está operando (BRAGA et al., 2000; 2014; BINOTI, 2010).

As redes podem ser classificadas quanto: ao número de camadas, que podem ser simplificadas em uma única camada ou de múltiplas camadas; tipos de conexões (*feedforward* ou *feedback*); e conectividade, que podem ser parcialmente ou totalmente conectadas. Estas classificações estão relacionadas aos tipos e quantidades de conexões entre nodos e servem para definir as arquiteturas das redes neurais. As conexões do tipo *feedforward* (ou acíclicas), possuem a

característica de serem alimentadas em camadas posteriores sempre adiante e, por serem acíclicas, ou seja, não são capazes de retroalimentação da informação, diferentes das *feedbacks* (cíclicas), que possuem pelo menos uma conexão de realimentação (BRAGA et al., 2000; 2014; HAYKIN, 2001).

### **2.3.2. Tipos de RNA**


Para Braga et al. (2000; 2014), existem vários tipos de arquiteturas de RNA. Entretanto, as mais comuns são as redes MLP (*Multilayer Perceptron*) e a RBF (*Radial Basis Function*). Contudo, outros algoritmos que se utilizam de preceitos da computação evolutiva através do treinamento com algoritmos genéticos (AGs) têm sido desenvolvidos e utilizados como forma de solucionar alguns entraves das redes convencionais (STANLEY e MIIKKULAINEN, 2002; 2004; STANLEY, 2004; BRAGA et al., 2014), bem como algoritmos mais dinâmicos com efeito cascata e que “pulam” camadas (RIPLEY, 1996).

### **2.3.3. Redes *Multilayer Perceptron* (MLP)**

As MLP mais simples consistem em arquiteturas com duas camadas de neurônios artificiais que cumprem a função de processamento dos dados (camada intermediária e camada de saída) e uma camada de neurônios artificiais, que apenas recebem os dados (camada de entrada) e direciona-os à camada intermediária (BINOTI et al., 2013; 2014). São estruturas capazes de trabalhar com problemas que não são linearmente separáveis e buscar soluções diferentes por aproximação de funções geralmente não lineares (BRAGA et al., 2014; HAYKIN, 2009).

Segundo Haykin (2009), as MLPs possuem três premissas básicas que as caracterizam: cada neurônio possui uma função de ativação não linear que é diferenciável; podem possuir uma ou mais camadas que estão ocultas tanto às camadas de entrada quanto para a de saída, e a rede exibe um alto grau de conectividade, em que são determinados seus pesos sinápticos (Figura 1).





**Figura 1** – Arquitetura de uma rede *Multilayer Perceptron* (MLP) do tipo *feedforward*, totalmente conectada, com 10 neurônios na camada de entrada, uma camada oculta com quatro neurônios e dois neurônios na camada de saída. Fonte: Haykin (2009).

A resolução de grande parte dos problemas apresentados a uma rede MLP é solucionável com apenas uma camada oculta. Assim, geralmente essas redes possuem uma camada oculta e o número de neurônios nesta camada pode variar a depender da complexidade do resultado a ser diagnosticado (BRAGA et al., 2014).

Este número de neurônios é atribuído de forma empírica quando se tem conhecimento da amplitude do problema ao qual a rede deverá solucionar. Nesse sentido, quando não há como determinar esta amplitude, recomenda-se que o dimensionamento da rede seja feito utilizando uma estrutura mínima e, caso o limite de tolerância do erro não seja alcançado, deve-se adicionar neurônios gradativamente até obter o mínimo erro quadrático estabelecido (BRAGA et al., 2000; 2014).

Outra questão é que as redes MLP em sua grande maioria possuem uma função de ativação não linear (sigmoide) na camada intermediária e podem possuir uma função não linear ou linear na camada de saída. As funções lineares na camada de saída geralmente são utilizadas em problemas de classificação (BRAGA et al., 2014).

Para o tipo MLP, o algoritmo mais usado para o treinamento é o *backpropagation*. Entretanto, algumas variações ao algoritmo já foram desenvolvidas

com a premissa de resolver possíveis limitações do algoritmo como, por exemplo, seu pior desempenho para maiores e mais complexos problemas, sendo o mais usual o *Resilient propagation (Rprop)* (BRAGA et al., 2014; HAYKIN, 2001; 2009; BINOTI et al., 2014). Outros algoritmos com outras funcionalidades também foram desenvolvidos com a premissa de sugerir novas vias para resoluções de problemas, com redes mais flexíveis, como é o caso das *Skip-layer connections* (RIPLEY, 1996; VENABLES e RIPLEY, 2002; VELTEN, 2009) e o *Neuroevolution of Augmenting Topologies* (STANLEY e MIIKKULAINEN, 2002).

### 2.3.3.1. *Resilient propagation (Rprop)*

A rede do tipo MLP mais comum está inserida na classificação de arquitetura *feedforward* de camadas múltiplas, com treinamento realizado de forma supervisionada pelo algoritmo *backpropagation*, que consiste em duas fases: uma denominada de “propagação adiante” (*forward*), onde os dados inseridos são propagados camada por camada até a produção das respectivas saídas e, uma segunda fase, denominada de “propagação reversa” (*backward*), que consiste nos ajustes dos pesos sinápticos de todos os neurônios da rede (BRAGA et al., 2014; HAYKIN, 2009; SILVA et al., 2010).

O algoritmo *backpropagation* possui a problemática do treinamento relacionada à sua sensibilidade às características da superfície do erro, o que dificulta a sua convergência em regiões de baixo gradiente e de mínimos locais, necessitando utilizar uma taxa de aprendizado decrescente, um termo *momentum* ou adicionar ruído aos dados para reduzir o efeito dos mínimos locais e acelerar o algoritmo (BRAGA et al., 2014). Outro aspecto desvantajoso é que o algoritmo é muito sensível a ruídos contidos na base de dados em comparação a outros algoritmos (ÖZÇELIK et al., 2010).

Assim, o *Rprop* (ou *Resilient propagation*) é a adaptação do *backpropagation* que é treinado de forma supervisionada de aprendizado *batch* em redes do tipo MLP. Ele tem a premissa de resolver a influência negativa do valor da derivada parcial no momento de ajuste dos pesos sinápticos. Segundo Braga et al. (2014), esta característica do *backpropagation* é devido ao fato de que quando a saída de um neurônio for próxima de 0 (ou 1), e a saída binária for 1 (ou 0), a derivada será

próxima de 0, ocorrendo uma tendência a buscar valores para os pesos do neurônio um ajuste mínimo, sempre próximo de 0.

Assim, a grande diferença do Rprop se dá através da utilização de apenas o sinal da derivada e não do valor dela. O sinal positivo ou negativo indicará a direção do ajuste dos pesos sinápticos, se deverá aumentar ou diminuir o valor anterior e o tamanho do ajuste é dado por um “vetor de atualização”, como mostra a Equação 1 (BRAGA et al., 2014).

$$\Delta w_{ij}(t) = \begin{cases} -\Delta_{ij}(t), & \text{se } \frac{\partial E}{\partial w_{ij}}(t) < 0 \\ +\Delta_{ij}(t), & \text{se } \frac{\partial E}{\partial w_{ij}}(t) > 0 \\ 0, & \text{se } \frac{\partial E}{\partial w_{ij}} = 0 \end{cases} \quad (\text{eq. 1})$$

Portanto, o valor de atualização  $\Delta_{ij}$  é definido por um processo adaptativo que é dependente do sinal da derivada do erro em relação ao peso a ser ajustado:

$$\Delta_{ij}(t) = \begin{cases} \eta^+ \Delta_{ij}(t-1), & \text{se } \frac{\partial E(t-0)}{\partial w_{ij}} \cdot \frac{\partial E(t)}{\partial w_{ij}} > 0 \\ \eta^- \Delta_{ij}(t-1), & \text{se } \frac{\partial E(t-0)}{\partial w_{ij}} \cdot \frac{\partial E(t)}{\partial w_{ij}} < 0 \\ \Delta_{ij}(t-1), & \text{se } \frac{\partial E}{\partial w_{ij}} = 0 \end{cases} \quad (\text{eq. 2})$$

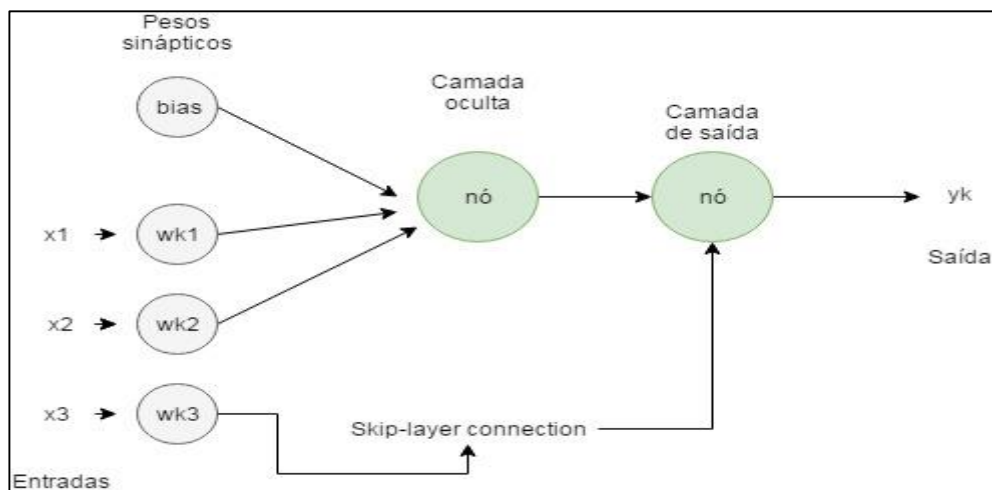
em que,  $0 < \eta^- < 1 < \eta^+$

Nesse sentido, quando a derivada parcial do erro em relação a um peso  $w_{ij}$  mantém seu sinal, sinaliza que seu último ajuste reduziu o erro gerado pela rede. Nesse caso, o valor de atualização  $\Delta_{ij}$  é agregado pelo fator  $\eta^+$ , aumentando assim o poder de convergência do treinamento. Quando a derivada parcial muda de sinal, o que indica que seu último ajuste foi grande demais, o valor de atualização  $\Delta_{ij}$  é reduzido pelo fator  $\eta^-$ , mudando a direção do ajuste (BRAGA et al., 2014).

### 2.3.3.2. Redes com *Skip-layer connections*

Conforme mencionado anteriormente, as redes do tipo MLP mais simples possuem a característica de apresentarem estruturas com alta conectividade entre os neurônios e se utilizam do algoritmo *backpropagation*, que é baseado na regra de aprendizagem por correção do erro (HAYKIN, 2001). Seu principal papel é transformar através da camada de entrada o problema não linearmente separável para que a camada oculta possa tratar o problema de forma linear e, assim, a camada de saída possa resolvê-lo conforme descrito no espaço de entrada (BRAGA et al., 2014).

Nesse sentido, na estrutura básica de uma MLP todas as camadas estão conectadas e possuem no mínimo uma camada oculta (HAYKIN, 2001; 2009). Assim, uma alternativa para tornar as redes MLP mais flexíveis, com a premissa de aumentar a precisão das estimativas, é criar uma conexão entre a camada de entrada e a camada de saída, sem passar obrigatoriamente por uma camada oculta, a exemplo das *Skip-layer connections* (VENABLES e RIPLEY, 2002; VELTEN, 2009). Segundo Velten (2009), as *Skip-layer connections* são conexões diretas entre a camada de entrada e a camada de saída em que os dados não são transferidos a uma camada oculta, ou seja, são capazes de “pular” a camada intermediária (Figura 2).



**Figura 2** – Rede *Skip-layer connection* com dois neurônios de entrada conectados à camada oculta e uma conexão *Skip-layer* ligada diretamente à camada de saída. Fonte: adaptado de Haykin (2001).

### 2.3.3.3. *Neuroevolution of Augmenting Topologies (NEAT)*

Os complexos seguimentos evolutivos baseados em eventos da natureza, são a principal fonte teórica a qual baseia-se a computação evolutiva. São algoritmos capazes de resolver problemas de grande descerramento na aprendizagem em Inteligência Artificial (AI). Estes sistemas desenvolvem genomas de comprimento fixo com a premissa de que as dimensões do genoma são eficazes em buscar a solução. Cada genoma possui um total de genes que decodifica cada ponto no espaço dimensional, com o argumento de que a solução se encontra em algum lugar deste espaço (STANLEY e MIIKKULAINEN, 2004). A técnica é bastante eficaz na varredura destes espaços, objetivando encontrar aproximações coerentes à solução ótima, quase sempre sem a necessidade de intervenção humana (LINDEN, 2008).

Partindo desse pressuposto, surgem as redes de caráter evolutivo baseadas em algoritmos genéticos (AGs). As semelhanças entre a computação evolutiva e os AGs, são: possuem populações de cromossomos; realizam seleções com base na aptidão; executam cruzamento entre os aptos para gerar descendentes e induz mutação randômica dos novos descendentes (MITCHELL, 1996).

Em termos gerais, os AGs são algoritmos de otimização e busca, baseados na teoria da seleção natural e genética de Darwin. Os algoritmos convencionais que possuem esta mesma função de busca (ex.: *backpropagation*) trabalham essa otimização de forma sequencial e possuem a desvantagem de analisar a cada instante uma possível solução. Já os AGs, trabalham com um conjunto de possíveis soluções simultaneamente (BRAGA et al., 2014). Portanto, a estrutura básica de um algoritmo genético concede a partir dos seguintes passos (MITCHELL, 1996):

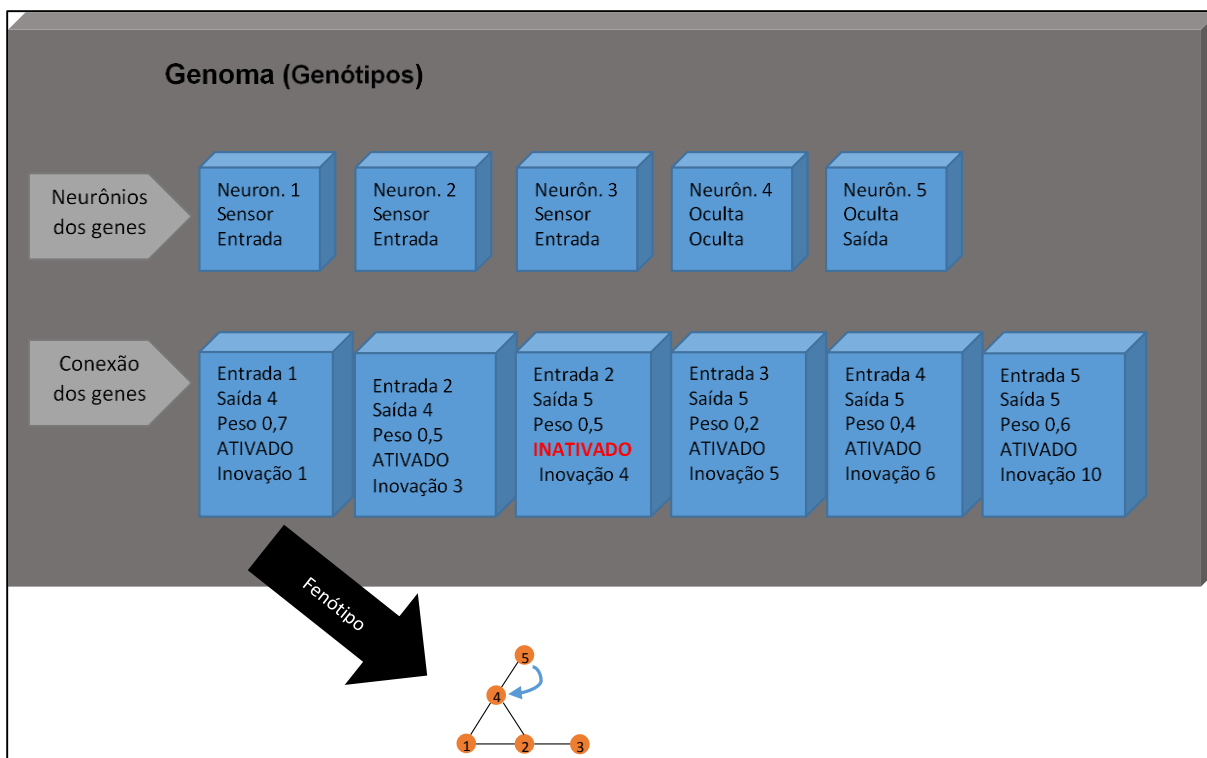
1. Inicia com uma população aleatoriamente criada de  $n$  *l-bit* cromossomos (ou seja, candidatos supostamente aptos à resolução do problema);
2. Calcula o *fitness*  $f(x)$  para cada cromossomo  $x$  na população;
3. Repete os passos seguintes antes que  $n$  descendentes tenham sido gerados:
  - a. Selecionam pares de cromossomos parentais a partir da população atual, para que o ato de seleção seja uma função crescente da aptidão. A seleção é realizada “com substituição”, ou seja, significa

que o mesmo cromossomo pode ser selecionado mais de uma vez para se tornar um pai;

- b. Com a probabilidade  $p_c$  (taxa ou probabilidade de cruzamento), cruzam-se pares a partir de um ponto aleatório escolhido para formar dois descendentes. Se nenhum outro cruzamento tomar lugar, formará dois descendentes com características iguais aos dos seus respectivos pais;
  - c. Mutação dos dois descendentes de cada ponto com uma probabilidade  $p_m$  (taxa provável de mutação) e, assim, alocar os novos cromossomos gerados na nova população. Se  $n$  for ímpar, um novo membro da população pode ser descartado aleatoriamente;
4. A população atual é substituída com a nova população (ou geração);
  5. Retorna à etapa 2.

O *Neuroevolution of Augmenting Topologies (NEAT)* é um algoritmo baseado nos princípios da computação evolutiva e dos algoritmos genéticos (AGs). Conforme mencionado anteriormente, os AGs trabalham com genes, genótipos, fenótipos e seu processo evolutivo se baseia nos conceitos de seleção natural. Sua principal vantagem em comparação às redes neurais convencionais é que, diferentemente delas, possui a capacidade de evoluir e mudar a topologia da RNA de forma automática, quando necessário. Estas evoluções iniciam com uma estrutura simplificada, geralmente com neurônios em uma única camada oculta, com cada neurônio conectado às camadas de entrada e saída simultaneamente (STANLEY e MIIKKULAINEN, 2002; 2004; STANLEY, 2004).

Segundo Stanley e Miikkulainen (2002), as redes NEAT foram desenvolvidas para solucionar três desafios. O primeiro é definir a forma de selecionar indivíduos capazes de efetuar cruzamentos, a fim de atender os pressupostos significativamente. O segundo, em como evitar que, através da evolução topológica, algumas gerações que podem otimizar o desempenho da rede desapareçam prematuramente. E, por último, em como as topologias podem apresentar um fenótipo simples sem a necessidade de criar uma função de aptidão com o único objetivo de medir a complexidade. Nesse sentido, as NEAT funcionam como mostra a Figura 4.



**Figura 3** – Mapa do fenótipo e genótipo da NEAT. Nota-se que o terceiro gene foi desativado, portanto, a conexão que o especifica não será expressa no fenótipo. Fonte: adaptado de Stanley e Miikkulainen (2002).

O genoma possui uma gama de genes de ligação em que cada um refere-se a dois genes conectados a nodos (neurônios). Cada conexão especifica a entrada e saída de cada neurônio e seus pesos sinápticos comunicam se cada um está ativado ou desativado (se o gene foi expressado ou não) e seu número de inovação. Este número habilita o algoritmo a encontrar os genes correspondentes no momento de cruzamento (STANLEY e MIIKKULAINEN, 2002).

Após esta etapa, ocorre a fase de mutação que pode alterar tanto os valores dos pesos quanto a estrutura da rede. A etapa de mutação é executada de duas maneiras: 1) Quando adicionadas novas conexões, um novo e único gene é incluído, conectando dois neurônios anteriormente desconectados; 2) Na mutação dos neurônios dos genes, uma conexão existente é dividida e um novo neurônio substitui a antiga conexão. Então, a conexão antiga é desativada e duas novas conexões são adicionadas ao genoma (STANLEY e MIIKKULAINEN, 2002).

Outro aspecto das redes NEAT é que cada gene eliminado ou incluído na rede é mapeado com base em sua origem. Esta informação cria uma ideia de localização, em que dois genes que possuem a mesma origem histórica,

representam uma estrutura igual, mesmo que possivelmente os pesos sejam diferentes, desde que eles tenham surgido de um gene ancestral em um mesmo momento no passado. Nesse sentido, quando um novo gene aparece, um novo número global de inovação é designado a este gene. Este número de inovação representa a cronologia de cada gene no sistema (STANLEY e MIIKKULAINEN, 2002; 2004; STANLEY, 2004).

#### **2.3.4. Radial Basis Function (RBF)**

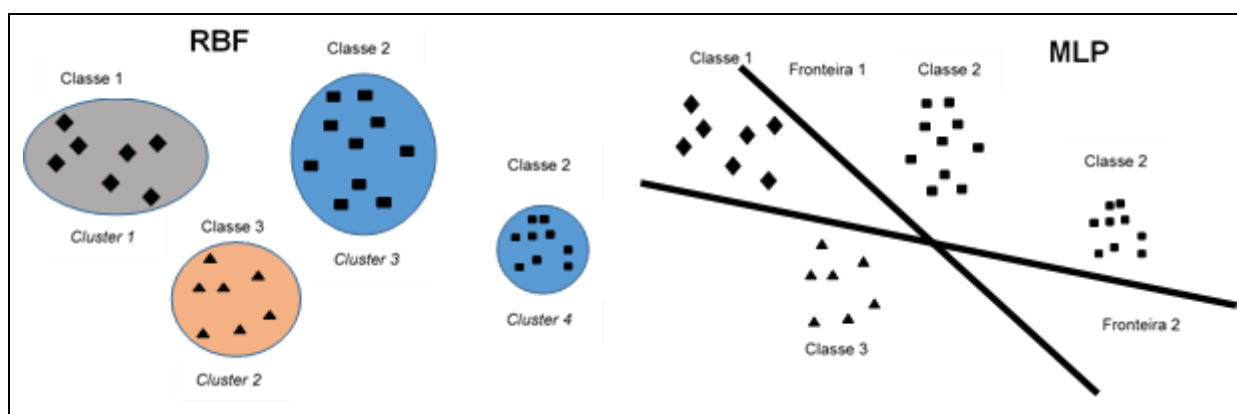
Apesar da semelhança às redes MLP, redes que possuem funções de base radial (RBF) apresentam algumas diferenças. A semelhança é que ambas são aproximadoras universais de funções, conhecida na estatística, como aproximações estocásticas. Enquanto que em uma rede MLP a função de ativação executada a cada neurônio utiliza como princípio o produto escalar do vetor de entrada, nas RBF sua ativação se dá em função da distância entre seus vetores de entrada e de peso (BRAGA et al., 2014; HAYKIN, 2001).

Uma RBF, por exemplo, tem uma única camada oculta, enquanto uma MLP pode ter uma ou mais camadas. São em sua essência parcialmente não lineares, ou seja, sua camada oculta processa de forma não linear enquanto que a camada de saída é linear, diferente das MLP, que podem ser totalmente não lineares ou parcialmente lineares (HAYKIN, 2001).

A primeira camada da RBF, ou seja, a camada de entrada dos dados, cumpre a função de agrupar os *inputs* em um *cluster* através de funções de base radiais. A segunda e única camada oculta, tem o objetivo de aplicar uma transformação não linear do espaço de entrada para o espaço oculto, transferindo o sinal para a camada de saída, que é linear, para fornecer a resposta com base nesse padrão de ativação que foi aplicado à camada de entrada. Nesse sentido, a explicação para a sequência de transformações (não linear para linear) é devido à partição de padrões ser linearmente separável com maior probabilidade em um espaço de alta dimensionalidade do que em um de baixa dimensionalidade. Quanto maior for a dimensão do espaço oculto, mais precisa será a aproximação (HAYKIN, 2001; BRAGA et al., 2014).



A etapa de separação dos dados é executada por funções radiais em que o valor pode diminuir ou aumentar a depender do distanciamento do valor em relação ao centro e se baseia por distância euclidiana. Assim, as funções de base radial mais comuns são a gaussiana, multiquadrática e *thin-plate-spline*. Enquanto que nas redes RBF cada neurônio na camada de entrada define uma hiperelipsóide para criar regiões de espaços e definição dos centros, as MLPs particionam o espaço de entrada através de hiperplanos, conforme mostra a Figura 3 (BRAGA et al., 2014).



**Figura 4** – Separação dos dados de entrada, executada por uma rede RBF, com quatro neurônios na camada intermediária; valores de entrada particionados por uma rede MLP com uma camada intermediária possuindo três neurônios. Fonte: adaptado de Braga et al. (2014).

### 2.3.5. Redes neurais artificiais em pesquisas florestais

O uso da ferramenta de inteligência artificial (AI) através de RNA teve seu início no final da década de 1980, com estudos referentes ao manejo florestal (COULSON et al., 1987). É atualmente considerada uma ótima ferramenta para o planejamento dos recursos, resolução de problemas mais complexos e tomada de decisões que exijam maior acurácia nas estimativas, como é o caso do volume (RODRIGUES et al., 2010; LIMA, 2014). Entretanto, estudos nessa área ainda são mais expressivos para espécies exóticas em plantios comerciais, como é o caso dos trabalhos de Gorgens et al. (2009), Binoti (2010), Binoti (2012) e Binoti et al. (2013), com poucos trabalhos envolvendo seu uso em florestas naturais (FRANCO, 2012).

O uso das RNA pode envolver cenários para estimativa de biomassa e carbono, com o treinamento da rede através do algoritmo de aprendizagem *backpropagation*, integrando algumas variáveis importantes para a utilização de

imagens de satélite nos inventários em conjunto com a RNA, isso aplicado a florestas nativas (SCHOENINGER et al., 2008).

Gorgens et al. (2009) afirmaram que um projeto florestal aplicado às RNA deve compreender três etapas para obter uma rede pronta para ser usada: 1) construção da rede, treinamento e validação; 2) que esta deve compreender também uma etapa de pré-processamento, processamento e, por fim; 3) um pós-processamento dos dados, que servirão para modelagem do volume de árvores. Salientam ainda que observância nas estimativas de distribuição dos diâmetros atribuídas pela rede, deve ser avaliada em comparação com os dados originais, evitando-se, assim, distorções e alterações no comportamento da variável original. Os mesmos autores utilizaram redes *feedforward* treinadas pelo algoritmo da retropropagação do erro (*backpropagation*) e, como dados de entrada, as variáveis DAP, Ht e cinco diferentes locais para as espécies *Eucalyptus spp.* e *Tectona grandis* L.f., concluindo que as redes foram eficazes para predição de volume nesses ambientes.

Além da estimativa de volume, as RNA podem ser usadas também para prognose com informações geradas através de inventários contínuos, utilizando-se de variáveis numéricas como a idade, área basal e volume por hectare, com o treinamento da rede pelo uso de um algoritmo de aprendizagem. Estas redes têm a capacidade de desempenhar a aproximação de funções para projeção da área basal e do volume, principalmente na utilização de redes dos tipos Linear, MLP e RBC, além da própria prognose da produção volumétrica a nível de povoamento (BINOTI, 2010).

Rodrigues et al. (2010), para a estimativa do volume do *Schizolobium amazonicum* (Paricá), utilizaram o treinamento da rede através do algoritmo de aprendizado *backpropagation* e sua topologia constituída de uma camada de entrada com cinco neurônios, um para cada variável de entrada, uma camada intermediária com três neurônios e uma camada de saída com um neurônio, para o volume comercial com casca em m<sup>3</sup>. Observaram que as RNA foram superiormente melhores na estimativa do volume real em comparação com os modelos lineares e quadráticos.

Uma alternativa para diminuir o dispêndio na cubagem está no uso das redes neurais para estimativa de diâmetros subsequentes com base nos três diâmetros

vizinhos. Este procedimento visa, através dos diâmetros coletados, diminuir o tempo gasto na cubagem dos indivíduos arbóreos, já que as redes MLP necessitam apenas de 10% dos dados de cubagem da população em comparação às equações de volume, o que diminui o custo em inventários florestais (SOARES et al., 2011c).

Outra aplicabilidade é na substituição dos atuais modelos hipsométricos por RNA treinadas, envolvendo simulação de cenários hipotéticos, a exemplo da inclusão de um novo material genético ou outro cenário envolvendo uma série histórica de inventário contínuo. Nesses cenários são geradas redes genéricas eficientes na estimativa da altura, podendo substituir os atuais modelos hipsométricos pelas RNA em plantios de *Eucalyptus sp* (BINOTI, 2012).

Franco (2012), em estudo com RNA para estimativa de volume em um remanescente de Floresta Estacional Semidecidual, utilizou 16 redes *Multilayer Perceptron* atribuindo as variáveis contínuas “área basal” por unidade de área, a “altura total média” como variáveis de entrada e o “volume total” como variável de saída, pelo treinamento do tipo *feedforward*. Sugere que pelo menos 70% dos dados sejam utilizados para treinamento e 30% para validação.

Em alguns casos, a simplificação da rede se faz necessária quanto ao número de neurônios incluídos nas camadas ocultas, mostrando que nem sempre há necessidade de construção de arquiteturas mais complexas para seu aprendizado (GORGENS et al., 2009; SOARES et al., 2011c; BINOTI et al., 2014). Isso traz uma vantagem para estimativas de volume nas RNA em comparação aos modelos volumétricos convencionais, como o de Schumacher & Hall, diminuindo a necessidade de ajuste de modelos individualmente por estrato ou outra situação aplicada (BINOTI et al., 2014).

Lacerda et al. (2014), comparando dois tipos de arquitetura de Redes Neurais Artificiais para o Cerrado *sensu stricto*, observou que as redes MLP foram superiores em comparação às RBF e a equação de Schumacher & Hall, tanto para volume comercial quanto para o volume total, com menores erros nas estimativas. Os autores constataram ainda que, pela análise do histograma de frequência, mesmo com altos valores em comparação ao comportamento das redes em plantadas, o resultado foi satisfatório devido à alta variabilidade das florestas inequidêneas.

Outra aplicação das redes neurais no Cerrado foi proposta por Silva et al. (2014), através da densidade básica para atestar a qualidade da madeira, utilizando

métodos não destrutivos. Nesse caso, as RNA se mostraram favoráveis para estimativas da densidade, mas sugeriu a aplicação do método em novas espécies e a inclusão de variáveis categóricas nessas redes.

Cunha et al. (2014), em Floresta Estacional Semidecidual, em Minas Gerais, mostrou que a inclusão de variáveis categóricas, a exemplo “qualidade do fuste”, podem fornecer melhores estimadores para obtenção do volume comercial com casca das espécies dessa fitofisionomia.

Lima (2014), em trabalho pioneiro com espécies da Caatinga, utilizou as RNA para estimativa de volume de fuste e galhos através da rede tipo *Multilayer Perceptron* (MLP), que foram treinadas de forma supervisionada, empregando o algoritmo da retropropagação do erro (*backpropagation*). O autor observou que as redes que apresentavam apenas o diâmetro como variável de entrada obtiveram piores precisões, necessitando da variável altura para aumento dessa precisão, em que o modelo de regressão de Schumacher e Hall obteve estimativas com menores tendenciosidades se comparado às RNA.

Araújo et al. (2015), ao trabalhar com diversas fitofisionomias no estado de Minas Gerais, inclusive a Caatinga arbórea, utilizaram a variável classe diamétrica como variável categórica para redes com conexões *Skip-layer*, observando ganhos bastante significativos na precisão das estimativas quando comparadas com o modelo de Schumacher e Hall. Deste modo, constataram que não houve diferença ao aplicar a estratégia de recorrência no treinamento das redes.

Apesar da recorrente utilização do NDVI como principal índice em estudos sobre estimativas de biodiversidade, através de técnicas de sensoriamento remoto, as RNA se apresentaram como técnica adequada na capacidade preditiva dos principais índices de diversidade e equabilidade (índice de Shannon e Pielou, respectivamente), na utilização de índices de vegetação e métricas da paisagem, sendo que o MVI5 (*Moisture Vegetation Index*) e SAVI (*Soil Adjusted Vegetation Index*) apresentaram realismo biológico para estimar os dois índices, no Cerrado brasileiro (CABACINHA e LAFETÁ, 2017).

### 3. REFERÊNCIAS

- ALVES JÚNIOR, F. T. **Estrutura, biomassa e volumetria de uma área de Caatinga, Floresta – PE**. Recife-PE: UFRPE, 2010, 123 p. Tese (Doutorado em Ciências Florestais) – Universidade Federal Rural de Pernambuco.
- ARAÚJO, A. C. da S. C.; BINOTI, M. L. M. da S.; LEITE, H. G.; BINOTI, D. H. B.; XIMENES, L. C.; NOGUEIRA, G. S.; CARNEIRO, J. A. Artificial Neural Networks with Skip Layer connections to estimate the volume of forest formations in the state of Minas Gerais. **Australian Journal of Basic and Applied Sciences**, v. 36, n. 9, p. 319-327, 2015.
- BARROS, P. L. C.; SILVA JÚNIOR, A. T. Equação de volume para árvores de uma floresta tropical densa no município de Anapu, oeste do estado do Pará, Amazônia Oriental. **Revista ciências agrárias**, n. 51, p.115-126, 2009.
- BINOTI, D. H. B.; BINOTI, M. L. M. da S.; LEITE, H. G. Configuração de redes neurais artificiais para estimação do volume de árvores. **Ciência da Madeira**, v. 5, n. 1, p. 58-67, 2014.
- 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.
- BINOTI, M. L. M. **Emprego de redes neurais artificiais em mensuração e manejo florestal**. Viçosa-MG: UFV, 2012, 130 p. Tese (Doutorado em Ciências Florestais) – Universidade Federal de Viçosa.
- BINOTI, M. L. M. **Redes neurais artificiais para prognose da produção de povoamentos não desbastados de eucalipto**. Viçosa-MG: UFV, 2010, 54 p. Dissertação (Mestrado em Ciências Florestais) – Universidade Federal de Viçosa.
- BRAGA, A. P.; CARVALHO, A. P. L. F.; LUDERMIR, T. B. **Redes neurais artificiais: teoria e aplicações**. 1. ed. LTC, Rio de Janeiro, 2000, 250 p.
- BRAGA, A. P.; CARVALHO, A. P. L. F.; LUDERMIR, T. B. **Redes neurais artificiais: teoria e aplicações**. 2. ed.- [Reimpr.]. LTC, Rio de Janeiro, 2014, 26 p.
- CABACINHA, C. D. **Um método para a realização do inventário florestal suprimindo a cubagem rigorosa**. Lavras-MG: UFLA, 2003, 166 p. Dissertação (Mestrado em Engenharia Florestal) – Universidade Federal de Lavras.
- CABACINHA, C. D.; LAFETÁ, B. O. Floristic diversity and equitability in forest fragments using Artificial Neural Networks. **Ciência Florestal**, v. 27, n. 1, p. 143-152, 2017.

CAMPOS, C. H. O.; GRAÇA, L. R.; RIBAS, L. C. A produtividade do bracatingal tradicional através do tempo. **Boletim de Pesquisa Florestal**, n. 12, p. 35-46, 1986.

CAMPOS, J. C. C.; LEITE, H. G. **Mensuração florestal: perguntas e respostas**. 3. ed. UFV, Viçosa, 2009, 548 p.

CASTELLANOS, A.; BLANCO, A. M.; PALENCIA, V. Applications of radial basis neural networks for area forest. **International Journal Information Theories and Applications**, v. 14, p. 218-222, 2007.

COLPINI, C.; TRAVAGIN, D. P.; SOARES, T. S.; SILVA, V. S. M. Determinação do volume, do fator de forma e da porcentagem de casca de árvores individuais em uma Floresta Ombrófila Aberta na região noroeste de Mato Grosso. **Acta Amazônica**, v. 39, n. 1, p. 97-104, 2009.

COULSON, R.N.; FOLSE, L.J.; LOH, D. K. Artificial intelligence and natural resource management. **Science**, v. 237, n. 4812, p. 262-267, 1987.

COUTO, H.T.Z.; BASTOS, N. L. M. Modelos de equações de volume e relações hipsométricas para plantações de *Eucalyptus* no Estado de São Paulo. **IPEF**, n. 37, p. 33-44, 1987.

CUNHA, E. G. S.; FRANCO, S. A. P.; OLIVEIRA, M. L. R.; MACHADO, E. L. M.; NOGUEIRA, G. S.; PEREIRA, I. M.; SILVA, A. G. Estimativa do volume de povoamento por meio de redes neurais artificiais em florestas naturais. In: CORTE, A. P. D. [et al.] (Eds.). **Atualidades em Mensuração Florestal** [livro eletrônico], 1. ed. Curitiba, 2014, p. 340-343.

EISFELD, R. L.; VIGOLO, D. Z.; SANQUETTA, C. R.; MELLO, A. A. de. Modelo de Hradetzky aplicado à estimativa do volume total para *Araucaria angustifolia* (Bert.) O. Ktze. **Revista Ambiência**, v. 4, n. 1, 2008.

FERREIRA, J. C. S.; SILVA, J. A. A. da; MIGUEL, E. P.; IMAÑA ENCINAS, J.; TAVARES, J.A. Eficiência relativa de modelos volumétricos com e sem a variável altura da árvore. **Revista ACTA Tecnológica**, v. 6, n. 1, 2011.

FIGUEIREDO, E. O.; SCHROEDER, R.; PAPA, D. de A. Fatores de Forma para 20 Espécies Florestais comerciais da Amazônia. **Comunicado Técnico**, n. 173. Embrapa, Rio Branco, AC, 2009.

FRANCO, E. J.; SCOLFORO, J. R. S.; MELLO, J. M. de; OLIVEIRA, A. D. de. Eficiência dos métodos para estimativa volumétrica de *Eucalyptus camaldulensis*. **Cerne**, v. 3, n. 1, p. 082-117, 1997.

FRANCO, S. A. P. **Estrutura e volume de povoamento de um remanescente de floresta estacional semidecidual em Curvelo-MG**. Diamantina-MG: UFVJM, 2012,

67 p. Dissertação (Mestrado em Ciências Florestais) – Universidade Federal dos Vales do Jequitinhonha e Mucuri.

GORGENS, E. B.; LEITE, H. G.; SANTOS, H. do N.; GLERIANI, J. M. Estimação do volume de árvores utilizando redes neurais artificiais. **Revista Árvore**, v. 33, n. 6, p.1141-1147, 2009.

HAYKIN, S. **Neural networks and learning machines**. 3. ed. Prentice Hall, New York, 2009, 906 p.

HAYKIN, S. **Redes neurais: princípios e prática**. 2. ed. Bookman, Porto Alegre, 2001, 900 p.

IBAMA – Instituto Brasileiro de Meio Ambiente e dos Recursos Naturais Renováveis. **Plano de Manejo: Floresta Nacional Contendas do Sincorá**, Volume I. MMA, Brasília, 2006.

LACERDA, T. H. S.; JESUS, R. B. de; PLAZAS, I. V. C.; LACERDA, K. W. de S.; CABACINHA, C. D.; ASSIS, A. L. de. Redes neurais artificiais para estimar o volume de espécies de cerrado *stricto sensu*. In: CORTE, A. P. D.; SANQUETTA, C. R.; RODRIGUES, A. L.; NETTO, S. P.; MACHADO, S. do A.; FIGUEIREDO FILHO, A.; NOGUEIRA, G. S. (Org.). **Atualidades em Mensuração Florestal**. 1. ed. UFPR, Curitiba, v. 1, 2014, p. 381-384.

LIMA, P. C. F.; OLIVEIRA, E. B.; MACHADO, S. do A. Equações para estimativa de biomassa de espécies de *prosopis* no semiárido brasileiro. **Parte do Boletim de Pesquisa Florestal**, n. 32/33, p. 67-79, 1996.

LIMA, R. B. de. **Distribuição diamétrica e volumetria em vegetação de caatinga arbustiva-arbórea, Floresta-PE**. Recife-PE: UFRPE, 2014, 134 p. Dissertação (Mestrado em Ciências Florestais) – Universidade Federal Rural de Pernambuco.

LINDEN, R. **Algoritmos genéticos: uma importante ferramenta da Inteligência Computacional**. 2. ed. Brasport, Rio de Janeiro, 2008, 400 p.

LOUREIRO, G. L.; CURTO, R. de A.; ROSOT, N. C.; MARANGON, G. P.; VARGAS, J. F. Ajuste de modelos volumétricos por classe diamétrica e para todas as classes em *Eucalyptus grandis* hill ex maiden. **(Anais...)**. In: 4º Congresso Florestal Paranaense, 2012.

MACHADO, S. do A.; TÉO, S. J.; URBANO, E.; FIGURA, M. A.; SILVA, L. C. R. da. Comparação de métodos de cubagem absolutos com o volume obtido pelo xilômetro para Bracatinga (*Mimosa scabrella* Bentham). **Cerne**, v. 12, n. 3, p. 239-253, 2006.

McTAGUE, J. P.; BATISTA, J. L. F.; STEINER, L. H. Equações de volume total, volume comercial e forma do tronco para plantações de *Eucalyptus* nos estados de São Paulo e Rio de Janeiro. **IPEF**, n. 41/42, p. 56-63, 1989.

MELLO, S. L. de M.; GONÇALVES, J. L. de M. Equações para estimar a biomassa da parte aérea e do sistema radicular em povoamentos de *Eucalyptus grandis* em sítios com produtividades distintas. **Revista Árvore**, v. 32, n. 1, p. 101-111, 2008.

MENDONÇA, A. V. R.; SOUZA, J. S.; GIULIETTI, A. M.; BERG, C. V. D. Estimação de biomassa aérea da caatinga do norte da Bahia. **Pesquisa florestal brasileira**, v. 33, n. 76, p. 355-368, 2013.

MIRANDA, D. L. C., AZEVEDO, F. F., SANTOS, J. P. Determinação de volume de toras da espécie *Mezilaurus itauba* (Meissn.) Taub. **Scientia Plena**, v. 9, n. 8, p.1-7, 2013.

MITCHELL, M. **An introduction to genetic algorithms**. Cambridge, Mass: MIT, 1996, 158 p.

ÖZÇELİK, R.; DIAMANTAPOULOU, M. J.; BROOKS, J. R.; WIANT JR.; H. V. Estimating tree bole volume using artificial neural network models for four species in Turkey. **Journal of Environmental Managing**, v. 91, n. 3, p. 742-753, 2010.

PÉLLICO NETTO, S.; BRENA, D. A. **Inventário Florestal**. UFPR, Curitiba, v. 1, 1997, 316 p.

PRADO, D. E. As Caatingas da América do Sul. In: LEAL, I.R., TABARELLI, M., SILVA, J.M.C. (eds.) **Ecologia e Conservação da Caatinga**. Recife, Univ. Federal de Pernambuco, 2003, p. 3-73.

REZENDE, A. V.; VALE, A. T.; SANQUETTA, C. R.; FIGUEIREDO FILHO, A.; FELFILI, J. M. Comparação de modelos matemáticos para estimativa do volume, biomassa e estoque de carbono da vegetação lenhosa de um cerrado sensu stricto em Brasília, DF. **Scientia Forestalis**, n. 71, p. 65-76, 2006.

RIPLEY, B. D. **Pattern Recognition and Neural Networks**. 1. ed., Cambridge University Press, Cambridge, 1996, 403 p.

RIZZINI, C.T. **Tratado de Fitogeografia do Brasil**: Aspectos ecológicos, sociológicos e florísticos. 2. ed. Âmbito Cultural, Rio de Janeiro, Volume único, 1997, 747 p.

RODRIGUES, E. F.; OLIVEIRA, T. F. de; MADRUGA, M. R.; SILVEIRA, A. M. da. Um método para determinar o volume comercial do *Schizolobium amazonicum* (huber) ducke utilizando redes neurais artificiais. **Revista Brasileira Biometria**, v. 28, n. 1, p. 16-23, 2010.

ROLIM, S. G.; COUTO, H. T. Z.; JESUS, R. M.; NASCIMENTO, H. E. M. Modelos volumétricos para a Floresta Nacional do Tapirapé-Aquirí, Serra dos Carajás (PA). **Acta Amazônica**, v. 36, p. 107-114, 2006.



RUFINI, A. L.; SCOLFORO, J. R. S.; OLIVEIRA, A. D. de; MELLO, J. M. de. Equações volumétricas para o cerrado *Senso Strictu* em Minas Gerais. **Revista Cerne**, v. 16, n. 1, p. 1-11, 2010.

SAMPAIO, E. V. S. B.; SILVA, G. C. Biomass equations for Brazilian semiarid caatinga plants. **Acta Botânica Brasílica**, v. 19, n. 4, p. 935-943, 2005.

SANQUETTA, C. R.; DALLA CORTE, A. P.; JACON, A. D. Crown area and trunk diameter relationship for tree species at a mixed-araucaria natural forest in the mid-southern Parana state, Brazil. **Floresta**, v. 41, n. 1, p. 63-72, 2011.

SANQUETTA, C. R.; DALLA CORTE, A. P.; RODRIGUES, A. L.; WATZLAWICK, L. F. **Inventários Florestais: planejamento e execução**. 3. ed. Multi-graphic gráfica e editora, Curitiba, 2014, 406 p.

SANTOS, A. T. dos; MATTOS, P. P. de; BRAZ, E. M.; ROSOT, N. C. Equação de volume e relação hipsométrica em plantio de *Ocotea porosa*. **Pesquisa florestal brasileira**, v. 32, n. 69, p. 13-21, 2012.

SCHOENINGER, E. R.; KOEHLER, H. S.; WATZLAWICK, L. F.; FILHO, P. C. de O. Uso de redes neurais artificiais como uma alternativa para mapeamento de biomassa e carbono orgânico no componente arbóreo de florestas naturais. **Ambiência**, v. 4, n. 3, p. 529-549, 2008.

SCOLFORO, J. R. et al. Equações de volume, peso de matéria de seca e produção de tanino do angico-vermelho (*Anadenanthera colubrina* (Benth) Brenan), em Minas Gerais. In: SCOLFORO, J. R.; OLIVEIRA, A. D.; ACERBI JÚNIOR, F. W. (Ed.). **Inventário Florestal de Minas Gerais - Equações de Volume, Peso de Matéria Seca e Carbono para Diferentes Fisionomias da Flora Nativa**. UFLA, Lavras, 2008, p. 117-128.

SCOLFORO, J.R.S.; MELLO, J.M.; ALMEIDA LIMA, C.S. Obtenção de relações quantitativas para estimativa de volume do fuste em floresta estacional semidecídua montana. **Cerne**, v. 1, n. 1, p. 123-134, 1994.

SFB. Serviço Florestal Brasileiro. **Florestas do Brasil em resumo - 2013: dados de 2007-2012**. / Serviço Florestal Brasileiro. SFB, Brasília, 2013.

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

SILVA, J. A. **Fitossociologia e relações alométricas em Caatinga nos Estados da Paraíba e Rio Grande do Norte**. Viçosa-MG: UFV, 2006, 80 p. Tese (Doutorado em Ciência Florestal) – Universidade Federal de Viçosa.

SILVA, J. P. M; CORDEIRO, N. G.; SOUZA, D. C.; ASSIS, A. L. de; CABACINHA, C. D. Redes neurais de multicamadas para estimar densidade básica de espécies do

cerrado *stricto sensu*. In: CORTE, A. P. D.; SANQUETTA, C. R.; RODRIGUES, A. L.; NETTO, S. P.; MACHADO, S. do A.; FIGUEIREDO FILHO, A.; NOGUEIRA, G. S. (Org.). **Atualidades em Mensuração Florestal**. 1. ed. UFPR, Curitiba, v. 1, 2014, 385-388 p.

SOARES, C. P. B.; MARTINS, F. B.; JUNIOR, H. U. L.; SILVA, G. F. da; FIGUEIREDO, L. T. M. de. Equações hipsométricas, volumétricas e de *taper* para onze espécies nativas. **Revista Árvore**, v. 35, n. 5, p. 1039-1051, 2011b.

SOARES, C. P. B.; NETO, F. de P.; SOUZA, A. L. de (Ed.). **Dendrometria e Inventário Florestal**. 2. ed. UFV, 2011a, 272 p.

SOARES, F. A. A. M. N.; FLORES, E. L.; CABACINHA, C. D.; CARRIJO, G. A.; VEIGA, A. C. P.. *Multilayer perceptron* na predição recursiva de diâmetros de clone de eucalipto. (**Anais...**). In: Simpósio Brasileiro de Automação Inteligente, 2011, São João Del Rei. X SEBAI - Simpósio Brasileiro de Automação Inteligente, v. 10. p. 450-455, 2011c.

SOUZA, A. L. de; SOARES, C. P. B. **Florestas nativas: estrutura dinâmica e manejo**. Viçosa: UFV, 2013, 322 p.

STANLEY, K. O. **Efficient Evolution of Neural Networks through Complexification**. Austin-TX: UT, 2004, 165 p. Tesis (Doctor of Philosophy) – The University of Texas.

STANLEY, K. O.; MIIKKULAINEN, R. Competitive Coevolution through Evolutionary Complexification. **Journal of Artificial Intelligence Research**, v. 25, p. 63-100, 2004.

STANLEY, K. O.; MIIKKULAINEN, R. Evolving Neural Networks through augmenting Topologies. **Evolutionary Computation**, v. 10, n. 2, p. 99-127, 2002.

THAINES, F.; BRAZ, E. M.; MATTOS, P. P. de; THAINES, A. A. R. Equações para estimativa de volume de madeira para a região da bacia do Rio Ituxi, Lábrea, AM. **Pesquisa Florestal Brasileira**, Colombo, v. 30, n. 64, p. 283-289, 2010.

VAN LAAR, A.; AKÇA, A. **Forest Mensuration: Managing Forest Ecosystems**. VON GADOW, K.; PUKKALA, T.; TOMÉ, M. (Ed.). Springer, 2. ed., v. 13, 2007, 383 p.

VEIGA, R. A. de A.; CARVALHO, C. M. de; BRASIL, M. A. M. Determinação de equações de volume para árvores de *Acacia mangium* Willd. **Cerne**, v. 6, n. 1, p. 103-107, 2000.

VELTEN, K. **Mathematical Modeling and Simulation: Introduction for Scientists and Engineers**. Wiley-VCH, Weinheim, 2009, 364 p.

VENABLES, W. N.; RIPLEY, B. D. **Modern applied Statistics with S.** 4. ed. Springer, New York, 2002, 504 p.

WEST, P. W. **Tree and Forest mensuration.** 2. ed. Springer, Berlin Heidelberg, 2009.

ZÁKIA, M. J. B.; PAREYN, F. G.; RIEGELHAUPT, E. Equações de peso e de volume para oito espécies lenhosa nativas do Seridó, RN. In: IBAMA. **Plano de manejo florestal para a região do Seridó do Rio Grande do Norte.** PNUD / FAO / IBAMA, Natal, 1992, 1-92 p.

## CAPÍTULO 1

### PARAMETRIZAÇÃO DE REDES NEURAIS PARA ESTIMATIVA DE VOLUME EM CAATINGA ARBÓREA

#### RESUMO

O volume é a principal variável quantitativa a ser estimada nos processos de inventário florestal e, em vegetações naturais, é o melhor indicador para obter o estoque de madeira e auxiliar no manejo desse recurso. Nesse sentido, as técnicas convencionais de quantificação volumétrica se baseiam em modelos de regressão, o que nem sempre traz uma resposta factível devido à limitação de inclusão de outros fatores que interferem na dinâmica das vegetações naturais. Assim, as Redes Neurais Artificiais têm sido difundidas como opção às limitações dos modelos de regressão, devido à facilidade dessas redes em captar padrões, bem como na inclusão de variáveis quantitativas e qualitativas. Entretanto, mesmo que as RNA tenham evidenciado os melhores resultados para quantificação em volume, há carência de informações a respeito de configurações iniciais para um melhor desempenho da rede. Portanto, o objetivo do presente trabalho foi testar diversas configurações para dois tipos de redes (MLP e RBF), com os algoritmos *Resilient propagation (Rprop+)*, *Skip-layer*, *Neuroevolution of Augmenting Topologies (NEAT)*. Foram utilizados dados de cubagem de 300 árvores da Caatinga arbórea, sendo 70% usado para treinamento e 30% para validação. Para treinamento e validação das redes, foram usadas combinações das variáveis diâmetro a 1,3 m (DAP), diâmetro a 0,3m (DAS) e altura total (HT), cinco funções de ativação e diferentes números de ciclos. Para validar o desempenho das redes, os critérios estatísticos adotados foram a Raiz do Erro Quadrático Médio (RMSE%), a correlação linear entre o volume estimado e o observado ( $r_{yy}'\%$ ) e seu gráfico, além do histograma de frequência dos erros percentuais. Observou-se que o algoritmo *NEAT* com 1.000 indivíduos e densidade 0,1 apresentou o melhor desempenho dentre os algoritmos testados. Para este tipo de rede, recomenda-se um número de 1.000 ciclos.

**Palavras-chave:** inteligência artificial; topologia; neurônios; algoritmos genéticos

## 1. INTRODUÇÃO

A estimativa do volume das árvores é uma das principais atividades florestais para quantificação do estoque em madeira em uma floresta. Por ser uma variável que operacionalmente demanda um maior dispêndio e necessita de uma acurácia nos inventários, várias técnicas são utilizadas para obtenção indireta de valores que evidenciem uma realidade factível. Assim, algumas variáveis como solo, espécie e bioma interferem diretamente no volume das árvores, o que dificulta o uso de modelos volumétricos consagrados que se atêm, apenas, ao uso das principais variáveis (diâmetro e altura), inclusive nas florestas plantadas, em que as equações possuem um ajuste superior. Nesse sentido, as Redes Neurais Artificiais (RNA) se tornam capazes de realizar uma projeção não linear do comportamento dos dados, além de habilitar a inserção livre e menos dispendiosa de variáveis categóricas, que é uma prática bastante trabalhosa aos modelos convencionais com uso de variáveis *dummy*.

As Redes Neurais Artificiais (RNA) tentam expressar computacionalmente o mesmo princípio biológico aplicado ao cérebro humano e, através da inserção de informações novas no sistema, são capazes de tomar decisões para resolução de problemas complexos. Este processo só é possível porque a rede trabalha com diversas funções matemáticas que podem se comunicar entre si através de conexões atribuídas a pesos sinápticos, até gerar um resultado com o mínimo de erro aceitável, processo este conhecido como treinamento (BRAGA et al., 2000; 2014; HAYKIN, 2001). Outrossim, com a rede treinada a partir de dados de uma floresta, ela se concentra em detectar padrões aceitáveis para então ter a capacidade de responder com o mínimo de erro e conseguir generalizar, inclusive, quando novos dados são apresentados a uma rede já treinada.

Alguns resultados satisfatórios com RNA têm sido apresentados em florestas equiâneas, reforçando sua superioridade em comparação aos modelos tradicionais de volume (GORGENS et al., 2009; BINOTI, 2012; BINOTI et al., 2014). Dessa maneira, para florestas com este perfil, é possível encontrar configurações de RNA para diversos algoritmos (BINOTI et al., 2014), sendo as redes *Multilayer Perceptron* treinadas com o *backpropagation* e *Resilient propagation* as mais utilizadas na estimativa de volume (GORGENS et al., 2014). Assim, o número de neurônios na

camada oculta, além da escolha do melhor algoritmo e função de ativação, tem sido uma das maiores preocupações no momento da configuração da arquitetura da rede para treinamento, por ser um dos principais fatores para dois processos que devem ser evitados em uma rede: o *overfitting*, ou memorização dos dados iniciais e o *underfitting*, que é o não cumprimento da tarefa desejada. Nesse sentido, recomenda-se que uma rede obtenha uma arquitetura simplificada e com o menor número de neurônios possível na camada oculta (HAYKIN, 2001; BINOTI, 2012; BRAGA et al., 2014).

Existem diversos algoritmos em programas computacionais disponíveis para o treinamento de redes neurais, sendo os mais comuns e com bons resultados o *backpropagation* e o *Resilient propagation*, em comparação a outros algoritmos (BINOTI, 2012). Em trabalhos com florestas nativas, apesar da escassez na utilização de RNA, o *backpropagation* é o mais difundido, com a utilização de parâmetros que também são aplicados em plantadas (FRANCO, 2012; LIMA, 2014, ARAÚJO et al., 2015) e, portanto, pouco elucidativos quanto ao uso da melhor função de ativação e algoritmo a serem utilizados em situações similares. No entanto, atualmente a escolha do algoritmo *Resilient propagation* vem se tornando usual tanto para nativas quanto para exóticas, por se tratar de uma adaptação melhorada do *backpropagation* (BRAGA et al., 2014; ARAÚJO, 2015b).

Outras propostas têm sido aprimoradas e utilizadas no ramo computacional e florestal, como é o caso dos algoritmos *Neuroevolution of Augmenting Topologies* (NEAT) e *Skip-layer connections*. O algoritmo NEAT, que é baseado em algoritmos genéticos (AG), tem um poder de configuração amplo, através de estruturas mais simplificadas que coevoluem. Redes treinadas com este algoritmo se adaptam ao comportamento dos dados e mutam às estruturas o mais simplificadas possíveis para a resolução do problema proposto (STANLEY e MIIKKULAINEN, 2002). O *Skip-layer*, entretanto, possui conexões especiais que pulam a camada oculta, em que os neurônios da camada de entrada são ligados diretamente à camada de saída (RIPLEY, 1996).

Portanto, objetivou-se nesse capítulo buscar a melhor configuração de RNA para dois tipos de rede (MLP e RBF), utilizando os algoritmos *Resilient propagation* (Rprop+), *Neuroevolution of Augmenting Topologies* (NEAT), *Skip-layer connections* e redes de base radial (*Radial Basis Function*, RBF), testando a combinação de várias

configurações de entrada, funções de ativação e número de neurônios na camada oculta, para estimativa de volume de espécies da Caatinga arbórea.

## 2. MATERIAL E MÉTODOS

### 2.1. Caracterização da área

Os dados utilizados neste estudo foram coletados na Floresta Nacional Contendas do Sincorá (FLONA), que é uma unidade de conservação inserida no grupo de uso sustentável, segundo a Lei nº 9.985, que estabelece o Sistema Nacional de Unidades de Conservação (BRASIL, 2000). Fica localizada no município de Contendas do Sincorá-BA, nas coordenadas 13°55'14,51"S e 41°6'54,79"O, e possui uma área de 11.215,78 hectares. Foi criada em 1999 como parte da compensação ambiental acordada entre o IBAMA e a antiga empresa de mineração proprietária. Antes de sua criação como Unidade de Conservação, a propriedade era de uso exploratório de carvão, que subsidiava as atividades da empresa Magnesita S.A., no período de 1990 a 1994. Posteriormente, foi vendida para a empresa Siderúrgica Itaminas S.A., que atuou até 1997, cedendo a propriedade, após esse período, como forma de aquisição de Créditos de Reposição Florestal.

Na área da FLONA, pode-se encontrar três tipos de tipologias vegetacionais: Caatinga arbórea arbustiva, Caatinga arbustiva fechada e complexo herbáceo-arbustivo. Destes, predomina a Caatinga arbórea arbustiva, seguida pela arbustiva fechada e, com relação a seus estratos, apresenta vegetação de porte compreendido entre 3,5 a 7,0 m, com poucas árvores maiores que 8,0 m de altura. Em levantamentos florísticos foram encontradas diversas espécies de interesse econômico, medicinal, alimentação humana e animal, para formulação das atividades de manejo que podem ser aplicadas à área (IBAMA, 2006).

A região enquadra-se no clima semiárido quente do tipo BSwh' de Köppen, com estação chuvosa no período de novembro a janeiro, precipitação entre 500 a 1.000 mm anuais, temperatura de 21 a 28 °C e umidade relativa de 60 a 70%. Predominam Argissolos e Latossolos Vermelho-Amarelo, com expressivas faixas de Neossolos Litólicos a oeste e leste do município de Contendas do Sincorá (INEMA, 2014).

A FLONA é cortada por dois córregos principais: sentido norte, formado por mais três ramos, o córrego da Garapa, que corta toda a sua extensão de oeste a leste, indo desaguar no Rio de Contas, onde encontra o córrego da Goiabeira. Este,



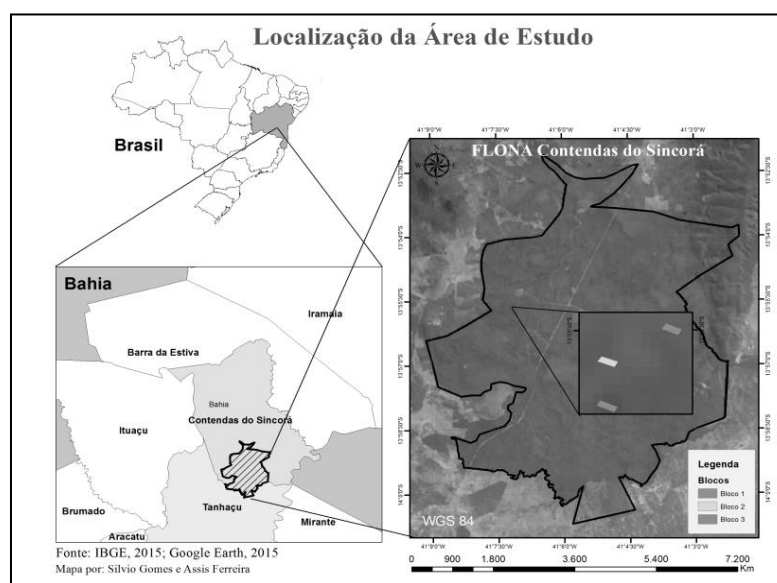
por conseguinte, é formado por outro ramo mais ao norte e que divide a FLONA de oeste a leste entre os municípios de Contendas do Sincorá e Tanhaçu (IBAMA, 2006).

## 2.2. Área amostral e critérios de inclusão

Na etapa inicial foram utilizados os dados de inventário para seleção dos indivíduos que foram suprimidos para a cubagem rigorosa. No inventário, foram distribuídos em uma área de Caatinga arbórea arbustiva, três blocos com 16 parcelas cada, sendo cada parcela com dimensão de 20 x 20 m, com quatro tratamentos distribuídos ao acaso.

Os tratamentos consistem no corte raso, corte seletivo das espécies de interesse econômico, corte com base no diâmetro de inclusão mínimo e a testemunha. Foram contabilizados todos os indivíduos com diâmetro à altura de 1,3 m (DAP)  $\geq$  5 cm, medidos com suta, além de aferir a variável altura por estimativa visual em todas as parcelas. Tanto a etapa da simulação do manejo quanto a do inventário não foram contempladas neste trabalho.

O delineamento foi utilizado para delimitar os espaços onde foram executadas as atividades de supressão das espécies para realização da cubagem rigorosa e dos tratamentos referente à simulação do manejo florestal sustentável (Figura 1).



**Figura 1** – Localização da FLONA Contendas do Sincorá, com a respectiva alocação dos três blocos onde foram aplicados os tratamentos e as atividades de cubagem rigorosa.

### 2.3. Critérios para cubagem

Para uma melhor amostragem na obtenção do volume comercial com casca ( $VC_{cc}$ , em  $m^3$ ) das espécies, foi utilizado o critério da distribuição por classe diamétrica, adotando-se amplitude de 5 cm para as classes, em referência aos critérios estabelecidos para florestas nativas em estágio inicial ou secundário de regeneração, conforme Souza e Soares (2013) (Tabela 1).

**Tabela 1** – Frequência absoluta por classe diamétrica dos indivíduos mensurados na Floresta Nacional Contendas do Sincorá (FLONA), de espécies da Caatinga arbórea.

Classes	Intervalos	Frequência cubagem	Vol. ( $m^3$ ) <sup>1</sup>
1	4,9  — 9,9	191	2.98483
2	9,9  — 14,9	63	3.26639
3	14,9  — 19,9	23	2.58930
4	19,9  — 24,9	12	2.76315
5	24,9  — 29,9	3	0.94196
6	29,9  — 34,9	1	0.21927
7	34,9  — 39,9	3	1.37436
8	39,9  — 44,9	2	1.28857
9	44,9  — 49,9	1	0.72836
10	49,9  — 54,9	1	1.07307
<b>TOTAL</b>		<b>300</b>	<b>17.22926</b>

<sup>1</sup> volume comercial da cubagem rigorosa referente ao somatório por classe diamétrica.

Foi realizada cubagem utilizando o método de Smalian, com seções ao longo do fuste, nas alturas iguais a 0,10; 0,30; 0,50; 0,70; 1,00; 1,30; 2,00 m. Após esta marca, as seções foram tomadas de um em um metro até o limite de 3 cm de diâmetro, considerado o limite mínimo para fuste comercial. Foram medidos também galhos com circunferência acima de 3 cm de diâmetro, averiguando o diâmetro mais homogêneo nas seções e seu comprimento.

### 2.4. Base de dados

Foram utilizados pares de dados de volume provenientes de cubagem rigorosa de 300 observações de 24 espécies identificadas, 5 espécies a nível de gênero e 63 consideradas morfoespécies (ou sem identificação), devido à ausência

de material botânico fértil e terem sido cubadas em período de caducifolia originada por período de baixíssima precipitação (APÊNDICE A).

As variáveis quantitativas utilizadas foram: diâmetro com casca a 1,3 m de altura (DAP), altura total – em metros (HT), e o volume comercial com casca (VC<sub>cc</sub>, em m<sup>3</sup>) (Tabela 2).

**Tabela 2** – Valores globais das variáveis quantitativas mensuradas na cubagem.

Variável	Mínimo	Máximo	Média	Desvio Padrão
DAP (cm)	5,00	52,60	10,50	6,96
Altura total (m)	3,50	11,50	6,74	1,41
Volume comercial (m <sup>3</sup> )	0,00354	1,07307	0,05743	0,11392

## 2.5. Redes Neurais Artificiais

No processo de parametrização e configuração das redes, utilizaram-se dois tipos de arquitetura: as redes *Multilayer Perceptron* (MLP) e a *Radial Basis Function* (RBF). Para as redes MLP, foram avaliados três algoritmos com funcionalidades de codificação distintas: o algoritmo *Resilient propagation*, o *Neuroevolution of Augmenting Topologies* (NEAT) e o *Skip Layer connections*. Todos os tipos e algoritmos testados podem ser encontrados no pacote de funcionalidades do Sistema para geração e aplicação de Redes Neurais Artificiais (Neuroforest), versão 4.0.

Para treinamento e validação dos dois tipos de arquitetura de rede, foi utilizado 70% dos dados para treinamento e 30% para validação (ARAÚJO, 2015b). A etapa de validação visa determinar a capacidade da rede em estimar satisfatoriamente para dados desconhecidos, ou seja, se a rede é capaz de extrapolar saídas coerentes na inserção de novos dados de entrada.

Nas redes MLP, foram testadas diferentes combinações de arquitetura onde alternaram-se as variáveis de entrada, número de neurônios na camada oculta e diferentes funções de ativação. Como variáveis quantitativas de entrada, utilizou-se o diâmetro à altura 1,3 m do solo (DAP, em cm), diâmetro à altura de 0,3 m do solo (DAS, em cm) e altura total (HT, em metros); e o volume comercial com casca (VC<sub>cc</sub>, em m<sup>3</sup>) como variável de saída. Assim, foram geradas seis diferentes combinações de entrada: 1) DAP; 2) DAS; 3) DAP+DAS; 4) DAP+HT; 5) DAS+HT; 6) DAP+DAS+HT. O número de neurônios na camada oculta variou de 1 a 3 neurônios

para cada combinação, estabelecendo um neurônio para cada variável introduzida. As funções de ativação atribuídas foram a Sigmoide (ou logística), Tangente hiperbólica, Logarítmica, Seno e Softmax, tanto para os neurônios da camada oculta quanto para os de saída.

Nas redes MLP com o algoritmo *Resilient propagation*, foi utilizada apenas a variação  $Rprop+$ . No algoritmo NEAT, há a possibilidade de alterar configurações de população e suas densidades iniciais. Nesse sentido, foram realizados testes para o número de indivíduos por população de 300, 600, 800, 1.000 e densidades iniciais de 0,1 e 0,5, em referência aos parâmetros avaliados por Araújo (2015a). Já para o *Skip-layer*, há apenas a possibilidade de treinar redes com e sem recorrência. Para este estudo foi utilizado apenas redes treinadas sem recorrência, por não haver diferença entre os dois processos (ARAÚJO et al., 2015).

As redes de função de base radial (*Radial Basis Function* ou RBF) foram treinadas variando apenas as variáveis de entrada e o número de neurônios para cada dimensão com o algoritmo *Rprop*. O número de neurônios por dimensão variou de 1 a 20, fixando duas dimensões como padrão, para confecção de gráfico demonstrativo que evidenciasse a presença de *overfitting*. Para as redes RBF, não foram testadas as diversas funções de ativação devido às características das redes RBF que, por padrão, processam os dados de forma não linear (funções de base radiais/gaussiana) na camada oculta e linear na camada de saída (SILVA et al., 2010).

Todas as redes foram treinadas com o critério de parada de 3.000 ciclos e erro médio quadrático de 0,0001, em que o treinamento de cada RNA finalizava quando um dos dois critérios fosse alcançado. As variáveis foram normalizadas no intervalo entre 0 e 1 antes do treinamento (BINOTI et al., 2014).

Com a melhor rede selecionada, foram testadas também diferentes amplitudes de ciclos a fim de determinar a melhor época em que a rede se estabiliza: a partir de 50, 100, 500, 1.000, 2.000, 3.000, 4.000 e 5.000 ciclos. Assim, foi gerado um gráfico que evidenciou o momento de estabilidade da curva para o treinamento e validação.

Para cada tipo de rede, treinou-se um total de cinco RNA, totalizando 270 combinações diferentes e, portanto, 1.350 redes treinadas. Por fim, foram retidas as cinco melhores redes MLP e seis melhores para RBF (para cada variação de

neurônios de entrada), conforme melhores medidas de precisão geradas, para cada algoritmo testado, variando as cinco funções de ativação (exceto para as RBF) para confecção dos gráficos, relacionando o volume observado e o estimado, e histogramas de frequência dos erros percentuais.

## 2.6. Critérios estatísticos para avaliação do desempenho das RNA

As estatísticas utilizadas para análise do desempenho das redes foram a correlação entre os valores estimados e observados de volume ( $r_{Y\hat{Y}}$ ), e a raiz do erro quadrado médio (RMSE%). A análise gráfica consistiu na inspeção estatística da dispersão dos erros (resíduos) percentuais em relação aos valores observados para o histograma de frequência dos erros percentuais, conforme Binoti (2010), sendo:

$$erro_{\%} = \frac{(Y - \hat{Y})}{Y} * 100$$

em que,  $Y$  é o volume observado e  $\hat{Y}$  é o volume estimado.

A correlação entre os valores observados e estimados ( $r_{Y\hat{Y}}$ ) indica a força e a direção da relação entre as duas variáveis. Essa correlação visa atribuir um grau associativo entre os valores estimados e os observados e, com o auxílio da análise de resíduos, permite inferir sobre a qualidade da estimativa. Quanto mais próxima de 1, maior a correlação entre as variáveis (BINOTI, 2010). Então:

$$r_{Y\hat{Y}} = \frac{cov(Y, \hat{Y})}{\sqrt{s^2(Y)s^2(\hat{Y})}}$$

sendo que,  $cov$  é a covariância e  $s^2$  é a variância.

A raiz do erro quadrado médio (RMSE) avalia a diferença quadrática média entre os valores observados e os valores estimados (BINOTI, 2010). Quanto menor o RMSE, melhor a precisão da estimativa (MEHTÄTALO et al., 2006), sendo:

$$RMSE_{\%} = \frac{100}{\bar{Y}} * \sqrt{\frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n}}$$

em que  $n$  é o número total de dados e  $\bar{Y}$  a média do volume observado.

### 3. RESULTADOS E DISCUSSÃO

A fim de dinamizar o fluxo de informações, os resultados das redes NEAT foram organizados em tabela distinta, devido às diferenças nas variações dos parâmetros testados e avaliados. Os resultados relacionados às redes com os melhores desempenhos estatísticos durante o treinamento e validação (generalização), das redes do tipo MLP (com *Resilient propagation* e *Skip-layer*) e redes do tipo RBF, estão apresentados na Tabela 3.

**Tabela 3** – Resultados dos desempenhos das melhores redes para cada algoritmo e funções de ativação utilizadas, para estimar volume comercial com casca da Caatinga arbórea.

Tipo/Algoritmo	RNA	Entrada	FA	NCO	Treinamento		Validação	
					RMSE%	ryy’%	RMSE%	ryy’%
MLP/ <i>Rprop+</i>	1	DAP; HT	Log	2	49,36	96,73	56,55	98,32
	2	<b>DAP; DAS</b>	<b>Seno</b>	<b>3</b>	<b>50,14</b>	<b>96,66</b>	<b>45,20</b>	<b>99,05</b>
	3	DAP; DAS	Tang. Hip.	3	47,18	97,06	46,40	98,59
MLP/ <i>Skip-layer</i>	4	DAP	Log	3	49,44	96,76	41,95	98,98
	5	DAP	Seno	3	49,80	96,70	45,62	98,96
	6	<b>DAP; DAS</b>	<b>Sigmoide</b>	<b>3</b>	<b>43,18</b>	<b>97,54</b>	<b>25,57</b>	<b>99,16</b>
	7	<b>DAP; DAS</b>	<b>Softmax</b>	<b>3</b>	<b>48,95</b>	<b>96,82</b>	<b>36,14</b>	<b>99,17</b>
	8	DAP; DAS	Tang. Hip.	3	49,94	96,69	47,60	98,97
RBF/ <i>Rprop</i>	9	<b>DAP</b>	<b>Gaussiana</b>	<b>19</b>	<b>39,04</b>	<b>97,98</b>	<b>27,05</b>	<b>99,11</b>
	10	DAS	Gaussiana	12	72,46	92,24	50,66	96,63
	11	<b>DAP; DAS</b>	<b>Gaussiana</b>	<b>10</b>	<b>33,63</b>	<b>98,50</b>	<b>29,10</b>	<b>99,04</b>
	12	DAP; HT	Gaussiana	3	54,02	96,07	65,43	95,29
	13	DAS; HT	Gaussiana	3	76,35	90,52	70,65	94,16
	14	<b>DAP; DAS; HT</b>	<b>Gaussiana</b>	<b>10</b>	<b>33,63</b>	<b>98,50</b>	<b>29,10</b>	<b>99,04</b>

FA = Função de ativação; NCO = Número de neurônios na camada oculta (ou na dimensão); RMSE% = raiz do erro quadrático médio, em percentual; ryy’= coeficiente de correlação linear de Pearson.

Para o algoritmo *Resilient propagation* (*Rprop+*), foram retidas apenas três redes por conta da não convergência deste algoritmo para as funções de ativação Sigmoide (ou logística) e Softmax. Este tipo de comportamento se contrapõe ao que é convencional para a função sigmoide, por se tratar da principal função a ser utilizada em diversos estudos com o mesmo algoritmo, tanto para nativas quanto para exóticas (BINOTI, 2012; FRANCO, 2012; LIMA, 2014). Segundo Binoti et al. (2014), o algoritmo pode não obter resultados satisfatórios em quantidade de neurônios inferior a três. Este aspecto pode ser um dentre alguns entraves, já que o algoritmo em questão não traz garantias quanto à convergência em regiões de baixo gradiente e mínimos locais (HAYKIN, 2001).

Entretanto, um aumento no número de neurônios na camada oculta nem sempre é garantia de melhores desempenhos quando se estende a estrutura e

complexidade da rede. Dentre os principais eventos esperados quanto ao aumento da complexidade, é o fenômeno chamado de *overfitting*, que mostra a capacidade de memorização dos dados pela arquitetura (ou super-treinamento), o que torna a rede muito flexível a ponto de memorizar também ruídos, ocasionando maior falha no momento de generalização (BRAGA et al., 2000; 2014; HAYKIN, 2001; 2009). Nesse sentido, redes menos robustas e com apenas um neurônio na camada oculta, têm apresentado bons resultados para o cálculo de volume em florestas (SILVA et al., 2009; BINOTI et al., 2014), mas isso não foi suficiente para as redes treinadas nesse estudo (Tabela 3).

Outro aspecto para a não convergência do algoritmo pode estar associado às características das RNA do tipo *perceptron*. Segundo Braga et al. (2014), este tipo de arquitetura, através do teorema de convergência, sempre encontra uma solução em um número finito de iterações, caso as classes sejam linearmente separáveis, dentro de um limiar linear ou de forma quadrática. Bailey (2015) comenta que o algoritmo *Resilient propagation* (Rprop) pode encontrar problemas em detectar o erro mínimo local devido a um gradiente de busca *ad-infinitum*, que faz uma varredura do valor real, através de vetores que agem de forma cíclica ao redor do erro mínimo global e, conseqüentemente, gerando a não convergência. Esta pode ser a principal razão para a não convergência do algoritmo para as duas funções, além de obter as piores estimativas para uma base de dados com grande heterogeneidade e ruído.

Em análise à Tabela 3, observa-se que não houve grandes mudanças no desempenho dos algoritmos *Rprop+* e *Skip-layer*, em se tratando do seu treinamento. Na validação, houve uma melhora sutil, porém significativa, quanto à diminuição do erro percentual para o algoritmo *Skip-layer*. Apesar do alto percentual de erro no treinamento, a rede com *Skip-layer* foi a que apresentou o maior poder de generalização, com erro de 25%, se comparada às outras duas redes apresentadas, com função de ativação sigmoide.

Para as redes com *Skip-layer connections*, apesar dos maiores erros no treinamento, a RNA 6 apresentou o menor erro na validação dos dados, se comparada a todas as arquiteturas testadas. Redes treinadas para nativas com este algoritmo tendem a apresentar melhores resultados que as próprias NEAT, mesmo evidenciando ótimos parâmetros estatísticos para os dois algoritmos na Caatinga

arbórea (ARAÚJO, 2015a). Outrossim, os resultados apresentaram um maior percentual de erro para o treinamento e menor para validação, se comparado com as redes NEAT, RBF e *Rprop+* (Tabelas 3 e 4).

Através das principais medidas de precisão, pode-se observar que o algoritmo *Neuroevolution of Augmenting Topologies* (NEAT) não obteve resultados expressivamente superiores ao algoritmo *Skip-layer* na etapa de treinamento, mas foi o que obteve um maior equilíbrio entre os valores de treinamento e validação (Tabelas 3 e 4). A variação no tamanho da população e densidades iniciais, não foi decisiva para uma melhoria substancial no desempenho, porém a associação do diâmetro na base (DAS a 0,3m de altura) e o diâmetro a 1,3 m (DAP), foram as variáveis que conferiram às redes menores erros no momento de generalização, além da alta correlação (Tabela 4).

**Tabela 4** – Resultados estatísticos do desempenho das topologias de redes *Neuroevolution of Augmenting Topologies* (NEAT), com diferentes tamanhos de populações e densidades iniciais, para estimativa do volume comercial com casca (*VCcc*).

Entrada	RNA	Tamanho da população	Densidade inicial	Treinamento		Validação	
				RMSE%	ryy'%	RMSE%	ryy'%
DAP; DAS; HT	15	300	0,1	40,03	97,91	33,05	99,10
DAP	16	300	0,5	47,26	96,99	30,37	99,12
DAP; DAS; HT	17	600	0,1	36,88	98,18	31,01	98,98
DAP; DAS; HT	18	600	0,5	43,14	97,57	27,61	99,09
DAP; HT	19	800	0,1	38,70	98,13	32,93	98,72
DAP; DAS	20	800	0,5	39,49	97,95	27,36	99,13
<b>DAP</b>	<b>21</b>	<b>1000</b>	<b>0,1</b>	<b>41,82</b>	<b>97,69</b>	<b>27,42</b>	<b>99,05</b>
DAP; DAS	22	1000	0,5	46,26	97,18	28,72	99,13

RMSE% = raiz do erro quadrático médio, em percentual; ryy' = coeficiente de correlação linear de Pearson.

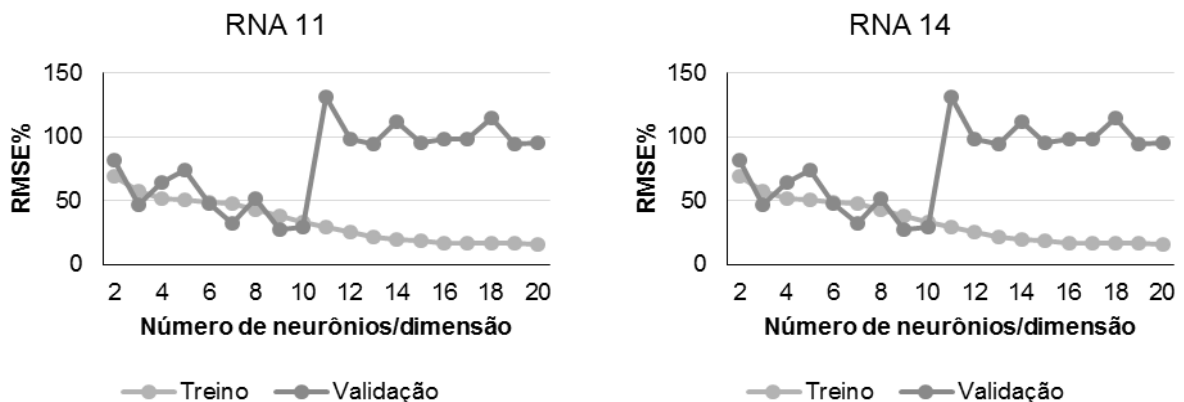
O ótimo desempenho do NEAT pode estar atrelado à liberdade do algoritmo em buscar diferentes topologias de rede a partir de uma estrutura básica, além de evoluir a depender da complexidade do problema. Estas topologias podem envolver variadas combinações entre as ligações das variáveis e os neurônios, flexibilização dos pesos, ampliando assim as chances da rede em encontrar o erro mínimo global (STANLEY e MIIKKULAINEN, 2002).

Em comparação às redes treinadas pelo *Resilient propagation* (*Rprop+*), as redes geradas pelo NEAT foram superiores por conta das diferenças no processamento de cada uma. O *Rprop+* utiliza do princípio que mantém uma única estrutura de rede, variando apenas os pesos sinápticos para cada neurônio, com



base em seu aprendizado e retroalimentação. No NEAT, as redes são alteradas a nível de estrutura e pesos, ligações entre neurônios e evolui até encontrar a estrutura mais simplificada possível, que represente o menor erro justificável. Em termos gerais, as redes NEAT tendem a buscar a melhor configuração de rede para os dados apresentados, diferentemente do algoritmo *Resilient propagation*, que mantém uma estrutura de rede fixa e exige um maior conhecimento inicial para a configuração da sua topologia. Assim, a melhor rede com o NEAT apresentou uma arquitetura simplificada, possuindo apenas um neurônio de entrada com a variável *DAP* (Rede 21).

Já as redes do tipo RBF evidenciaram comportamento estatístico similar às redes MLP. Redes de número 11 e 14 obtiveram os mesmos parâmetros estatísticos entre elas, para duas diferentes combinações de entrada. Nas redes 11 e 14, isto aconteceu inclusive, para uma mesma quantidade de neurônios. As redes RBF obtiveram melhores estimativas quando o número, para cada dimensão, atingiu a marca de 10 neurônios, conforme mostra a Figura 2.



**Figura 2** – Estabilização da raiz do erro quadrático médio (RMSE%) em função do número de neurônios por dimensão para duas redes RBF (11 e 14).

Este tipo de arquitetura evidenciou também que, acima de 10 neurônios, acentuou o processo de super treinamento e flexibilização da rede, ocasionando maiores erros na etapa de generalização. Na etapa de treinamento, as redes RBF se mantiveram estáveis a partir de 13 neurônios, porém apresentou os piores valores na etapa de validação. Este comportamento se dá devido às limitações do algoritmo em encontrar padrões no espaço de entrada das dimensões quando os dados

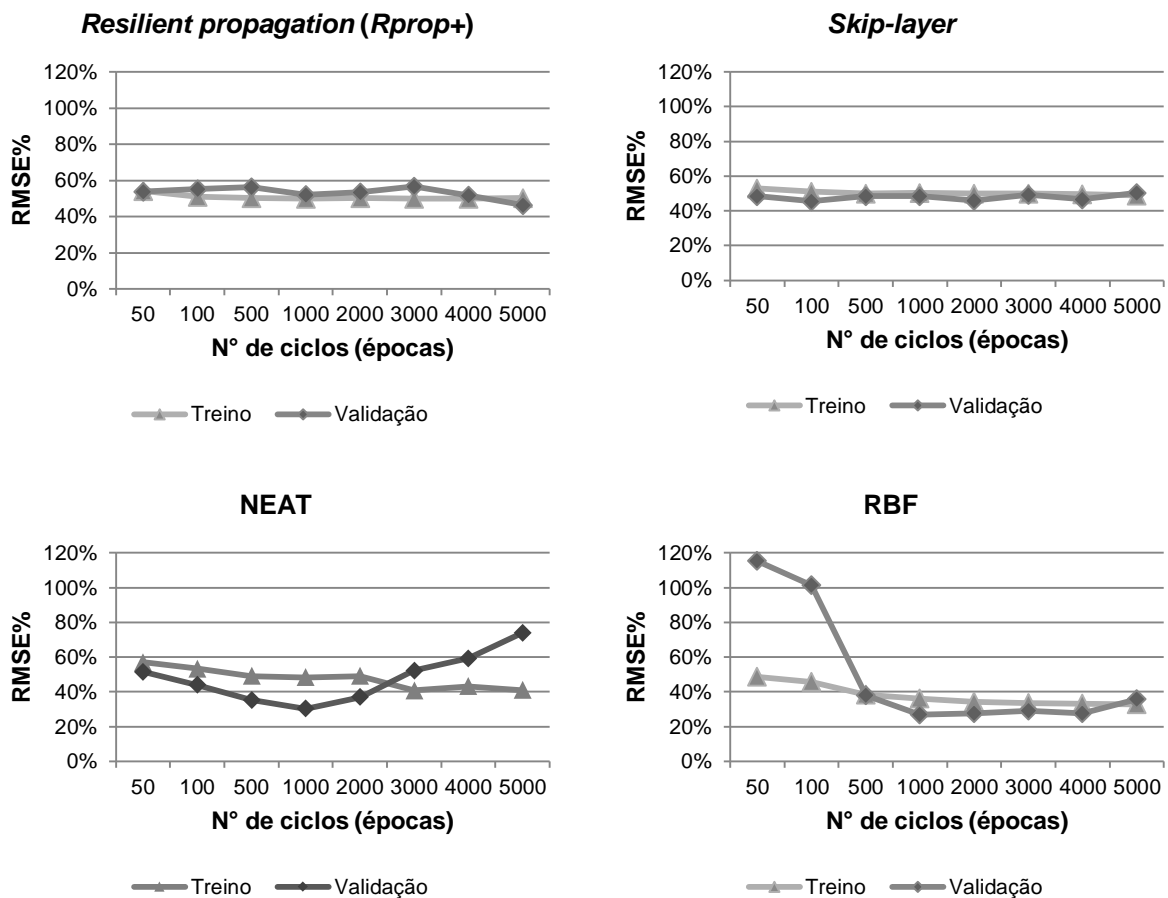
inseridos na rede são muito heterogêneos e pouco linearizáveis, ocasionando problemas de interpolação (HAYKIN, 1999; 2001).

Outro aspecto é que não houve convergência por parte do tipo de rede de base radial com apenas um neurônio em cada dimensão, sendo possível apenas a partir de dois neurônios. Como cada neurônio agrupa os padrões em um *cluster*, um número muito reduzido de neurônios faz com que a rede não extrapole corretamente, por não conter número suficiente de padrões para seu funcionamento, mesmo que a topologia tenha uma maior facilidade em mapear com exatidão o vetor de entrada para a saída correta. Porém, este último comportamento pode ser indesejável quando a base de dados se encontra com um grande patamar de ruído, gerando assim *overfitting* (BRAGA et al., 2014).

As relações do número de ciclos necessários para que todas as topologias testadas obtivessem os melhores resultados e apresentassem estabilidade tanto no treinamento quanto na validação, são apresentadas na Figura 3.

Observa-se que para os algoritmos *Resilient propagation (Rprop+)* e *Skip Layer*, a curva para treinamento apresentou comportamento estável a partir de 500 ciclos, com um padrão de diminuição do erro semelhante para ambas. Na etapa de validação, o algoritmo *Skip-Layer* evidenciou menores oscilações na curva em comparação ao *Rprop+*, em que, este último, não mostrou notória estabilidade da curva. Binoti et al. (2014) observaram que o algoritmo *backpropagation* necessita de um maior número de ciclos para convergência, sendo que foram testados de 500 a 3.000 ciclos e não observaram influências no tempo de treinamento. Isso indica a eficiência dos dois algoritmos quanto à taxa de processamento, evidenciando um menor dispêndio de tempo na busca do erro mínimo local.

O algoritmo NEAT e de base radial (RBF) apresentaram comportamento diferenciado em comparação ao *Resilient propagation (Rprop+)* e *Skip layer connections*. No NEAT, o algoritmo mostrou uma breve tendência à estabilidade do erro, em nível de treinamento, entre 3.000 a 5.000 ciclos e, no que se refere à validação, apresentou o melhor desempenho, com até 1.000 ciclos. Contudo, no intervalo entre 2.000 e 3.000 ciclos, a rede passou a demonstrar maior flexibilização e memorização dos dados no treinamento, apresentando maior falha na generalização dos dados.



**Figura 3** – Estabilização do erro de treinamento e validação em função do número de ciclos, para os algoritmos NEAT, *Rprop+*, *Skip-layer* e redes de base radial do tipo RBF.

Neste sentido, para as redes pelo NEAT, o processo pode não ser desejável por evidenciar uma queda no desempenho do algoritmo a partir do momento em que o número de ciclos é superior a 1.000. Valores de ciclos inferiores são interessantes nesta situação, por se tratar de algoritmo com alto consumo de tempo e processamento, se comparado às outras topologias e tipos de redes treinadas (STANLEY e MIIKKULAINEN, 2002; CAAMAÑOS et al., 2014). Haykin (2009) comenta que conhecer o período correto em que uma rede deve parar seu treinamento e poder de memorização dos dados é importante para determinar em quantos ciclos a rede para de evidenciar *overfitting*.

A rede do tipo RBF, apesar de ter iniciado estabilidade entre 1.000 e 2.000 ciclos, apresentou um comportamento diferenciado entre o treinamento e validação. Houve congruência entre as duas etapas (treinamento e validação) apenas a partir

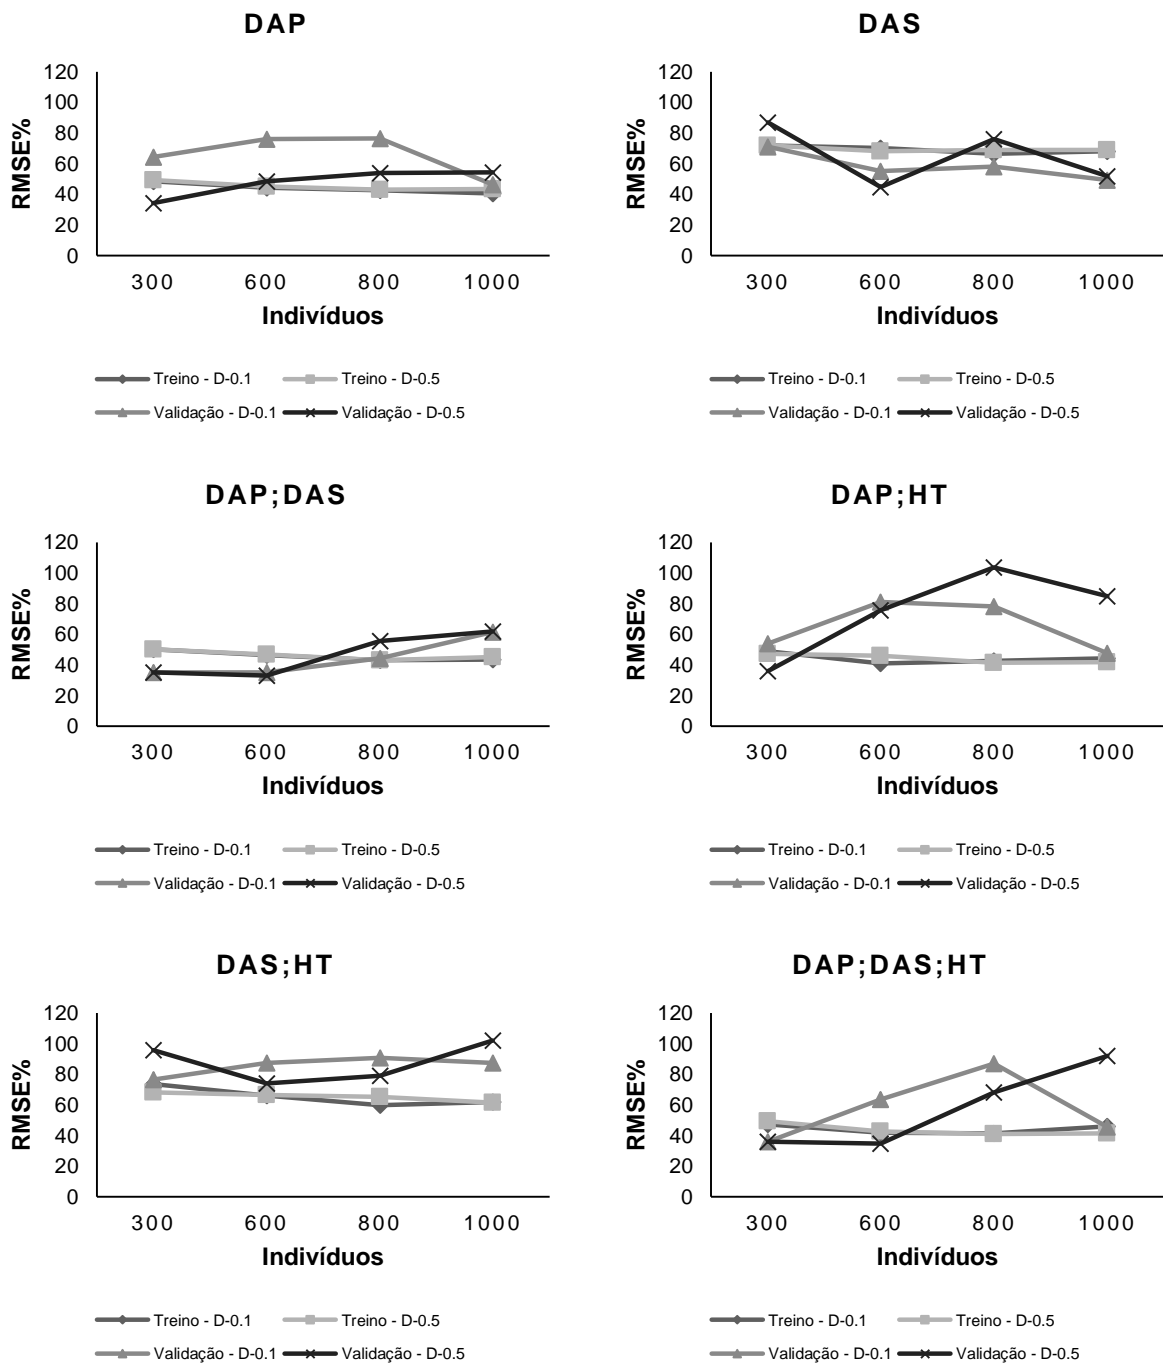
de 500 ciclos, momento em que a rede começou a não apresentar problemas de generalização.

Em relação ao número de populações suficientes para a melhor convergência e desempenho do algoritmo NEAT, observou-se que as redes obtêm melhores resultados quando treinadas com populações acima de 800 indivíduos (Figura 4).

Assim, em todas as combinações de neurônios de entrada, é nítido o comportamento semelhante nesta etapa nas duas densidades iniciais avaliadas (0,1 e 0,5), não ocorrendo grandes variações entre as populações, atingindo melhores resultados do algoritmo com 1.000 indivíduos na população inicial. Entretanto, este mesmo comportamento não ocorreu na etapa de validação, onde a densidade inicial de 0,5 apresentou o pior desempenho e, portanto, não deve ser utilizada. Esta afirmação é reforçada ao observar os gráficos (Figura 4) para a variável “DAS”, as combinações “DAP;DAS”, “DAP;HT” e “DAP;DAS;HT”, evidenciando seu baixo rendimento se comparada a 0,1 de densidade inicial.

Apesar da alta estabilidade no treinamento, houve uma baixa estabilidade no momento de validação. Este aspecto pode estar relacionado ao fato de as redes com o NEAT sempre iniciarem com estruturas de rede menos complexas para então coevoluir a uma estrutura que amplie as dimensões de busca. Estas estruturas adicionam novas conexões e nodos nas populações até atingir o erro mínimo global necessário para resolução do problema (STANLEY, 2004). Neste sentido, nota-se que quanto maior for o número de topologias iniciais que formarão os atributos de busca e varredura do mínimo global, ampliará a gama de possibilidades da rede em captar maiores espaços dimensionais com as melhores e mais simplificadas topologias para a resolução do problema proposto.

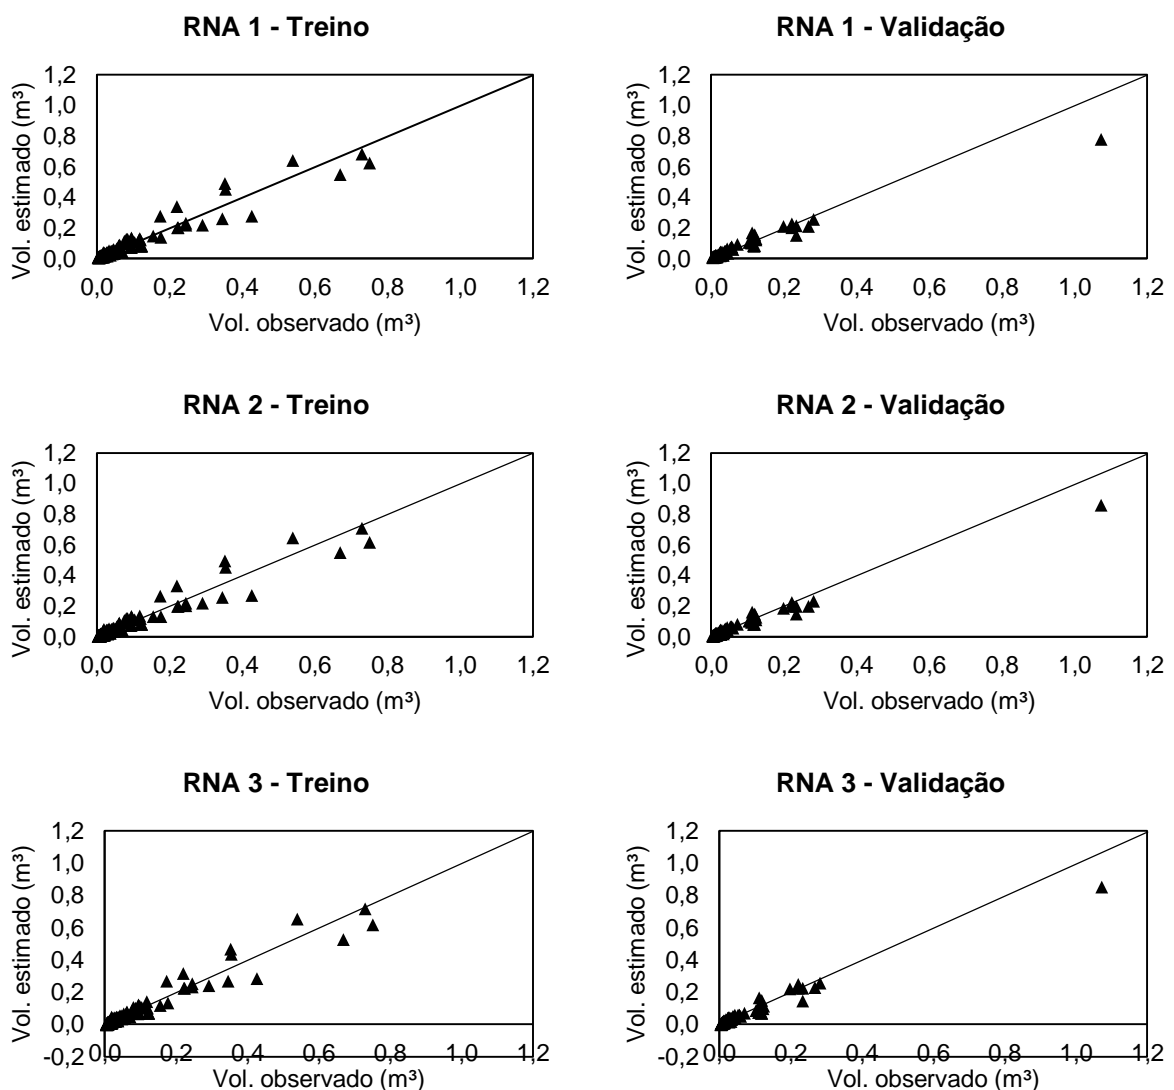
Araújo (2015a) observou que não houve diferença ao alterar as densidades iniciais para espécies da Caatinga arbórea. Entretanto, concluiu que redes treinadas pelo NEAT, com populações acima de 600 indivíduos e com densidade de 0,1, foram melhores para todas as fitofisionomias avaliadas. Assim, a melhor configuração para redes evolutivas apresenta populações mais elevadas, preferencialmente acima de 800 indivíduos e com densidade inicial de 0,1. Contudo, este tipo de inferência pode variar por se tratar de um algoritmo que trabalha por vias probabilísticas, bem como por ter em seu princípio computacional preceitos de programação evolutiva (BRAGA et al., 2014).



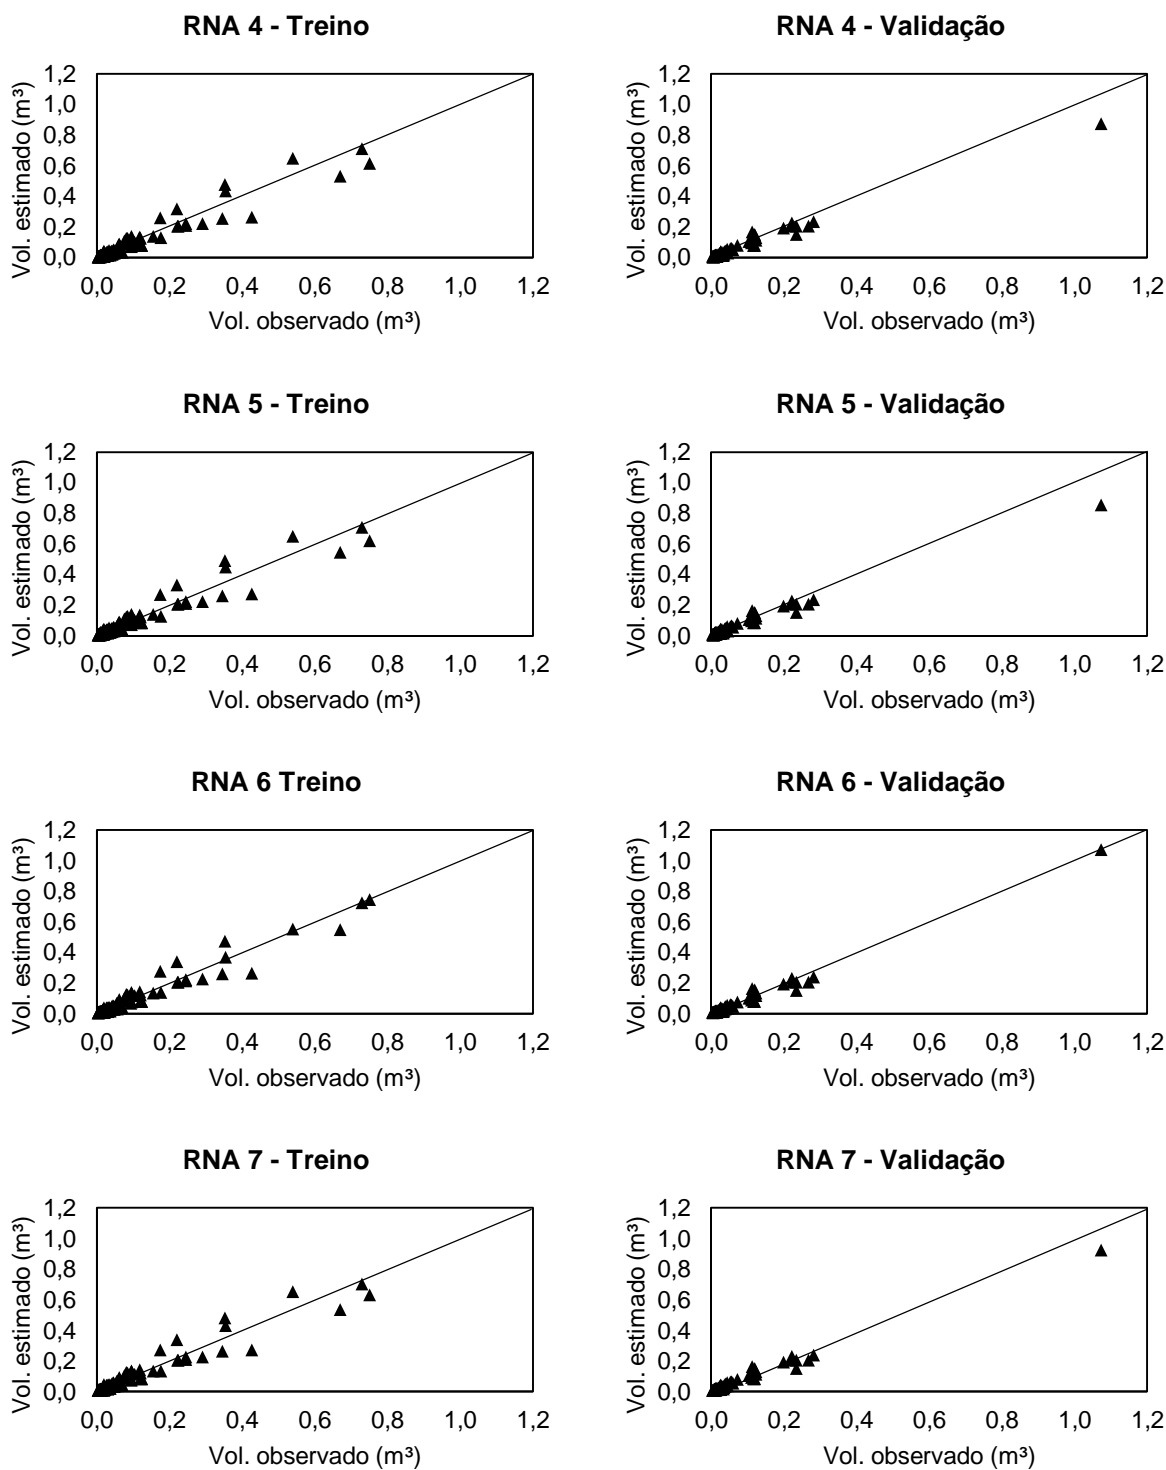
**Figura 4** – Desempenho das Redes *Neuroevolution of Augmenting Topologies* (NEAT), evidenciando o erro médio de todas as redes em função do número de indivíduos por população e densidades iniciais, tanto para treinamento quanto para validação e as diferentes combinações de variáveis de entrada avaliadas. Em que: D-0.1, densidade inicial de 0,1; D-0.5, densidade inicial 0,5.

Em análise aos gráficos referente à relação do volume observado e o volume estimado pelas redes, observa-se um alto grau de ajuste para todos os tipos de arquitetura. Isso explica a alta correlação nas medidas de precisão entre os dois

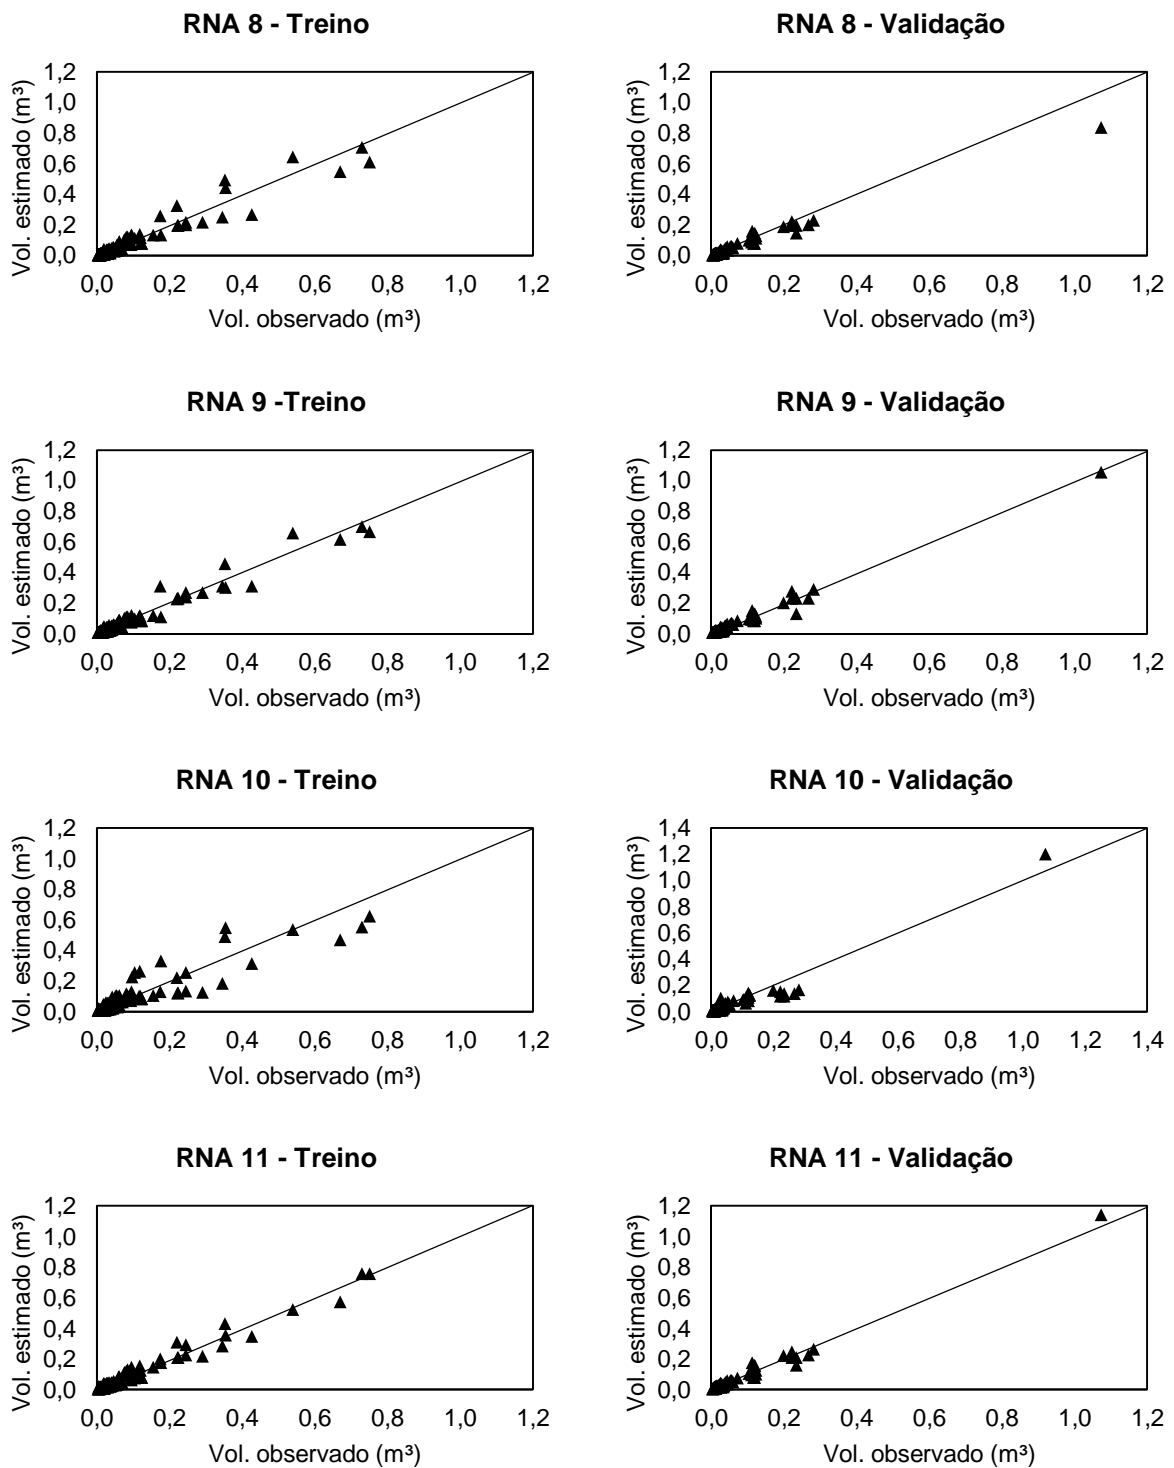
volumes, compreendidas entre 90 a 98% para treinamento e entre 94 a 99% para validação (Tabela 3). Assim, as redes do tipo MLP com algoritmo *Skip-layer* (RNA 6), NEAT (RNA 17 e 20) e do tipo RBF (RNA 11 e 14), foram as que apresentaram os melhores alinhamentos no sentido da reta, com linha de tendência mais próxima a um ângulo de 45°, que é o desejável para uma correlação de comportamento linear. No entanto, as redes de número 3 (*Resilient propagation*), com variável de entrada DAP e HT, e as redes 12 e 13, ambas RBF, foram as que obtiveram os piores ajustes, apresentando, inclusive, volumes com estimativas negativas (Figura 5).



**Figura 5** – Volume observado e o volume estimado (VC<sub>cc</sub>) das melhores redes selecionadas dos tipos MLP e RBF, sendo 70% dos dados para treinamento e 30% para validação. RNA 1 a 3, algoritmo *Resilient propagation* (Rprop+); RNA 4 a 8, *Skip-layer connections*; RNA 9 a 14, redes do tipo RBF; RNA 15 a 22, redes NEAT. “*Continua*”

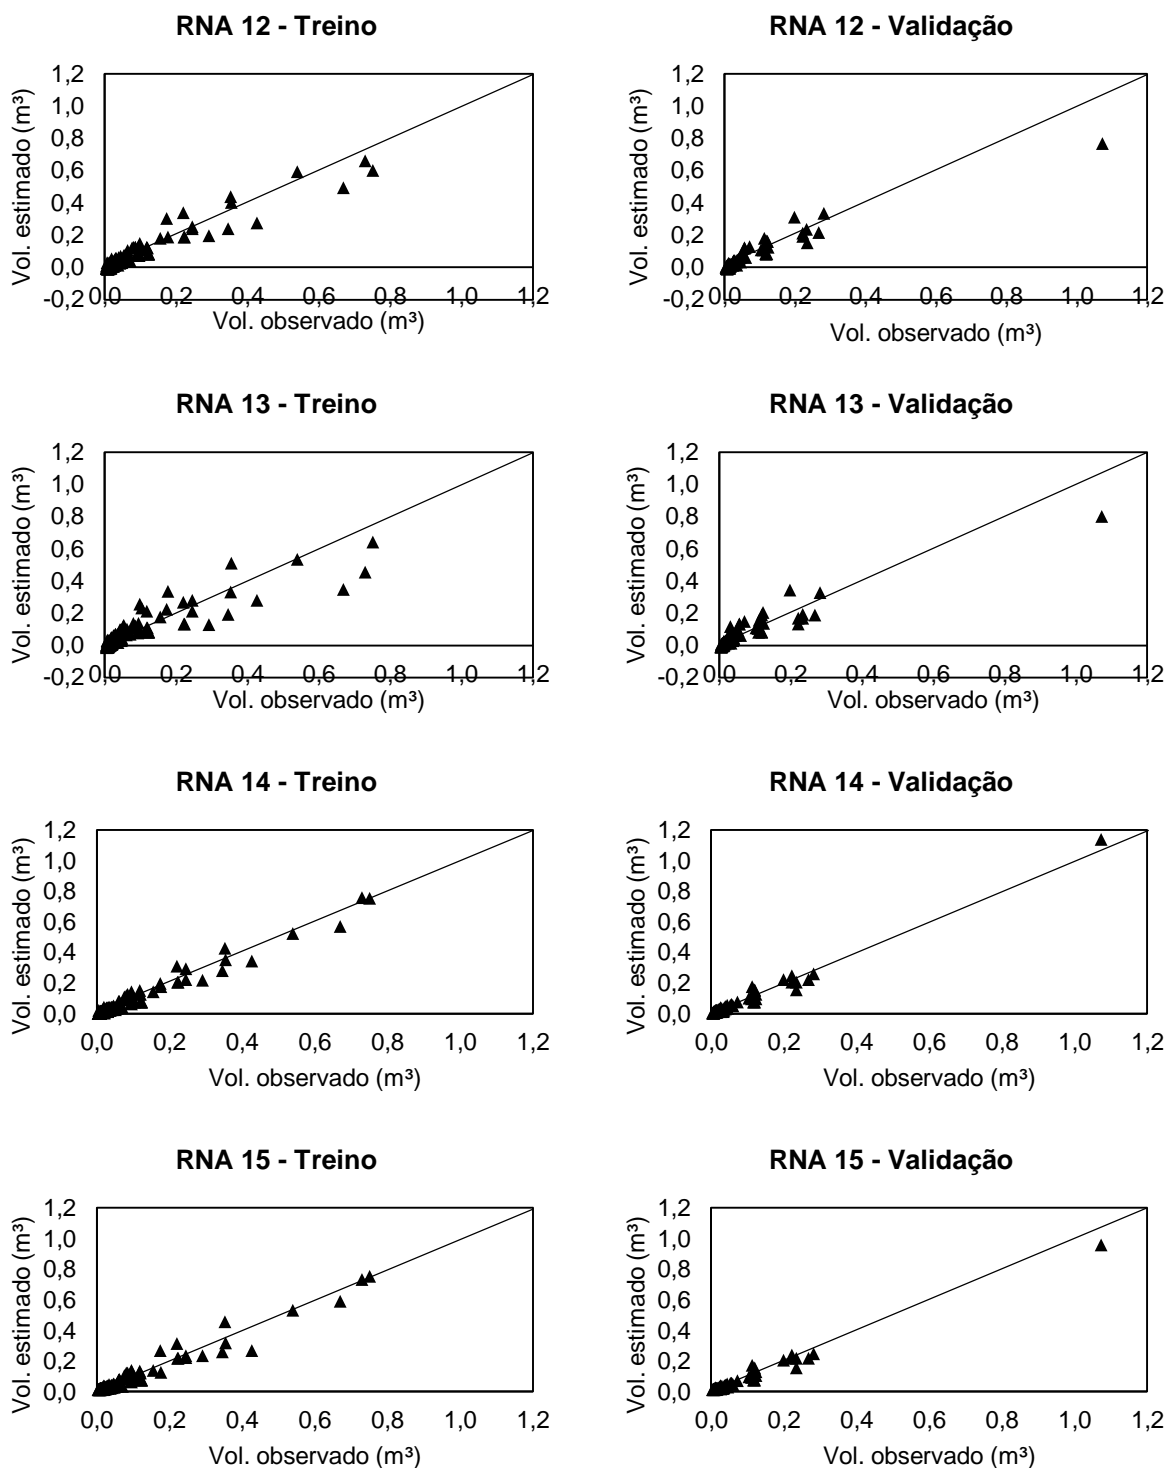


**Figura 5** – Volume observado e o volume estimado (VC<sub>cc</sub>) das melhores redes selecionadas dos tipos MLP e RBF, sendo 70% dos dados para treinamento e 30% para validação. RNA 1 a 3, algoritmo *Resilient propagation* (Rprop+); RNA 4 a 8, *Skip-layer connections*; RNA 9 a 14, redes do tipo RBF; RNA 15 a 22, redes NEAT. “*Continuação*”

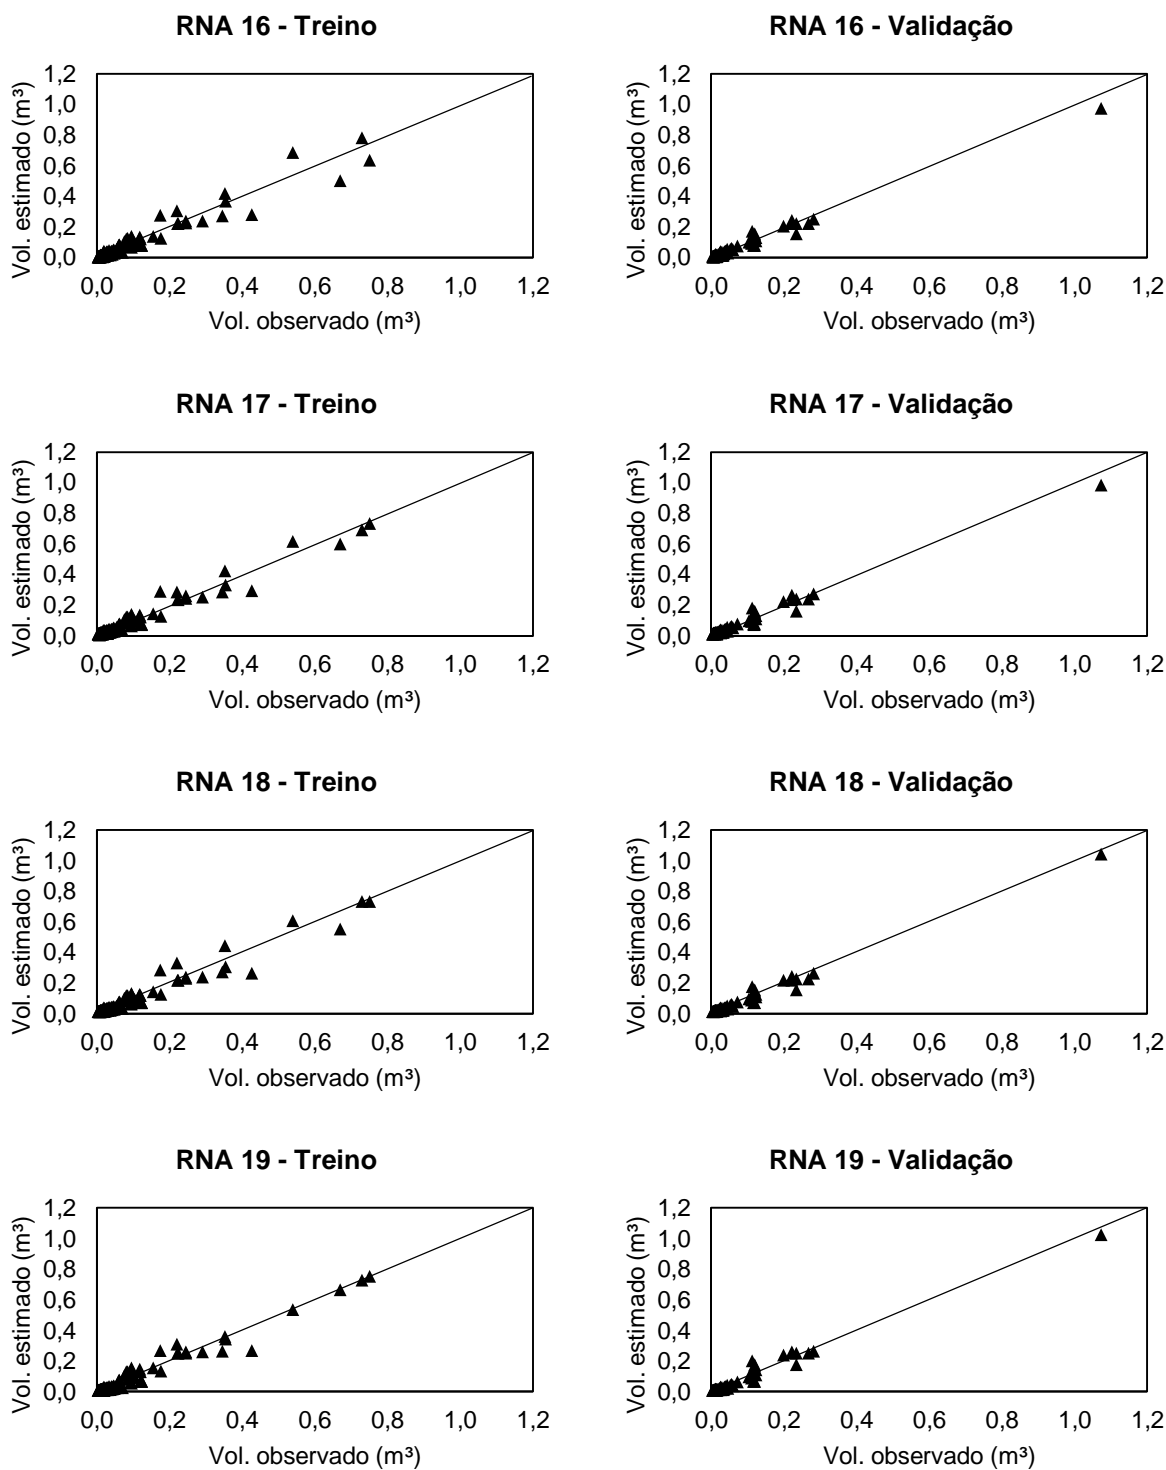


**Figura 5** – Volume observado e o volume estimado (VCcc) das melhores redes seleccionadas dos tipos MLP e RBF, sendo 70% dos dados para treinamento e 30% para validação. RNA 1 a 3, algoritmo *Resilient propagation* (Rprop+); RNA 4 a 8, *Skip-layer connections*; RNA 9 a 14, redes do tipo RBF; RNA 15 a 22, redes NEAT. “*Continuação*”

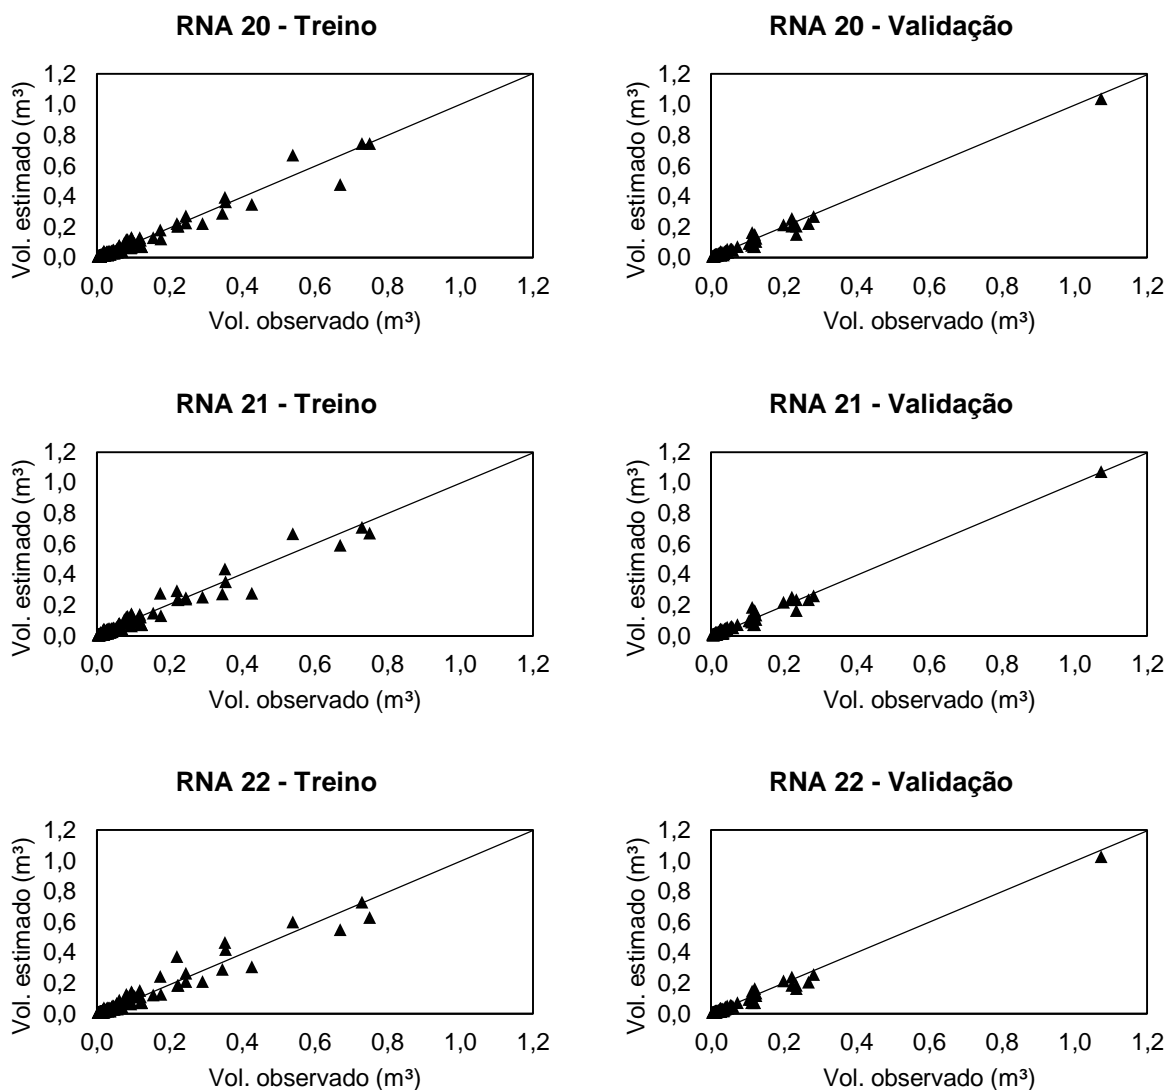




**Figura 5** – Volume observado e o volume estimado (VCcc) das melhores redes seleccionadas dos tipos MLP e RBF, sendo 70% dos dados para treinamento e 30% para validação. RNA 1 a 3, algoritmo *Resilient propagation* (Rprop+); RNA 4 a 8, *Skip-layer connections*; RNA 9 a 14, redes do tipo RBF; RNA 15 a 22, redes NEAT. “*Continuação*”



**Figura 5** – Volume observado e o volume estimado (VCcc) das melhores redes seleccionadas dos tipos MLP e RBF, sendo 70% dos dados para treinamento e 30% para validação. RNA 1 a 3, algoritmo *Resilient propagation* (Rprop+); RNA 4 a 8, *Skip-layer connections*; RNA 9 a 14, redes do tipo RBF; RNA 15 a 22, redes NEAT. “*Continuação*”



**Figura 5** – Volume observado e o volume estimado ( $VC_{cc}$ ) das melhores redes selecionadas dos tipos MLP e RBF, sendo 70% dos dados para treinamento e 30% para validação. RNA 1 a 3, algoritmo *Resilient propagation* (Rprop+); RNA 4 a 8, *Skip-layer connections*; RNA 9 a 14, redes do tipo RBF; RNA 15 a 22, redes NEAT.

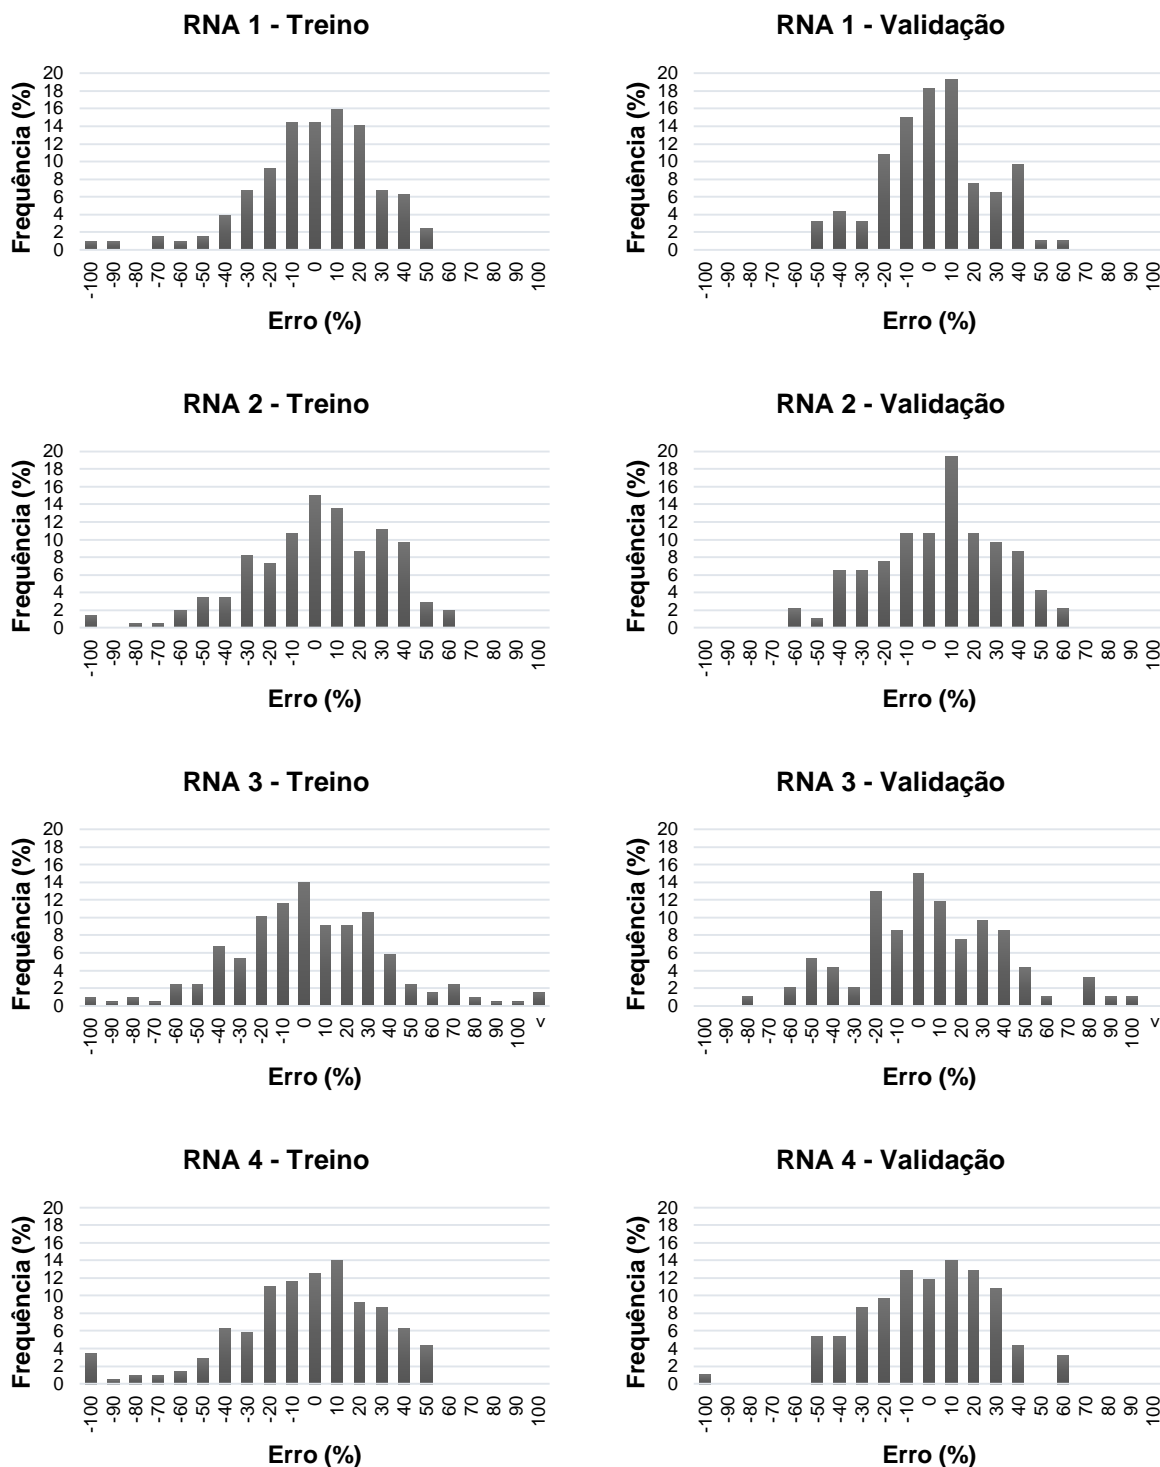
Todas as redes apresentaram uma alta tendência a superestimar os volumes, com erros percentuais concentrados, em média e globalmente, nos intervalos de -40 a 60%. Houve uma grande diferença comportamental em comparação às frequências dos erros para treinamento e validação. De forma geral, as RNA do tipo *Multilayer Perceptron* (MLP), apresentaram maiores tendenciosidades na fase de treinamento em comparação à fase de validação das redes. Isto pode ser observado pelo caráter anormal dos histogramas das RNA 15 e 18, referentes às redes NEAT (Figura 6).

Apesar das RNA 1 e 2 terem apresentado um dos piores resultados estatísticos na etapa de treinamento e validação, estas redes evidenciaram um baixo grau de superestimativa do volume, com intervalos de -20 a 40% e -40 a 50%, respectivamente, sendo a primeira com os erros majoritariamente concentrados no centro do gráfico. Mesmo com RMSE% para treinamento maior que as redes 6, 11 e 14, a RNA 21 apresentou melhor distribuição dos erros nos gráficos tanto para treino quanto para validação, sem a observância de erros acima de 100% (em módulo) na validação dos dados. Isso mostra a ótima capacidade de generalização do algoritmo NEAT, mesmo com estatísticas desfavoráveis no treinamento. A RNA 21 apresentou erros majoritariamente nos intervalos de -30 a 30%, o que corrobora com os resultados encontrados por Araújo (2015a).

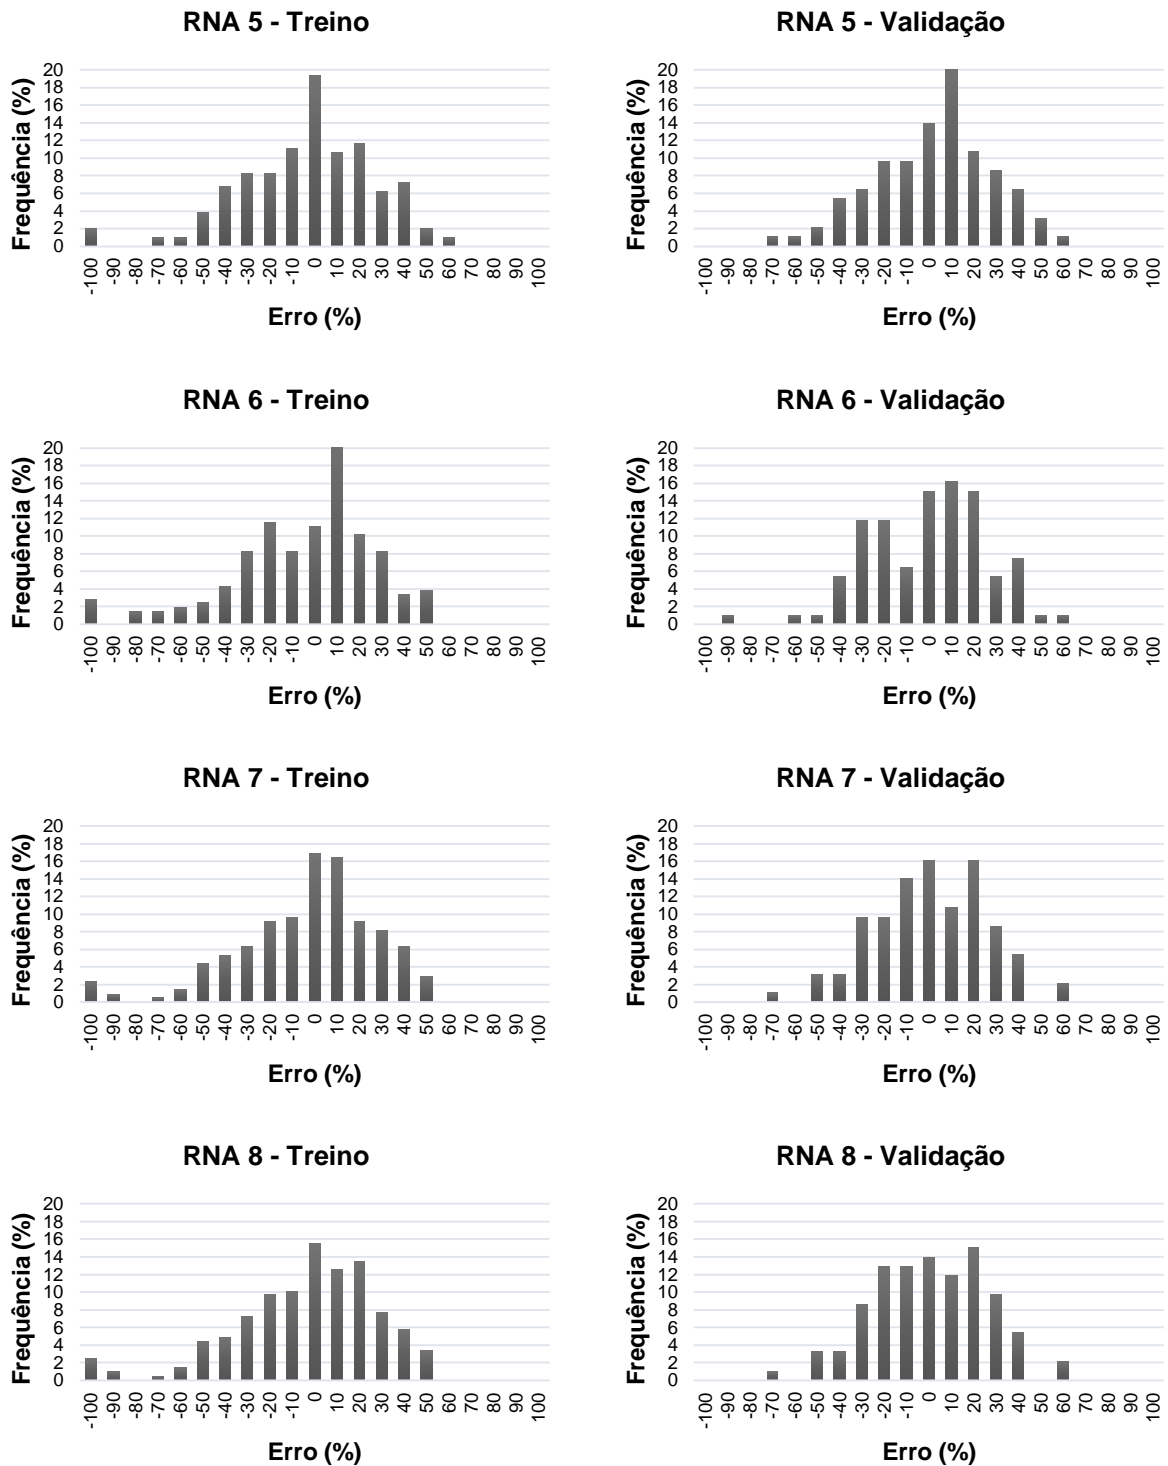
Este mesmo comportamento foi observado nas RNA 1 e 2, com algoritmo *Rprop+*, e RNA 5, com o algoritmo *Skip-Layer*, função de ativação Seno, com 3 neurônios na camada oculta, sendo que a melhor distribuição dos erros se deu para validação da RNA 5, função de ativação Seno e 3 neurônios na camada oculta, com erros compreendidos majoritariamente no intervalo de -30 a 35%. Isso mostra a capacidade do *Skip-layer* em melhor detectar padrões quando há um grande patamar de ruídos na rede, sendo que este comportamento foi semelhante para as redes NEAT, com distribuição dos erros de forma equivalente. Lima (2014), em estudo com Caatinga, apresentou uma forte tendenciosidade em redes MLP com algoritmo *backpropagation*, quando estas eram treinadas com apenas uma variável de entrada (o diâmetro na base,  $D_b$  ou diâmetro a 0,3 m), com erros de até 45,75% e observou um alto desempenho quando a variável altura foi acrescida, com erros de até 16%. Isto corrobora com a necessidade da inclusão da variável altura em alguns casos, mesmo que o ganho em precisão não seja tão nítido.

Em relação às redes RBF, as melhores distribuições se deram nas redes de número 9, 11 e 14. Como esperado, as RNA 11 e 14 obtiveram a mesma distribuição da frequência dos erros, concentrados no intervalo de -40 a 35%. Apesar de ter apresentado uma leve queda no desempenho, em relação às redes MLP, os resultados foram equivalentes para os dois tipos, tanto no treinamento quanto na validação. Porém as redes MLP são melhores em detectar os padrões do que as redes RBF. Os resultados aqui encontrados foram semelhantes ao observado por Lacerda et al. (2014), com espécies do cerrado, em que as redes

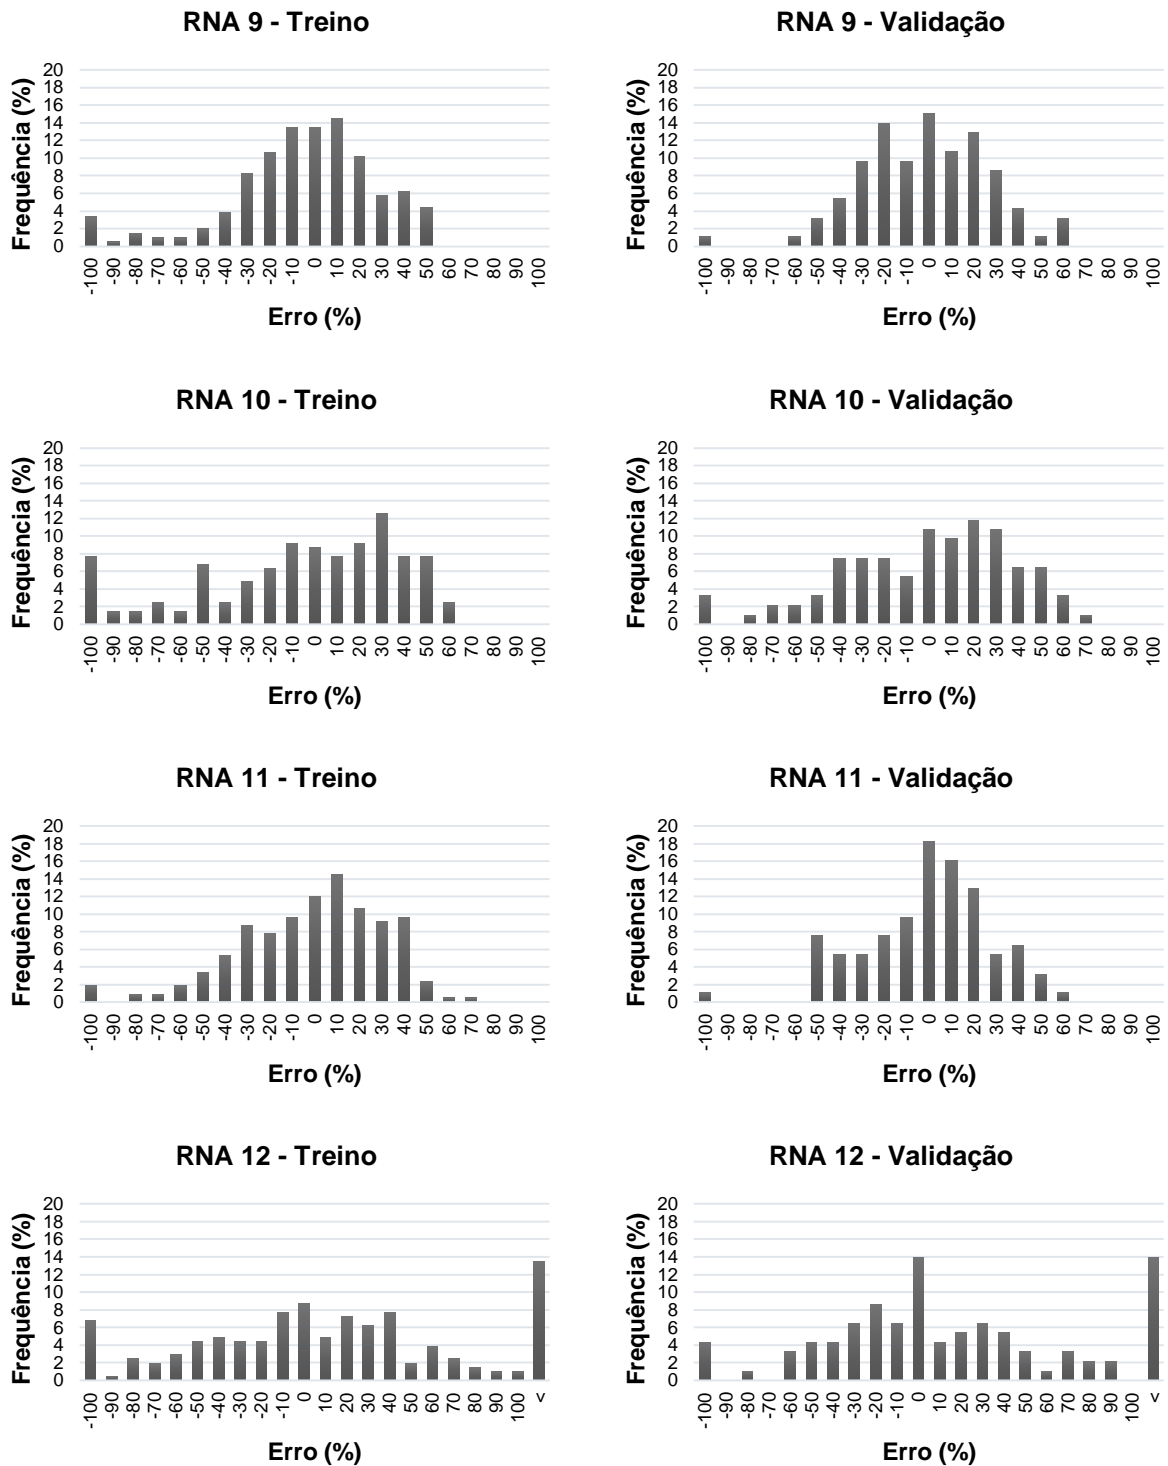
RBF foram nitidamente inferiores às redes MLP, com RMSE de 44% e intervalos nos histogramas de frequência dos erros compreendidos entre -36 a 44%.



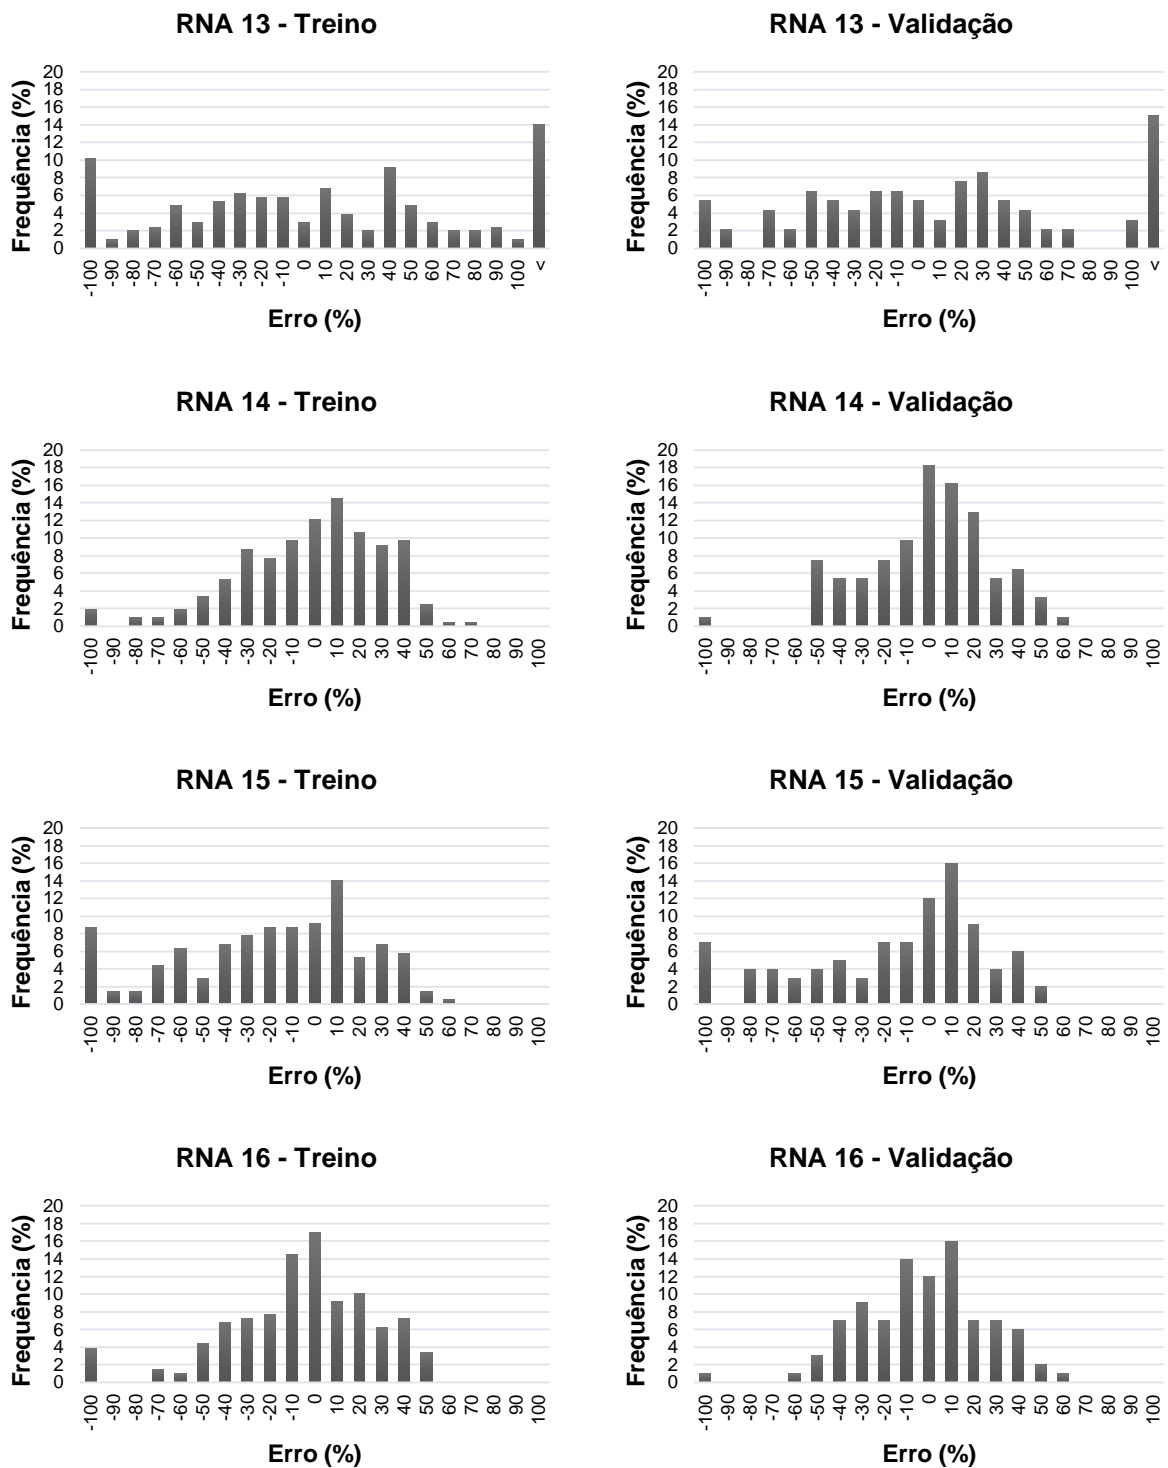
**Figura 6** – Histogramas de frequência dos erros percentuais das melhores RNA selecionadas para redes do tipo MLP e RBF, com 70% dos dados para treinamento e 30% para validação. RNA 1 a 3, *Resilient propagation* (Rprop+); RNA 4 a 8 – *Skip-layer*; RNA 9 a 15, redes do tipo RBF. “*Continua*”



**Figura 6** – Histogramas de frequência dos erros percentuais das melhores RNA selecionadas para redes do tipo MLP e RBF, com 70% dos dados para treinamento e 30% para validação. RNA 1 a 3, *Resilient propagation* (Rprop+); RNA 4 a 8 – *Skip-layer*; RNA 9 a 15, redes do tipo RBF. “*Continuação*”

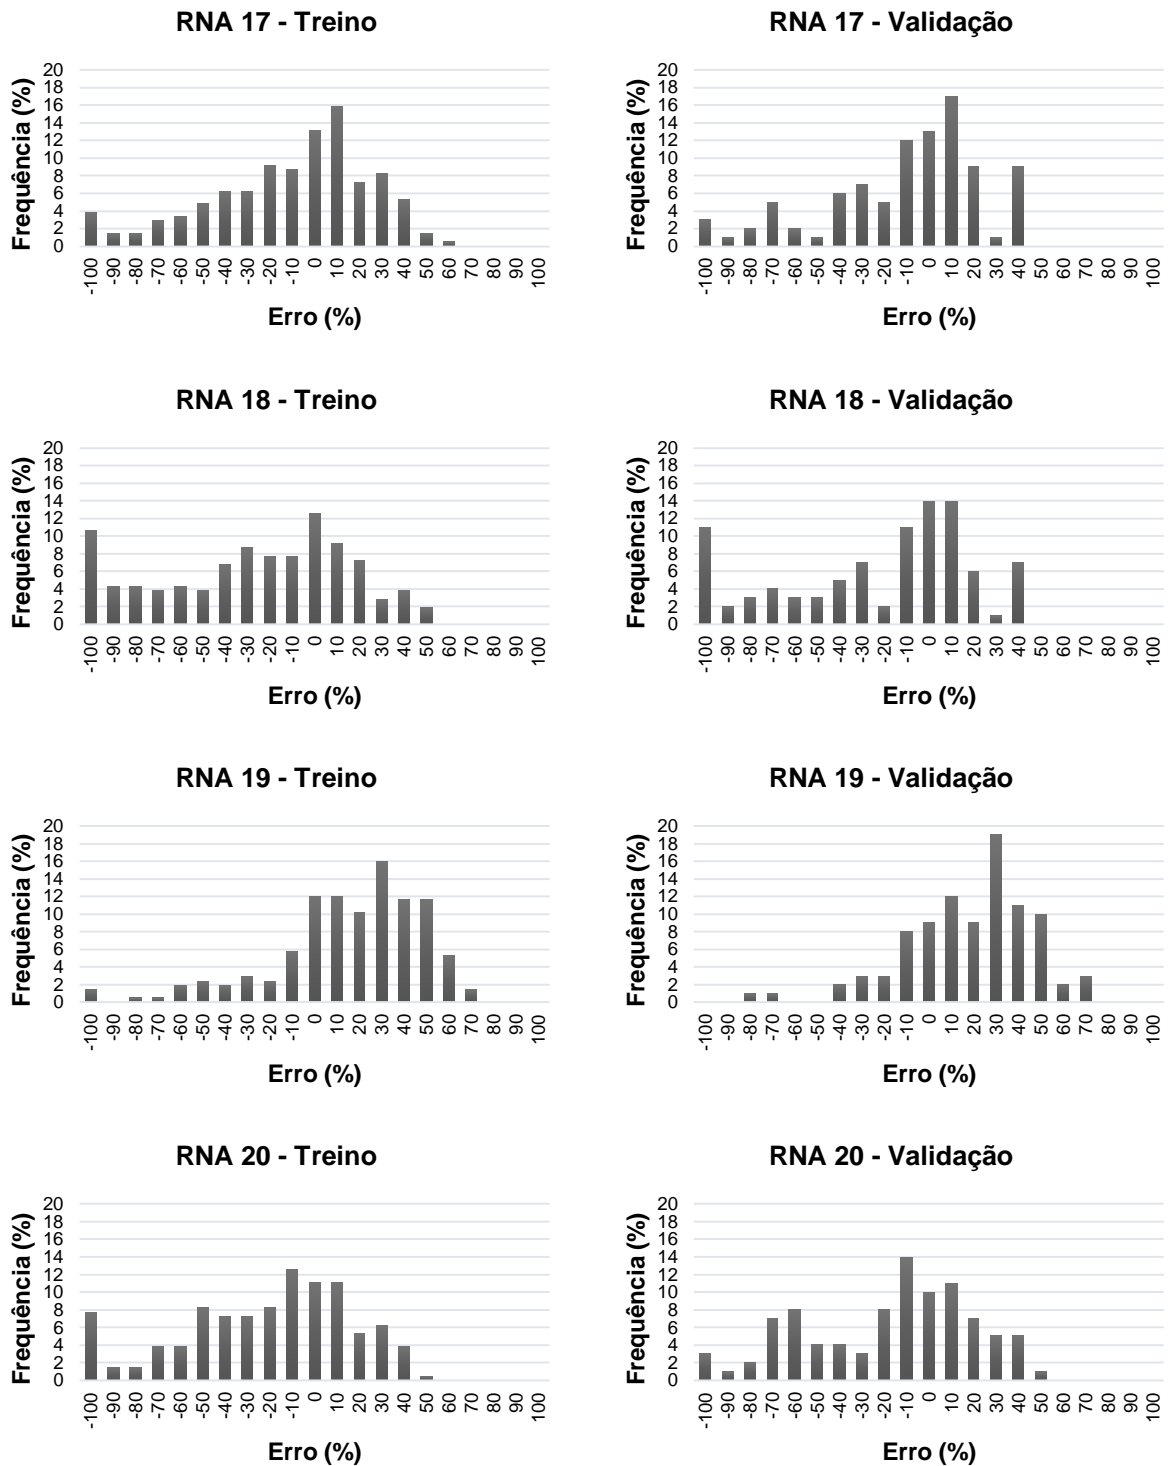


**Figura 6** – Histogramas de frequência dos erros percentuais das melhores RNA selecionadas para redes do tipo MLP e RBF, com 70% dos dados para treinamento e 30% para validação. RNA 1 a 3, *Resilient propagation* (Rprop+); RNA 4 a 8 – *Skip-layer*; RNA 9 a 15, redes do tipo RBF. “*Continuação*”

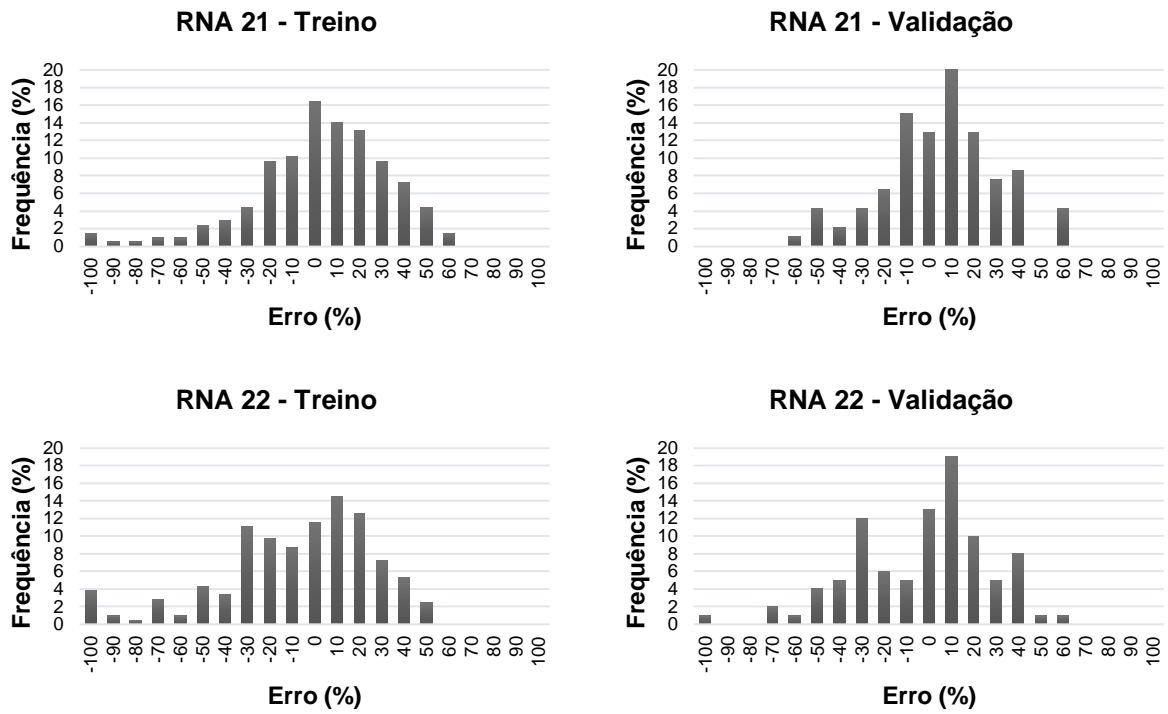


**Figura 6** – Histogramas de frequência dos erros percentuais das melhores RNA selecionadas para redes do tipo MLP e RBF, com 70% dos dados para treinamento e 30% para validação. RNA 1 a 3, *Resilient propagation* (Rprop+); RNA 4 a 8 – *Skip-layer*, RNA 9 a 15, redes do tipo RBF. “*Continuação*”





**Figura 6** – Histogramas de frequência dos erros percentuais das melhores RNA selecionadas para redes do tipo MLP e RBF, com 70% dos dados para treinamento e 30% para validação. RNA 1 a 3, *Resilient propagation* (Rprop+); RNA 4 a 8 – *Skip-layer*; RNA 9 a 15, redes do tipo RBF. “*Continuação*”



**Figura 6** – Histogramas de frequência dos erros percentuais das melhores RNA selecionadas para redes do tipo MLP e RBF, com 70% dos dados para treinamento e 30% para validação. RNA 1 a 3, *Resilient propagation* (Rprop+); RNA 4 a 8 – *Skip-layer*; RNA 9 a 15, redes do tipo RBF.

## 4. CONCLUSÕES

As redes treinadas com os algoritmos *Rprop+* e *Skip-Layer* evidenciaram um ótimo poder de generalização e simetria na distribuição dos erros percentuais, em algumas configurações testadas.

As redes treinadas pelo NEAT, com densidade de 0,1, apresentaram melhores resultados com indivíduos por população acima de 800 no momento de treinamento, e seu comportamento na validação foi influenciado pela quantidade de neurônios de entrada.

A melhor estrutura da RBF se dá com a combinação das variáveis de entrada DAP e DAS, com 10 neurônios para cada dimensão. As redes RBF obtiveram desempenho equivalente às redes MLP, podendo ser utilizadas para esta fitofisionomia.

As redes treinadas com o *Resilient propagation (Rprop+)* e *Skip-layer* estabilizam-se a partir de 100 ciclos e mantêm um comportamento equivalente para ambas, sem apresentar *overfitting*, a uma taxa de erro de 0,0001. Para as redes obtidas a partir do NEAT, a arquitetura se mostra favorável até 1.000 ciclos e, a partir desta marca, a rede pode perder capacidade de generalização.

O algoritmo NEAT com apenas uma variável de entrada é suficiente para obter bons resultados com tamanho da população igual a 1.000 e densidade inicial de 0,1, sendo a rede com apenas a variável DAP a que apresentou melhores estatísticas e menores tendenciosidades no histograma de frequência dos erros percentuais em comparação a todas as redes.

## 5. REFERÊNCIAS

ARAÚJO, A. C. da S. C. BINOTI, M. L. M. da S.; LEITE, H. G.; BINOTI, D. H. B.; XIMENES, L. C.; NOGUEIRA, G. S.; CARNEIRO, J. A. Artificial Neural Networks with Skip Layer connections to estimate the volume of forest formations in the state of Minas Gerais. **Australian Journal of Basic and Applied Sciences**, v. 36, n. 9, p. 319-327, 2015.

ARAÚJO, A. C. da S. C. **Redes neurais artificiais para quantificação volumétrica de florestas nativas no estado de Minas Gerais**. Diamantina-MG: UFVJM, 2015a, 73 p. Dissertação (Mestrado em Ciências Florestais) – Universidade Federal dos Vales do Jequitinhonha e Mucuri.

ARAÚJO, B. H. P. de. **Modelagem da altura, volume e afilamento de *Calycophyllum spruceanum* Benth. empregando regressão e redes neurais artificiais**. Manaus-AM: INPA, 2015b, 53 p. Dissertação (Mestrado em Ciências de Florestas Tropicais) – Instituto Nacional de Pesquisas da Amazônia.

BAILEY, T. M. Convergence of Rprop and variants. **Neurocomputing**, v. 159, p. 90-95, 2015.

BINOTI, D. H. B.; BINOTI, M. L. M. da S.; LEITE, H. G. Configuração de redes neurais artificiais para estimação do volume de árvores. **Ciência da Madeira**, v. 5, n. 1, p. 58-67, 2014.

BINOTI, M. L. M. **Emprego de redes neurais artificiais em mensuração e manejo florestal**. Viçosa-MG: UFV, 2012, 130 p. Tese (Doutorado em Ciências Florestais) – Universidade Federal de Viçosa.

BINOTI, M. L. M. **Redes neurais artificiais para prognose da produção de povoamentos não desbastados de eucalipto**. Viçosa-MG: UFV, 2010, 54 p. Dissertação (Mestrado em Ciências Florestais) – Universidade Federal de Viçosa.

BRAGA, A. P.; CARVALHO, A. P. L. F.; LUDERMIR, T. B. **Redes neurais artificiais: teoria e aplicações**. 1. ed. LTC, Rio de Janeiro, 2000.

BRAGA, A. P.; CARVALHO, A. P. L. F.; LUDERMIR, T. B. **Redes neurais artificiais: teoria e aplicações**. 2. ed.- [Reimpr.]. LTC, Rio de Janeiro, 2014.

BRASIL. **Lei nº 9.985, de 18 de Julho de 2000**. Regulamenta o artigo 225, § 1º, incisos I, II, III e VII da Constituição Federal, institui o Sistema Nacional de Unidades de Conservação da Natureza e dá outras providências. Ministério do Meio Ambiente, Brasília.

CAAMAÑOS, P.; BELLAS, F.; DURO, R. J. Augmenting the NEAT Algorithm to Improve its Temporal Processing Capabilities. **2014 International Joint Conference on Neural Networks (IJCNN)**, Beijing, p. 1467-1473, 2014.

FRANCO, S. A. P. **Estrutura e volume de povoamento de um remanescente de floresta estacional semidecidual em curvelo, MG**. Diamantina-MG: UFVJM, 2012, 67 p. Dissertação (Mestrado em Ciências Florestais) – Universidade Federal dos Vales do Jequitinhonha e Mucuri.

GORGENS, E. B.; LEITE, H. G.; 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.

GORGENS, E. B.; LEITE, H. G.; SANTOS, H. N.; GLERIANI, J. M. Estimação do volume de árvores utilizando Redes Neurais Artificiais. **Revista Árvore**, v. 33, n. 6, p. 1141-1147, 2009.

HAYKIN, S. **Neural networks and learning machines**. 3. ed. Prentice Hall, New York, 2009, 906 p.

HAYKIN, S. **Neural networks: a comprehensive foundation**. Prentice Hall, New York, 1999, 823 p.

HAYKIN, S. **Redes neurais: princípios e prática**. 2. ed. Bookman, Porto Alegre, 2001. 900 p.

IBAMA – Instituto Brasileiro de Meio Ambiente e dos Recursos Naturais Renováveis. **Plano de Manejo: Floresta Nacional Contendas do Sincorá, Volume I**. MMA: Brasília, 2006.

INEMA – Instituto do Meio Ambiente e Recursos Hídricos do Estado da Bahia. **Regiões de Planejamento e Gestão das Águas** – RPGA e Solos. Governo do Estado da Bahia, 2014.

LACERDA, T. H. S.; JESUS, R. B. de; PLAZAS, I. V. C.; LACERDA, K. W. de S.; CABACINHA, C. D.; ASSIS, A. L. de. Redes neurais artificiais para estimar o volume de espécies de cerrado *stricto sensu*. In: CORTE, A. P. D.; SANQUETTA, C. R.; RODRIGUES, A. L.; NETTO, S. P.; MACHADO, S. do A.; FIGUEIREDO FILHO, A.; NOGUEIRA, G. S. (Org.). **Atualidades em Mensuração Florestal**. 1. ed. UFPR, Curitiba, v. 1, p. 381-384, 2014.

LIMA, R. B. de. **Distribuição diamétrica e volumetria em vegetação de caatinga arbustiva-arbórea, Floresta-PE**. Recife-PE: UFRPE, 2014, 134 p. Dissertação (Mestrado em Ciências Florestais) – Universidade Federal Rural de Pernambuco.

MEHTÄTALO, L; MALTAMO, M; KANGAS, A. The Use of Quantile Trees in the Prediction of the Diameter Distribution of a Stand. **Silva Fennica**, v. 40, n. 3, 2006.

RIPLEY, B. D. **Pattern Recognition and Neural Networks**. 1. ed. Cambridge University Press, Cambridge, 1996, 403 p.

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

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

SOUZA, A. L. de; SOARES, C. P. B. **Florestas nativas**: estrutura dinâmica e manejo. UFV, Viçosa, 2013, 322 p.

STANLEY, K. O. **Efficient Evolution of Neural Networks through Complexification**. Austin-TX: UT, 2004, 165 p. Tesis (Doctor of Philosophy) - The University of Texas.

STANLEY, K. O.; MIIKKULAINEN, R. Evolving Neural Networks through augmenting Topologies. **Evolutionary Computation**, v. 10, n. 2, p. 99-127, 2002.

## CAPÍTULO 2

### ESTIMATIVA DE VOLUME COMERCIAL DE ESPÉCIES DA CAATINGA ARBÓREA ARBUSTIVA COM RNA

#### RESUMO

A Caatinga é o bioma exclusivo do Brasil e atualmente vem apresentando uma diminuição de sua flora por conta da exploração não sustentável de seus recursos. Assim, uma forma de conhecer o potencial da fitofisionomia se dá através de técnicas baseadas em regressão para estimativa do estoque volumétrico. No entanto, estas técnicas nem sempre conseguem expressar com a acurácia necessária devido à alta variação entre as espécies, algo raramente encontrado em florestas plantadas. Portanto, outras técnicas baseadas em inteligência artificial, com o uso de Redes Neurais Artificiais (RNA), vêm sendo utilizadas a fim de diminuir os erros nas estimativas nessas vegetações naturais. Nesse sentido, redes baseadas em algoritmos evolutivos e genéticos vêm se tornando evidentes como forma de suprir a necessidade do caráter empírico dos algoritmos convencionais. Assim, neste capítulo, buscou-se comparar o desempenho de dezoito equações tradicionais de volume com redes *Neuroevolution of Augmenting Topologies* (NEAT) para estimativa do volume comercial de espécies da Caatinga arbórea arbustiva. Foram utilizados dados de cubagem de 300 árvores da Caatinga arbórea, no estado da Bahia, sendo 70% para treinamento e 30% para validação. Para treinamento e validação das redes, foram usadas combinações das variáveis diâmetro a 1,3 m (*dap*), diâmetro a 0,3 m (*das*) e altura total (*Ht*), além de aferir a influência do número de indivíduos por população e densidades iniciais. Para validar o desempenho das redes e das equações, os critérios estatísticos comuns adotados foram a Raiz do Erro Quadrático Médio (RMSE%), a correlação linear de Pearson entre o volume estimado e o observado ( $r_{yy'}$ ), o *Akaike information Criterion* (AIC), gráfico da dispersão dos resíduos, histograma de frequência dos erros percentuais, além da verificação da acurácia para validação das técnicas pelo teste F de Graybill. Para os modelos foi realizado o teste da falta de ajuste (*lack-of-fit*). O algoritmo NEAT com 1.000 indivíduos e densidade 0,1 apresentou o melhor desempenho em comparação ao melhor modelo de regressão (Schumacher & Hall log).

**Palavras-chave:** regressão; computação evolutiva; algoritmos genéticos.



## 1. INTRODUÇÃO

A Caatinga ocupa extensivas faixas do território brasileiro e caracteriza-se por apresentar espécies altamente aptas a terem pleno desenvolvimento em regiões semiáridas. É o bioma considerado exclusivo do território nacional, com alta variabilidade de espécies em sua flora e, em muitos casos, espécies endêmicas. Atualmente encontra-se em constante diminuição de sua cobertura vegetal, o que ampliou áreas desertificadas devido às ações de práticas agrícolas inadequadas, desmatamentos e salinização do solo (BRASILEIRO, 2009).

Assim, uma forma de diminuir estes impactos é conhecer a capacidade do estoque volumétrico da vegetação para subsidiar a elaboração de planos de manejo sustentável. Este estoque é comumente estimado por equações de volume ou fatores de forma (FIGUEIREDO et al., 2009; COLPINI et al., 2009).

Devido à alta heterogeneidade das vegetações tropicais, equações de volume ajustadas por regressão tendem a não explicar com acurácia o estoque volumétrico quando comparadas às estimativas em florestas plantadas, devido à alta variação na forma do tronco observada nas diferentes espécies e dentro de uma mesma espécie, o que enfraquece as relações entre a(s) variável(is) dependente(s) e independente(s).

Atualmente, conceitos de inteligência artificial, sobretudo a partir do uso de Redes Neurais Artificiais (RNA), surgiram como uma alternativa às equações convencionais em vegetações naturais, a fim de diminuir esta incompatibilidade (FRANCO, 2012; LIMA, 2014; ARAÚJO et al., 2015).

As Redes Neurais Artificiais (RNA) são sistemas paralelos baseados em codificações computacionais através de algoritmos que cumprem a função de absorver a informação em um processo de aprendizagem, semelhante aos princípios biológicos de um cérebro humano. São estruturas que contêm camadas interligadas entre si através de conexões que atribuem uma quantidade de neurônios onde, em cada uma, é anexado um peso sináptico que pode variar a depender da complexidade da tarefa empreendida (HAYKIN, 2001; 2009; BRAGA et al., 2014). Essas estruturas podem possuir uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída, padrão convencional das redes *Multilayer Perceptron* (MLP) com o algoritmo *backpropagation*, que é o tipo de rede mais usual

para estimativa de volume em florestas, por seu alto poder de precisão (BINOTI, 2010; ÖZÇELİK et al., 2010; BINOTI, 2012; LIMA, 2014; BINOTI et al., 2014), porém possui a desvantagem de ser mais sensível a ruídos na base de dados em comparação a outros algoritmos (ÖZÇELİK et al., 2010).

Apesar de serem mais usuais, as redes MLP com o algoritmo *backpropagation* possuem uma topologia fixa com a limitação em ajustar os pesos sinápticos em seu limiar, as funções de ativação e o número de neurônios na camada oculta. Isto exige do operador um conhecimento prévio a respeito de qual configuração de rede deverá ser utilizada, sendo necessárias práticas de busca manuais para atingir um parâmetro ótimo da rede. Assim, algoritmos evolutivos baseados em conceitos genéticos, ou AGs, foram desenvolvidos com a premissa de isentar o caráter empírico da configuração inicial das RNA, através das *Neuroevolution of Augmenting Topologies* (NEAT).

O algoritmo NEAT possui a capacidade de atribuir às redes neurais um caráter evolutivo, através de princípios de algoritmos genéticos (AGs), para execução de tarefas e, diferentemente dos algoritmos convencionais, possui a vantagem de não necessitar de supervisão para obter uma boa precisão no processo de aprendizado (STANLEY e MIKKULAIEN, 2002; STANLEY, 2004). Os algoritmos genéticos se baseiam no princípio da evolução natural proposto por Darwin, e são algoritmos de otimização e busca baseados também nos princípios de seleção natural e genética (BRAGA et al., 2014). Nesse sentido, as redes treinadas pelo NEAT iniciam com uma estrutura de rede básica e evoluem para uma configuração mais simples possível, que comporte a resolução do problema proposto (STANLEY e MIKKULAIEN, 2002; STANLEY, 2004).

Assim, neste capítulo, buscou-se comparar o desempenho de equações tradicionais de volume com redes *Neuroevolution of Augmenting Topologies* (NEAT), para estimativa do volume comercial de espécies da caatinga arbórea arbustiva.

## 2. MATERIAL E MÉTODOS

### 2.1. Caracterização da área

Os dados utilizados neste estudo foram coletados na Floresta Nacional Contendas do Sincorá (FLONA), que é uma unidade de conservação inserida no grupo de uso sustentável, segundo a Lei nº 9.985, que consiste no Sistema Nacional de Unidades de Conservação (BRASIL, 2000). Fica localizada no município de Contendas do Sincorá, Bahia, nas coordenadas 13°55'14,51"S e 41°6'54,79"O, e possui uma área de 11.215,78 hectares. Foi criada em 1999 como parte da compensação ambiental acordada entre o IBAMA e a antiga empresa de mineração proprietária. Antes de sua criação como Unidade de Conservação, a propriedade era de uso exploratório de carvão, que subsidiava as atividades da empresa Magnesita S.A., no período de 1990 a 1994. Posteriormente, foi vendida para a empresa Siderúrgica Itaminas S.A., que atuou até 1997, cedendo a propriedade após esse período como forma de aquisição de Créditos de Reposição Florestal.

Na área da FLONA, podem-se encontrar três tipos de tipologias vegetacionais: Caatinga arbórea arbustiva, Caatinga arbustiva fechada e complexo herbáceo-arbustivo. Desses, predomina a Caatinga arbórea arbustiva, seguida pela arbustiva fechada e, com relação a seus estratos, apresenta vegetação de porte compreendido entre 3,5 a 7,0 m, com poucas árvores maiores que 8,0 m de altura. Em levantamentos florísticos foram encontradas diversas espécies de interesse econômico, medicinal, alimentação humana e animal, para a formulação das atividades de manejo que podem ser aplicadas à área (IBAMA, 2006).

A região enquadra-se no clima semiárido quente, do tipo BSw<sup>h</sup>' de Köppen, com estação chuvosa no período de novembro a janeiro, precipitação entre 500 a 1.000 mm anuais, temperatura de 21 a 28 °C e umidade relativa de 60 a 70%. Predominam Argissolos e Latossolos Vermelho-Amarelo, com expressivas faixas de Neossolos Litólicos a oeste e leste do município de Contendas do Sincorá (INEMA, 2014).

A FLONA é cortada por dois córregos principais: sentido norte, formado por mais três ramos, o córrego da Garapa, que corta toda a sua extensão de oeste a leste, indo desaguar no Rio de Contas, onde encontra o córrego da Goiabeira. Este,

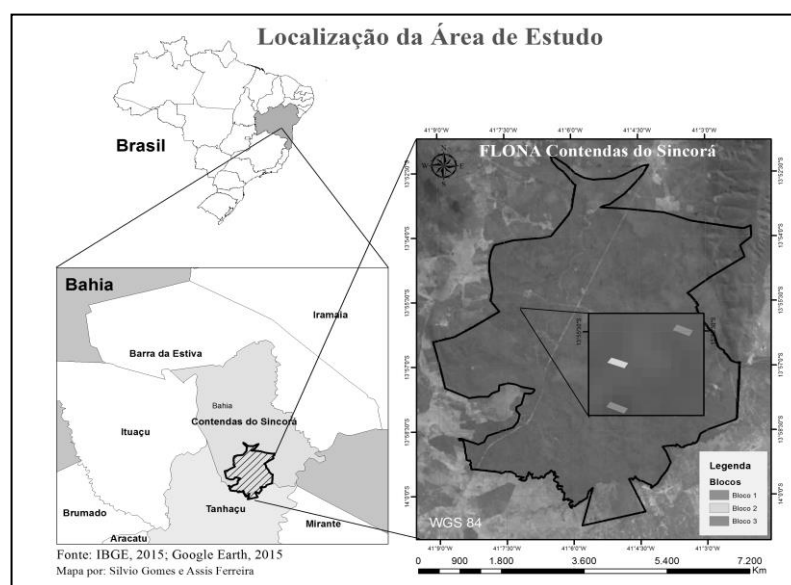
por conseguinte, é formado por outro ramo mais ao norte e que divide a FLONA de oeste a leste entre os municípios de Contendas do Sincorá e Tanhaçu (IBAMA, 2006).

## 2.2. Área amostral e critérios de inclusão

Na etapa inicial, foram utilizados os dados de inventário para a seleção dos indivíduos que foram suprimidos para a cubagem rigorosa. No inventário, foram distribuídos em uma área de Caatinga arbórea arbustiva, três blocos com 16 parcelas cada, sendo que cada parcela possuía uma dimensão de 20 x 20 m, com quatro tratamentos distribuídos ao acaso.

Os tratamentos consistem no corte raso, corte seletivo das espécies de interesse econômico, corte com base no diâmetro de inclusão mínimo e a testemunha. Foram contabilizados todos os indivíduos com diâmetro à altura de 1,3 m (DAP)  $\geq$  5 cm, medidos com suta, além de aferir a variável altura por estimativa visual em todas as parcelas. Tanto a etapa da simulação do manejo quanto o inventário não foram contempladas neste trabalho.

Este delineamento foi utilizado para delimitar os espaços onde foram executadas as atividades de supressão das espécies para realização da cubagem rigorosa e dos tratamentos referentes à simulação do manejo florestal sustentável (Figura 1).



**Figura 1** – Localização da FLONA Contendas do Sincorá com a respectiva alocação dos três blocos onde foram aplicados os tratamentos e as atividades de cubagem rigorosa.

### 2.3. Critérios para cubagem

Para uma melhor amostragem na obtenção dos volumes comercial com casca ( $VC_{cc}$ , em  $m^3$ ) das espécies, foi utilizado o critério da distribuição por classe diamétrica, adotando-se amplitude de 5 cm para as classes em referência aos critérios estabelecidos para florestas nativas em estágio inicial ou secundário de regeneração, conforme Souza e Soares (2013) (Tabela 1).

**Tabela 1** – Frequência absoluta por classe diamétrica, dos indivíduos mensurados na Floresta Nacional Contendas do Sincorá (FLONA), de espécies da Caatinga arbórea.

Classes	Intervalos	Frequência cubagem	Vol. ( $m^3$ ) <sup>1</sup>
1	4,9  — 9,9	191	2.98483
2	9,9  — 14,9	63	3.26639
3	14,9  — 19,9	23	2.58930
4	19,9  — 24,9	12	2.76315
5	24,9  — 29,9	3	0.94196
6	29,9  — 34,9	1	0.21927
7	34,9  — 39,9	3	1.37436
8	39,9  — 44,9	2	1.28857
9	44,9  — 49,9	1	0.72836
10	49,9  — 54,9	1	1.07307
<b>TOTAL</b>		<b>300</b>	<b>17.22926</b>

<sup>1</sup> volume comercial da cubagem rigorosa referente ao somatório por classe diamétrica.

Foi realizada uma cubagem utilizando o método de Smalian, com seções ao longo do fuste nas alturas iguais a 0,10; 0,30; 0,50; 0,70; 1,00; 1,30; 2,00 m. Após esta marca, as seções foram tomadas de um em um metro até o limite de 3 cm de diâmetro, considerado o limite mínimo para fuste comercial (Figura 2). Foram medidos também galhos com circunferência acima de 3 cm de diâmetro, averiguando o diâmetro mais homogêneo nas seções e seu comprimento.

### 2.4. Base de dados

Foram utilizados pares de dados de volume provenientes de cubagem rigorosa de 300 observações de 24 espécies identificadas, sendo 5 espécies a nível de gênero e 63 consideradas morfoespécies (ou sem identificação), devido à

ausência de material botânico fértil e por terem sido cubadas em período de caducifolia originada por período de baixíssima precipitação (APÊNDICE A).

As variáveis quantitativas utilizadas, foram: diâmetro com casca a 1,3 m de altura (DAP), altura total, em metros (HT) e volume comercial com casca (VC<sub>cc</sub>, em m<sup>3</sup>) (Tabela 2).

**Tabela 2** – Valores globais das variáveis quantitativas mensuradas na cubagem.

Variável	Mínimo	Máximo	Média	Desvio Padrão
DAP (cm)	5,0	52,6	10,50	6,96
Altura total (m)	3,5	11,5	6,74	1,41
Volume comercial (m <sup>3</sup> )	0,00354	1,07307	0,05743	0,11392



**Figura 2** – Aplicação de cubagem rigorosa na Floresta Nacional Contendas do Sincorá (FLONA), Bahia, para estimativa de volume de espécies da Caatinga arbórea, ano 2016.

## 2.5. Equações de volume

Foram ajustadas 18 equações de volume (Tabela 3) comumente observadas na literatura florestal para a vegetação natural. O critério de escolha das equações baseou-se nas seleções dos autores e aquelas que obtiveram os melhores parâmetros estatísticos para cada fitofisionomia avaliada (REZENDE et al., 2006; IMAÑAS-ENCINAS et al., 2009; GAMA et al., 2015).

**Tabela 3** – Modelos de regressão para estimativa de volume comercial com casca (VCcc).

Nº	Modelo	Autor
1	$V = \beta_0 + \beta_1 dap^2 + \varepsilon$	Kopezky-Gehrhardt
2	$V = \beta_1 dap + \beta_2 dap^2 + \varepsilon$	Dissescu-Meyer
3	$V = \beta_0 + \beta_1 dap + \beta_2 dap^2 + \varepsilon$	Hohenadl-Krenm
4	$V = \beta_0 dap^{\beta_1} + \varepsilon$	Berkhout
5	$LnV = \beta_0 + \beta_1 Lndap + \varepsilon$	Husch
6	$LnV = \beta_0 + \beta_1 Lndap + \beta_2 \frac{1}{dap} + \varepsilon$	Brenac
7	$LnV = \beta_0 + \beta_1 Lndap + \beta_2 Lnht + \varepsilon$	Schumacher-Hall(log)
8	$V = \beta_0 + \beta_1 dap^2 ht + \varepsilon$	Spurr
9	$V = \beta_0 * dap^{\beta_1} * ht^{\beta_2} + \varepsilon$	Schumacher-Hall
10	$V = \frac{dap^2}{\beta_0 + \beta_1 \frac{1}{ht}} + \varepsilon$	Honner
11	$V = dap^2(\beta_0 + \beta_1 ht) + \varepsilon$	Ogaya
12	$V = \beta_0 + \beta_1 dap^2 + \beta_2 dap^2 ht + \beta_3 ht + \varepsilon$	Stoate
13	$V = \beta_0 + \beta_1 dap^2 + \beta_2 dap^2 ht + \beta_3 dapht^2 + \beta_4 ht^2 + \varepsilon$	Naslund
14	$V = \frac{dap^2 ht}{\beta_0 + \beta_1 dap} + \varepsilon$	Takata
15	$LnV = \beta_0 + \beta_1 Ln(dap^2 ht) + \varepsilon$	Spurr (log)
16	$V = \beta_0 + \beta_1 dap + \beta_2 dap^2 + \beta_3 dapht + \beta_4 dap^2 ht + \beta_5 ht + \varepsilon$	Meyer
17	$V = \beta_0 + \beta_1 dap^2 ht^{\beta_2} + \varepsilon$	Scolforo e Silva (1993)
18	$V = \beta_1 dap^2 + \beta_2 dap^2 ht + \varepsilon$	Rezende et al. (2006)

V = Volume comercial com casca (VCcc); dap= diâmetro a 1,3 m do solo; ht = altura total; Ln = logaritmo neperiano.

Para comparar com as RNA, as equações foram ajustadas utilizando a estratificação proporcional de 70% dos dados para gerar os parâmetros dos modelos e 30% para validação. A fim de padronizar os termos, foi utilizada a nomenclatura “treino” (ajuste) para 70% e “validação” para os 30% e, assim, atestar a capacidade

de generalização das equações para valores desconhecidos na fitofisionomia em questão.

Quando a variável dependente é alterada por algum tipo de transformação algébrica, o erro padrão da estimativa ( $S_{yx}$ ) deverá ser recalculado para que esse possa ser comparável aos das equações cuja variável dependente não sofreu transformação. Essa correção pode ser executada pela seguinte expressão:

$$S_{yx_{recalc.}} = \sqrt{\frac{\sum (y_i - \hat{y}_i)^2}{(n-p)}}$$

em que:  $y_i$  = valor real de cada observação;  $\hat{y}_i$  = valor estimado de cada observação;  $n$  = número de dados;  $p$  = número de coeficientes de cada equação, incluindo o  $\beta_0$ .

Os ajustes dos modelos foram realizados no *software RStudio 2016*, através das funções *lm* e *nls* do pacote *stats*, com auxílio do *Microsoft Excel®*, para a elaboração de cálculos auxiliares, confecção dos gráficos de resíduos e histogramas de frequência dos erros percentuais.

## 2.6. Redes evolutivas com *Neuroevolution of Augmenting Topologies (NEAT)*

Nas redes treinadas pelo *Neuroevolution of Augmenting Topologies (NEAT)*, foram utilizados 70% dos dados para treinamento e 30% para validação (ARAÚJO et al., 2015b). A etapa de validação visa determinar a capacidade da rede em convergir satisfatoriamente para dados desconhecidos, ou seja, se a rede é capaz de extrapolar saídas coerentes na inserção de novos dados de entrada. O algoritmo em questão pode ser encontrado no pacote de funcionalidades do Sistema para geração e aplicação de Redes Neurais Artificiais (Neuroforest), versão 4.0.

Como variáveis quantitativas de entrada, utilizou-se o diâmetro a 1,3 m do solo ( $d_{ap}$ , em cm), diâmetro à altura de 0,3m do solo ( $d_{as}$ , em cm) e altura total ( $H_t$ , em metros); e o volume comercial com casca ( $VC_{cc}$ , em  $m^3$ ) como variável de saída, configurando seis diferentes combinações de entrada. Todas as variáveis foram normalizadas no intervalo de 0 e 1 antes do treinamento.

No algoritmo NEAT, há a possibilidade de alterar configurações de população e suas densidades iniciais. Nesse sentido, foram realizados testes para o número de indivíduos por população de 300, 600, 800, 1.000 e densidades iniciais de 0,1 e 0,5 em referência aos parâmetros avaliados por Araújo (2015a). Assim, como forma de



avaliar se o número de indivíduos e densidades iniciais possuem nítida influência nos erros médios absolutos (RMSE médio), foi gerado um gráfico tridimensional de análise multivariada com três eixos (nº de indivíduos, densidade e RMSE médio), através do pacote *Scatterplot 3d* do software *RStudio 2016*.

Foi treinada um total de cinco RNA para cada configuração, totalizando 240 redes geradas. Por fim, foram retidas apenas as redes com melhores estatísticas de cada configuração para confecção dos gráficos de resíduos e histogramas de frequência dos erros percentuais, em referência ao Capítulo 1.

## 2.7. Critérios estatísticos para avaliação do desempenho das técnicas

As estatísticas utilizadas para análise do desempenho das equações e das redes foram a correlação entre os valores estimados e observados de volume ( $r_{Y\hat{Y}}$ ), a raiz do erro quadrado médio (RMSE%) e o *Akaike Information Criterion* (AIC). A análise gráfica consistiu na inspeção estatística da dispersão dos erros (resíduos) percentuais em relação aos valores observados para o histograma de frequência dos erros percentuais, conforme Binoti (2010), sendo:

$$erro_{\%} = \frac{(Y - \hat{Y})}{Y} * 100$$

em que,  $Y$  é o volume observado e  $\hat{Y}$  é o volume estimado.

A correlação entre os valores observados e estimados ( $r_{Y\hat{Y}}$ ) indica a força e a direção da relação entre as duas variáveis. Essa correlação visa atribuir um grau associativo entre os valores estimados e os observados e, com o auxílio da análise de resíduos, permite inferir sobre a qualidade da estimativa. Quanto mais próxima de 1, maior a correlação entre as variáveis (BINOTI, 2010). Então:

$$r_{Y\hat{Y}} = \frac{cov(Y, \hat{Y})}{\sqrt{s^2(Y)s^2(\hat{Y})}}$$

sendo que,  $cov$  é a covariância e  $s^2$  é a variância.

A raiz do erro quadrado médio (RMSE) avalia a diferença quadrática média entre os valores observados e os valores estimados (BINOTI, 2010). Quanto menor o RMSE, melhor a precisão da estimativa (MEHTÄTALO et al., 2006), sendo:

$$RMSE_{\%} = \frac{100}{\bar{Y}} * \sqrt{\frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n}}$$

em que,  $n$  é o número total de dados e  $\bar{Y}$  a média do volume observado

Critério de informação Akaike ou *Akaike information criterion* (AIC), constitui-se em uma medida relativa da qualidade de ajuste de um modelo estatístico estimado. Quando o resultado de  $\frac{n}{K}$  for maior do que 40, então, o AIC pode ser definido como:

$$AIC = -2 \left( \frac{-n}{2} \ln \left( \frac{1}{n} \sum_{i=1}^n e_i^2 \right) \right) + 2k$$

No entanto, quando o resultado de  $\frac{n}{K}$  for menor do que 40, o AIC pode ser definido e calculado através da fórmula (BURNHAM e ANDERSON, 2002; BURNHAM et al., 2010):

$$AIC_c = -2 \left( \frac{-n}{2} \ln \left( \frac{1}{n} \sum_{i=1}^n e_i^2 \right) \right) + 2k \frac{n}{(n - k - 1)}$$

Onde:

$e$  = resíduos;

$n$  = número de observações;

$K = p+1$

$p$  = número de parâmetros do modelo

### 2.7.1. Teste da falta de ajuste (*lack-of-fit*)

Após a escolha do melhor modelo de regressão, foi aplicado um *teste da falta de ajuste* (ou *lack-of-fit*). Esse teste consiste em avaliar se o modelo foi eficiente em ajustar-se aos dados apresentados ou se há problemas no modelo e, assim, analisar se há necessidade da escolha de outro modelo ou reformulá-lo.

Assim, a soma dos quadrados da falta de ajuste e o cálculo do erro puro são dados pelas equações propostas por Serinoli (2009):

$$SQFA = \sum_{i=1}^k n_i (\bar{Y}_i - \hat{Y}_i)^2$$

$$SQEP = \sum_{i=1}^k \sum_{j=1}^{n_i} (Y_{ij} - \bar{Y}_i)^2$$

Em que:

SQFA = Soma dos Quadrados da Falta de Ajuste;

SQEP = Soma dos Quadrados do Erro Puro;

K = Número de posições;

n = Número de observações associadas ao valor da variável independente.

Com isso, a soma de quadrados do resíduo é:  $SQRes = SQFA + SQEP$ .

Tanto para modelos de regressão linear simples e múltipla, o procedimento de cálculo da Soma de Quadrados se dá da mesma maneira para ambos, diferenciando-se apenas nos valores do Quadrado Médio (QM).

Nesse sentido, caso o modelo seja de forma linear simples, os cálculos para a tabela da Anova para o Quadrado Médio, tanto na Falta de Ajuste do modelo quanto ao Erro Puro, foram computados da seguinte forma:

$$QMFA = \frac{SQRes - SQEP}{k - 2}$$

$$QMEP = \frac{SQEP}{n - k}$$

Para modelos lineares múltiplos, o procedimento foi assim designado:

$$QMFA = \frac{SQRes - SQEP}{k - p - 1}$$

$$QMEP = \frac{SQEP}{n - k}$$

em que:

QMFA = Quadrado médio da Falta de Ajuste;

QMEP = Quadrado médio do Erro Médio;

p = número de coeficientes do modelo.

Portanto, consideram-se as seguintes hipóteses:

$H_0$ : o modelo foi adequado e, portanto, não há falta de ajuste;

$H_1$ : o modelo não foi adequado e, portanto, há falta de ajuste.

Assim, para rejeitar a hipótese de nulidade  $H_0$  no modelo linear simples, considerou-se a seguinte expressão:

$$F_{FA} = \frac{\frac{SQFA}{k-2}}{\frac{SQEP}{n-k}} \geq F_{(\alpha, k-2, n-k)}$$

Para modelos lineares múltiplos, rejeita-se  $H_0$  quando:

$$F_{FA} = \frac{\frac{SQFA}{k-p-1}}{\frac{SQEP}{n-k}} \geq F_{(\alpha, k-p-1, n-k)}$$

Sendo:  $\alpha$  (0,05)

### 2.7.2. Avaliação da acurácia das estimativas de volume obtidas pelo teste de identidade entre diferentes métodos e teste F de Graybill

Nesta etapa, foi utilizado o método estatístico sugerido por Leite e Oliveira (2002), que se constitui na avaliação simultânea da estatística F modificada por Graybill (1976), o teste do erro médio e o coeficiente de correlação linear. Este procedimento visa determinar se há ou não diferença estatística entre as duas técnicas avaliadas, observando se os valores de  $\beta_0$  e  $\beta_1$  são, ao mesmo tempo, iguais a  $\beta_0 = 0$  e  $\beta_1 = 1$ , respectivamente.

O teste F de Graybill consiste na determinação dos parâmetros do modelo  $Y = \beta_0 + \beta_1 Y_p + \varepsilon$ , em que: Y é a variável obtida no método alternativo;  $\beta_0$  e  $\beta_1$  são os parâmetros do modelo;  $Y_p$  é a variável no método padrão; e  $\varepsilon$  é o erro aleatório.

Com isso, testa-se a hipótese  $H_0: \begin{bmatrix} \beta_0 \\ \beta_1 \end{bmatrix} = \begin{bmatrix} 0 \\ 1 \end{bmatrix}$ , com  $H_1$ : complemento de  $H_0$ , por meio do cálculo da estatística F dada por:  $F(H_0) = \frac{(\hat{\beta} - \theta)'(Y_p' Y_p)^{-1}(\hat{\beta} - \theta)}{2 * QMR}$

em que:  $\hat{\beta} = \begin{bmatrix} \beta_0 \\ \beta_1 \end{bmatrix}$  é o vetor de coeficientes da equação de regressão;  $\theta = \begin{bmatrix} 0 \\ 1 \end{bmatrix}$ ;

$(Y_p' Y_p) = \begin{bmatrix} n & \sum Y_p \\ \sum Y_p & \sum Y_p^2 \end{bmatrix}$ ; e QMR é o quadrado médio do resíduo da regressão. Assim,

compara-se o valor obtido com o  $F_{tab} = (5\%, 2, n - 2)$ : se  $F(H_0) \geq F_{tab}$ , rejeita-se a hipótese de nulidade  $H_0$ ; caso contrário, a hipótese não é rejeitada e admite-se que os dois métodos são iguais ao nível de significância proposto ( $Y = Y_p$ ).

O valor do erro médio ( $\bar{e}$ ) é calculado pela expressão  $\bar{e} = \sum[(Y - Y_p)/Y_p]/n$ . Assim, para testar a hipótese de que  $H_0: \bar{e} = 0$  e  $H_1: \bar{e} \neq 0$ , utiliza-se a estatística  $t$  que consiste em  $t_{\bar{e}} = (\bar{e} - 0)/S_{\bar{e}}$ , em que  $S_{\bar{e}} = S_e/(n)^{1/2}$  com  $n-1$  graus de liberdade. Portanto, se  $t_{\bar{e}} < t_{\alpha(n-1)}$ , a diferença entre os dois métodos comparados é causada devido à chance da hipótese de nulidade ser aceita.

Por fim, os métodos somente serão equivalentes quando  $F(H_0)$  e  $t_{\bar{e}}$  forem não significativos, além da correlação apresentar o seguinte comportamento  $R_{YY_p} \geq (1 - |\bar{e}|)$ , simultaneamente. Caso contrário, as técnicas são diferentes estatisticamente ( $Y \neq Y_p$ ).

Todos os ajustes e construções dos gráficos foram elaborados no *software RStudio 2016*, estabelecendo-se um critério mínimo de 95% de probabilidade ( $\alpha = 0,05$ ) para o teste  $t$  de *Student* no teste dos coeficientes e teste  $F$  de Graybill.

### 3. RESULTADOS E DISCUSSÃO

#### 3.1. Avaliação dos modelos de volume

Todos os modelos ajustados apresentaram alta capacidade de generalização dos dados, mesmo com altos percentuais de erro no momento do ajuste (treino) (Tabela 4). Isto evidenciou que todas as equações volumétricas foram capazes de gerar estimativas próximas aos valores reais quando foram usadas em dados desconhecidos, mesmo quando as medidas de precisão do ajuste não apresentaram resultados muito bons. Este aspecto pode ser observado ao analisar que grande parte dos modelos se concentraram entre 33 a 36% de raiz do erro quadrático médio (RMSE%) e correlação entre 0,98 a 0,99 no momento de validação.

Apesar de todas as equações terem gerado boas estimativas no momento de validação, a eficiência no momento do ajuste não foi satisfatória. A equação 15 (Spurr log) foi a que obteve o menor percentual de erro e menor AIC para validação, no entanto, apresentou o inverso na etapa de treinamento (ajuste), com 70% dos dados. Este evento pode ter ocorrido devido ao fato dos dados aleatorizados para o ajuste serem bastante heterogêneos, o que faz com que a equação gere uma reta média entre os dados. Isso explica que há alta probabilidade dos dados utilizados para validação estarem concentrados mais próximos da curva média gerada pela equação, portanto, este fato pode estar influenciando as estatísticas dos ajustes para a validação.

Outro aspecto é a alta variabilidade dos dados por se tratar de uma vegetação natural que teve seu contingente arbóreo suprimido em anos anteriores (IBAMA, 2006), alterando assim sua dinâmica, com maior incidência de árvores com menores volumes e que impactam diretamente nas relações alométricas. Segundo Lopes et al. (2012), o restabelecimento da vegetação em regiões do semiárido através da sua sucessão ecológica em áreas perturbadas, mesmo abandonadas após 16 anos, pode não possuir características de amadurecimento da vegetação. Portanto, o caso específico da FLONA apresenta um comportamento dinâmico de sucessão em estágio secundário, não atingindo seu potencial clímax e, conseqüentemente, um equilíbrio ecológico, o que explica a alta variação de volume inter e intraespecífica.

**Tabela 4** – Coeficientes ajustados para os modelos de volume comercial com casca (VC<sub>cc</sub>) da Caatinga arbórea, juntamente com as medidas de precisão: erro padrão da estimativa em m<sup>3</sup> (S<sub>xy</sub>); correlação linear de Pearson (r<sub>yy'</sub>); raiz do erro quadrático médio (RMSE%) e o critério de informação de Akaike (AIC), tanto para treinamento quanto para validação dos dados.

Mod. N°	Coeficientes						Treino (ajuste)				Validação			
	$\beta_0$	$\beta_1$	$\beta_2$	$\beta_3$	$\beta_4$	$\beta_5$	S <sub>xy</sub> (m <sup>3</sup> )	r <sub>yy'</sub>	RMSE%	AIC	S <sub>xy</sub> (m <sup>3</sup> )	r <sub>yy'</sub>	RMSE%	AIC
1	-0,000518 <sup>ns</sup>	0,000357*					0,0286	0,9654	51,07	-1469,29	0,02177	0,9907	35,22	-709,90
2	-	0,000177 <sup>ns</sup>	0,000350*				0,0286	0,9656	51,03	-1469,50	0,02209	0,9908	35,54	-705,91
3	-0,016630*	0,002370*	0,000303*				0,0283	0,9664	50,32	-1473,33	0,02257	0,9911	36,31	-701,93
4	0,000429*	1,947000*					0,0285	0,9660	50,87	-1470,89	0,02237	0,9913	36,19	-704,80
5	-8,573260*	2,219300*					0,0367	0,9616	65,44	-1364,64	0,02604	0,9850	41,89	-675,34
6	-6,949500*	1,759700*	-5,026000*				0,0284	0,9664	50,56	-1471,46	0,02430	0,9917	39,09	-688,21
7	<b>-9,677990*</b>	<b>2,013220*</b>	<b>0,830950*</b>				<b>0,0380</b>	<b>0,9619</b>	<b>67,68</b>	<b>-1350,66</b>	<b>0,02180</b>	<b>0,9882</b>	<b>35,07</b>	<b>-708,40</b>
8	0,009254*	0,000037*					0,0305	0,9607	54,37	-1443,36	0,02454	0,9873	39,70	-687,63
9	0,000221*	1,807000*	0,522200*				0,0281	0,9673	49,94	-1476,53	0,02437	0,9907	39,21	-687,66
10	2609*	1835 <sup>ns</sup>					0,0286	0,9655	51,02	-1467,67	0,02183	0,9907	35,12	-708,12
11	0,000321*	0,000004 <sup>ns</sup>					0,0286	0,9655	51,00	-1469,79	0,02175	0,9907	35,19	-710,04
12	-0,024950*	0,000328*	0,000002 <sup>ns</sup>	0,003973*			0,0283	0,9664	50,33	-1471,26	0,02171	0,9910	34,74	-707,97
13	-0,002480 <sup>ns</sup>	0,000294*	-0,000006 <sup>ns</sup>	0,000058*	-0,000286 <sup>ns</sup>		0,0279	0,9677	49,38	-1477,16	0,02581	0,9872	41,06	-674,67
14	15402,03*	297,93*					0,0280	0,9670	50,00	-1478,06	0,03059	0,9819	49,49	-646,62
15	-9,861650*	0,983390*					0,0373	0,9617	66,62	-1359,22	0,02091	0,9879	33,83	-717,35
16	-0,020710 <sup>ns</sup>	0,003112 <sup>ns</sup>	0,00009 <sup>ns</sup>	0,000144 <sup>ns</sup>	0,000017 <sup>ns</sup>	-0,00037 <sup>ns</sup>	0,0279	0,9678	49,31	-1475,34	0,02527	0,9887	39,97	-677,39
17	0,000627 <sup>ns</sup>	0,000282*	0,104300 <sup>ns</sup>				0,0287	0,9655	51,01	-1467,76	0,02189	0,9907	35,22	-707,59
18	-	0,000321*	0,000004 <sup>ns</sup>				0,0286	0,9655	51,00	-1467,79	0,02187	0,9907	35,19	-707,77

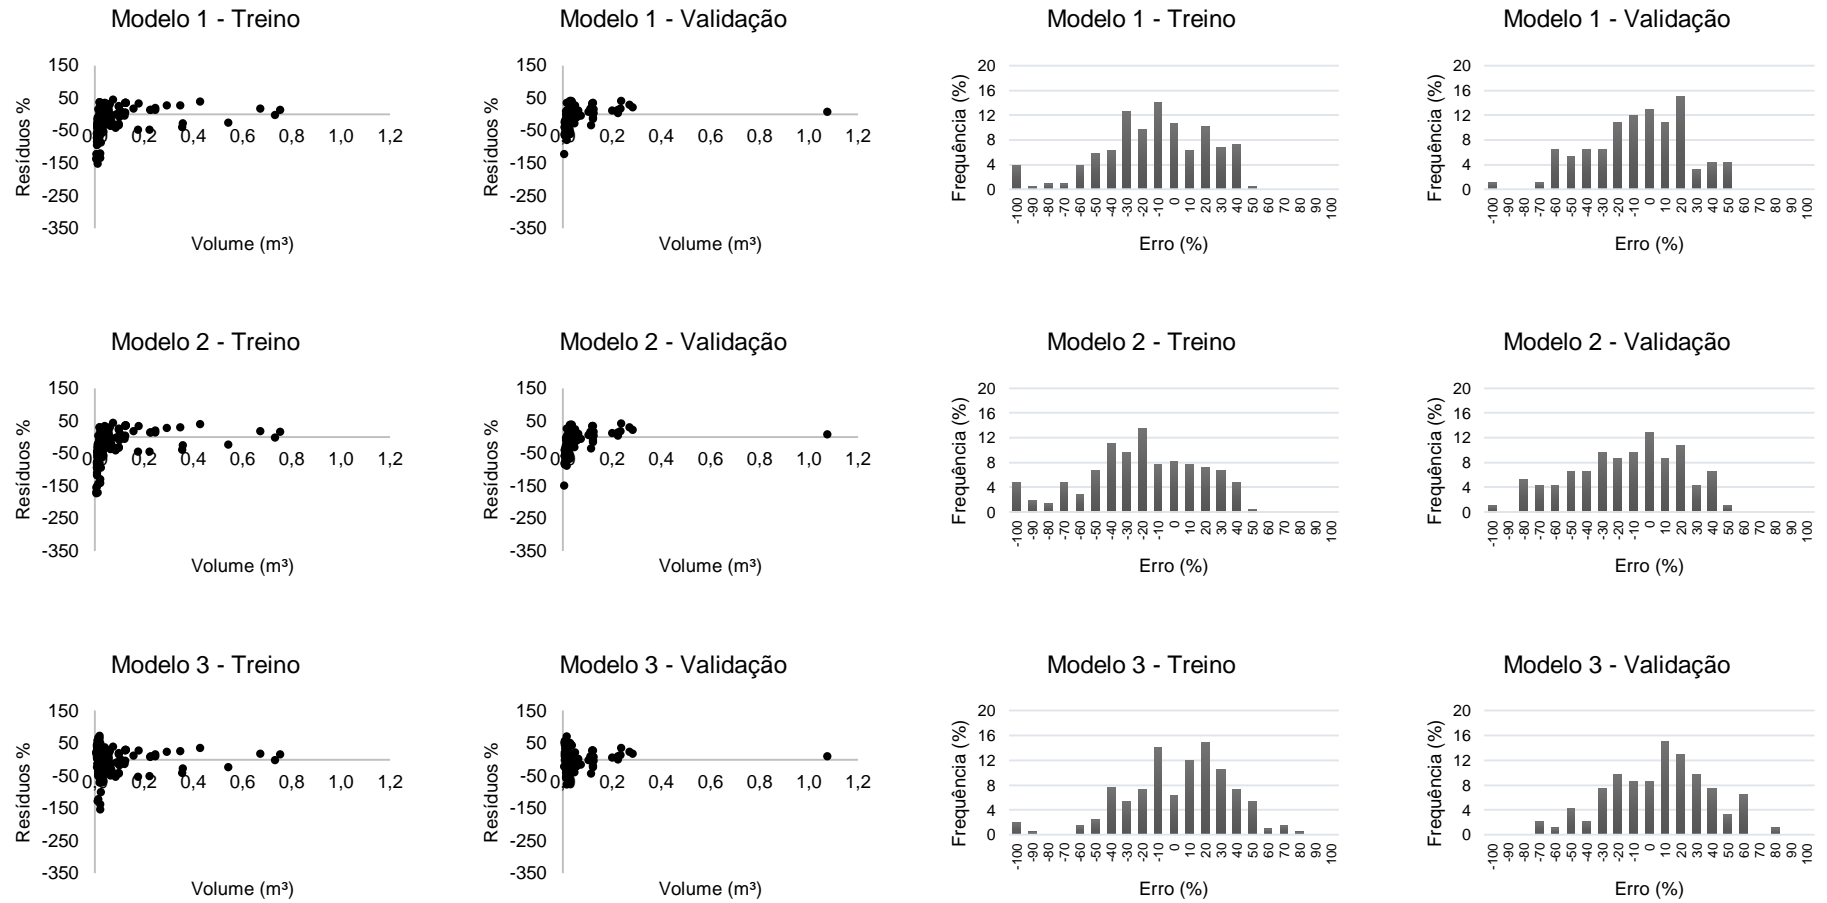
\* coeficientes significativos no modelo pelo teste t de *student*; ns = coeficientes não significativos no modelo.

A inclusão da variável altura ( $Ht$ ), apesar de ter sido fundamental no favorecimento de alguns modelos, não diferenciou em grande escala nas medidas de precisão, se comparada aos modelos de simples entrada. A variável  $dap$  sem transformação não obteve significância em todos os modelos e foi significativa quando transformada, exceto no modelo de Meyer (modelo 16), em que todas as variáveis inseridas não foram significativas. Já a transformação da variável dependente na sua forma logarítmica, apesar dos piores resultados no ajuste, obteve melhores performances no momento de validação, a exemplo do modelo de Spurr (log), que foi o modelo com menor erro dentre todos os modelos, porém com maiores tendências às superestimativas (Figura 3).

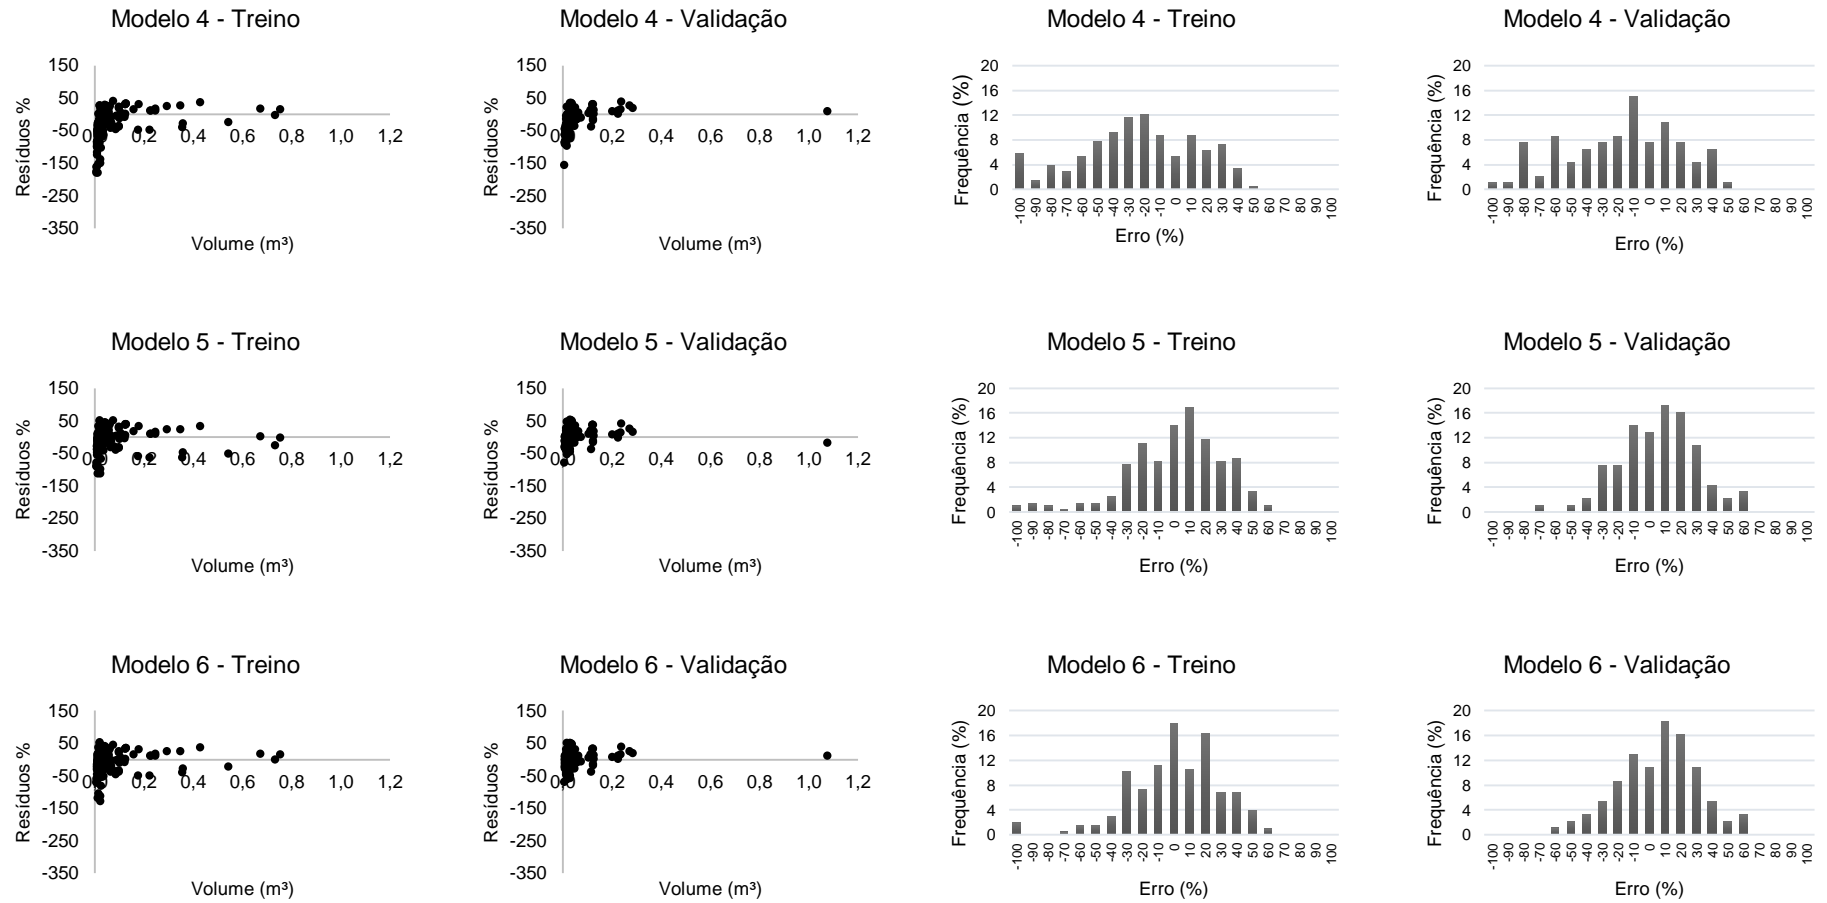
Observando a Tabela 4 e Figura 3, no que se refere aos parâmetros estatísticos, gráficos de resíduos e histograma de frequência dos erros percentuais, a equação que obteve equilíbrio nos dois aspectos foi a de Stoate (modelo 12), com um RMSE% de 50,33%,  $ryy'$  de 0,9664 para treino e 34,74% e 0,9910 na validação, sendo a combinação da variável  $dap$  com  $Ht$  não significativa para o modelo. Os gráficos de resíduos evidenciam que o modelo tem leve tendência a superestimativas em classes de volumes e diâmetros menores, apesar do caráter compensatório apresentado no histograma de frequência dos erros. Este aspecto se mostrou tanto para o treinamento quanto para a validação, porém com melhor distribuição para o ajuste do modelo (treino).

A característica de tendenciosidade também foi observada por Alves Júnior (2010), em estudo na Caatinga em Pernambuco, onde as melhores equações apresentaram grande capacidade de superestimar o volume nas menores classes de diâmetro em que, nesse sentido, os modelos de Spurr e Schumacher & Hall não obtiveram êxito perante as equações sugeridas pelo método de *stepwise*. O modelo de Spurr (log) foi um dos modelos que também apresentaram as piores medidas de precisão para treinamento no presente estudo, com 66% de erro no ajuste (Tabela 4). Já o modelo de Schumacher & Hall, em sua forma original, não obteve os melhores resultados quando comparado à sua forma logaritmizada, com maiores tendências no gráfico de resíduos. O modelo com a variável transformada foi o que obteve a melhor distribuição dos erros percentuais no momento de validação, o que justifica sua escolha dentre todos os modelos testados na volumetria com espécies nativas.

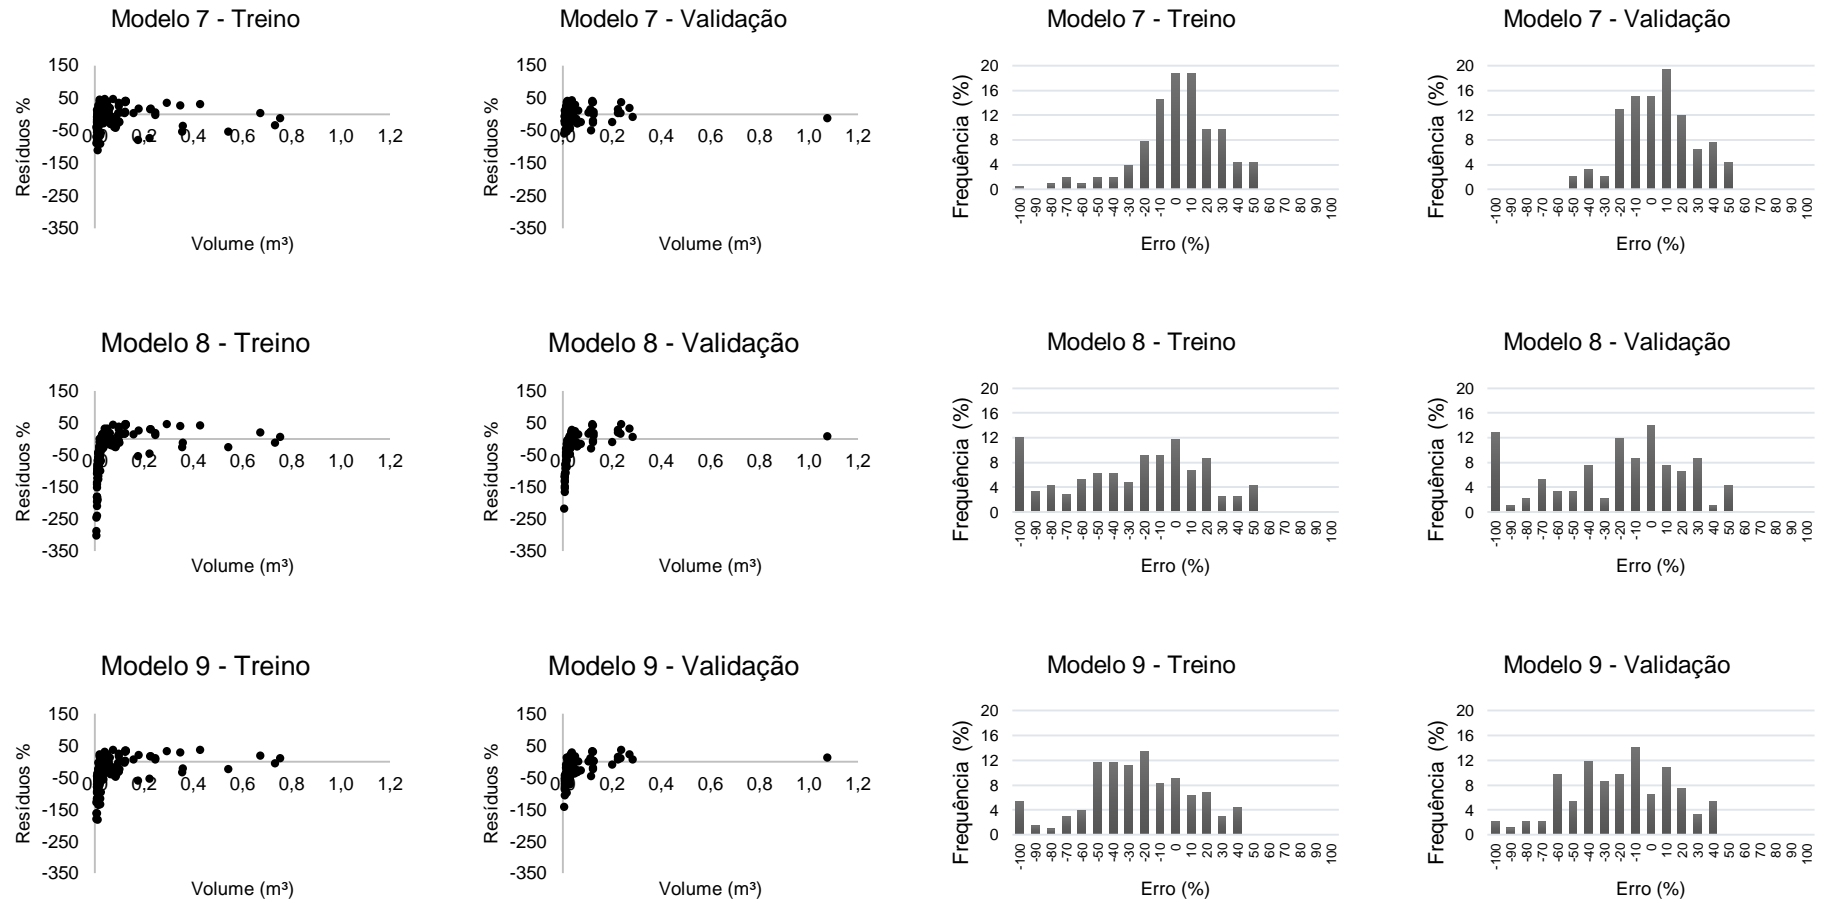




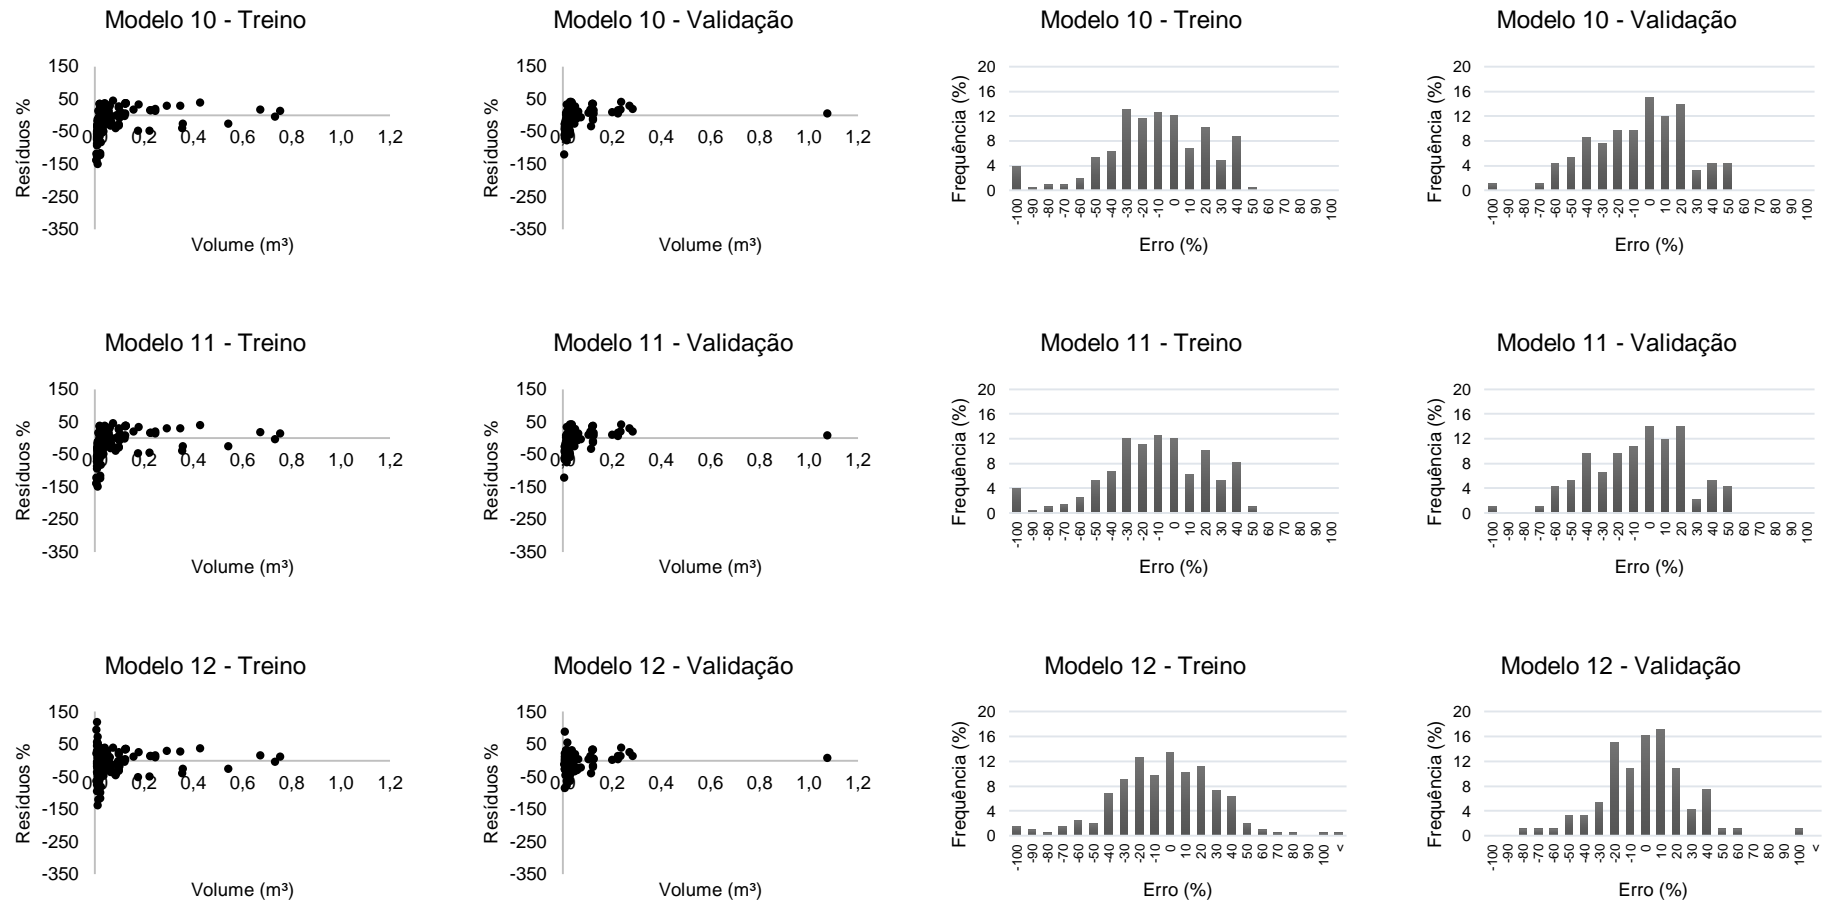
**Figura 3** – Gráficos de resíduos e histogramas de frequência dos erros percentuais das dezoito equações ajustadas, com 70% dos dados para ajuste (Treino) e 30% para validação da técnica para volume comercial com casca (VC<sub>cc</sub>) da Caatinga arbórea. “*Continua*”



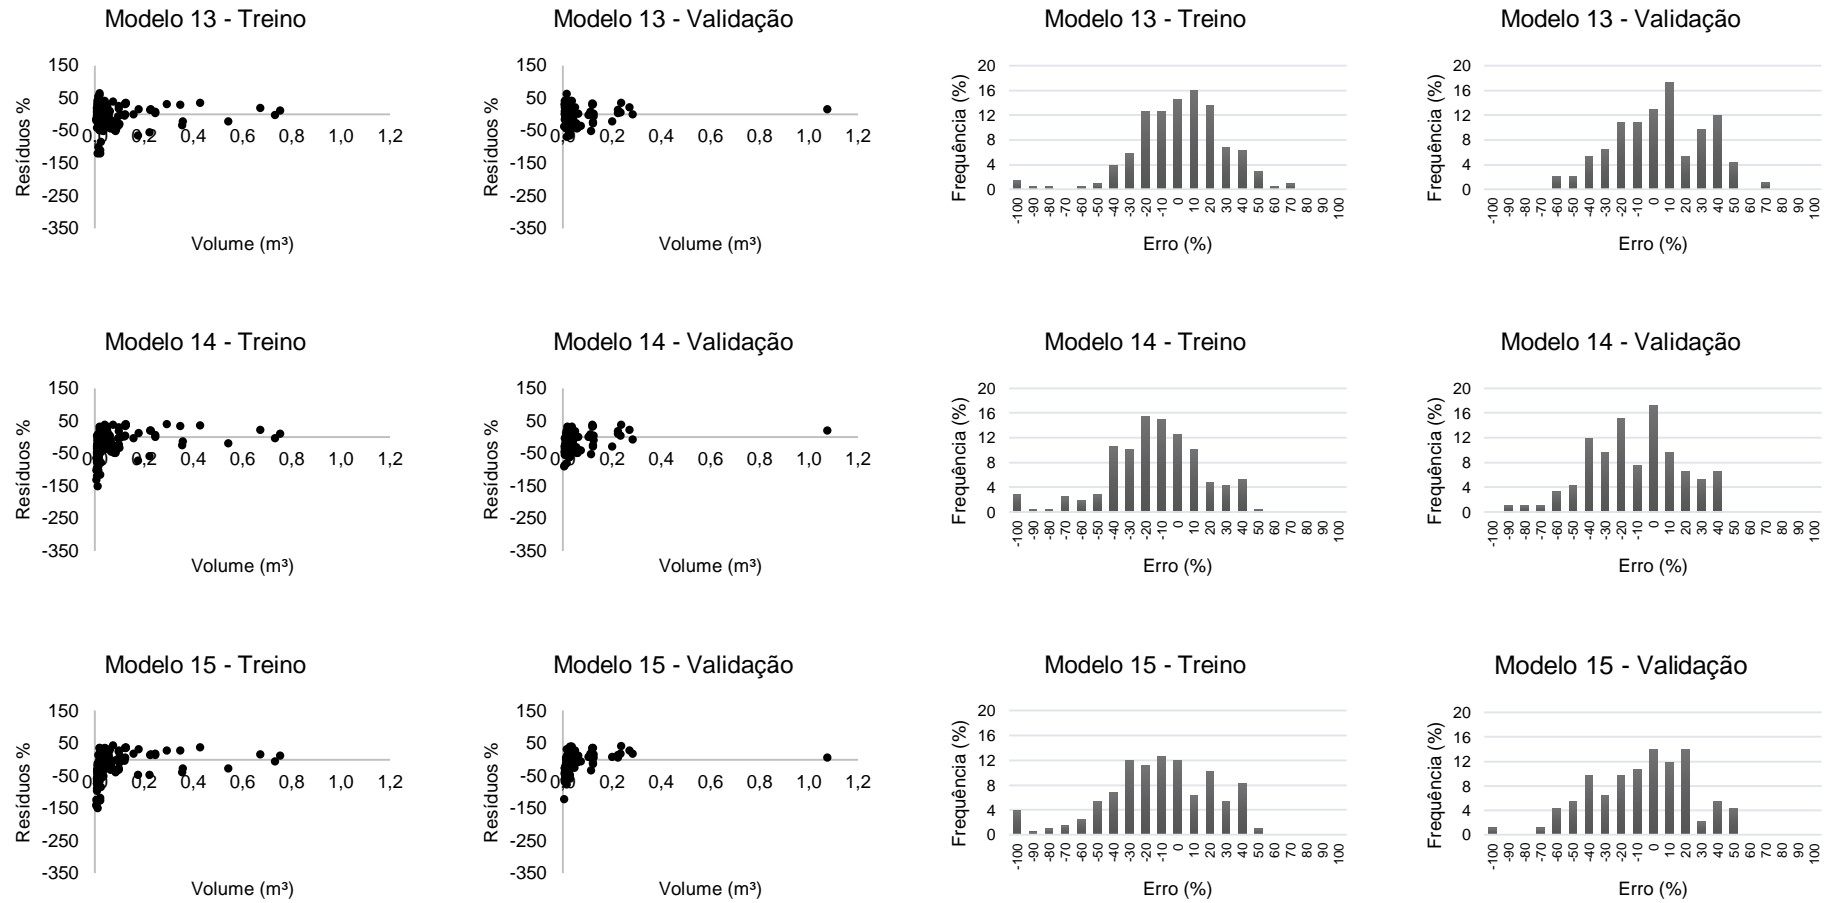
**Figura 3** – Gráficos de resíduos e histogramas de frequência dos erros percentuais das dezoito equações ajustadas, com 70% dos dados para ajuste (Treino) e 30% para validação da técnica para volume comercial com casca (VC<sub>cc</sub>) da Caatinga arbórea. “Continuação”



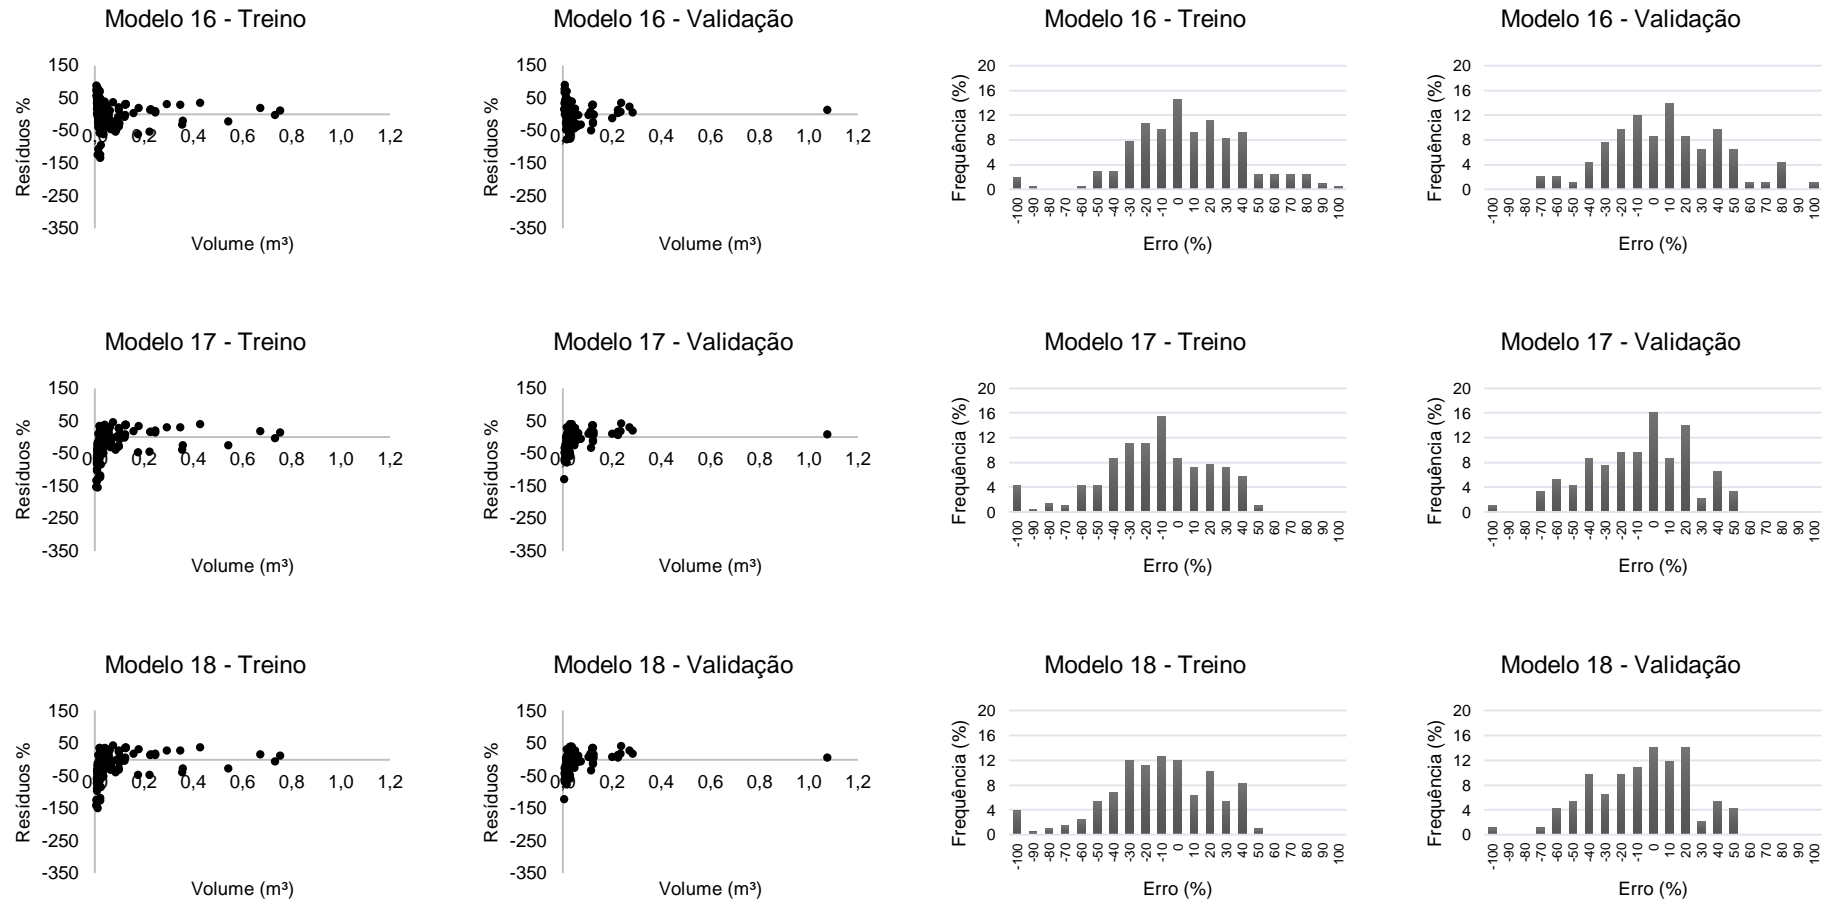
**Figura 3** – Gráficos de resíduos e histogramas de frequência dos erros percentuais das dezoito equações ajustadas, com 70% dos dados para ajuste (Treino) e 30% para validação da técnica para volume comercial com casca (VC<sub>cc</sub>) da Caatinga arbórea. “Continuação”



**Figura 3** – Gráficos de resíduos e histogramas de frequência dos erros percentuais das dezoito equações ajustadas, com 70% dos dados para ajuste (Treino) e 30% para validação da técnica para volume comercial com casca (VC<sub>cc</sub>) da Caatinga arbórea. “Continuação”



**Figura 3** – Gráficos de resíduos e histogramas de frequência dos erros percentuais das dezoito equações ajustadas, com 70% dos dados para ajuste (Treino) e 30% para validação da técnica para volume comercial com casca (VC<sub>cc</sub>) da Caatinga arbórea. “Continuação”



**Figura 3** – Gráficos de resíduos e histogramas de frequência dos erros percentuais das dezoito equações ajustadas, com 70% dos dados para ajuste (Treino) e 30% para validação da técnica para volume comercial com casca (VCCc) da Caatinga arbórea.

Apesar da recorrente escolha do modelo de Schumacher e Hall, na sua forma original, em estudos com Caatinga (LIMA, 2014; ARAÚJO et al., 2015) e outras fitofisionomias (MACHADO et al., 2008; COLPINI et al., 2009), o modelo não apresentou bons parâmetros estatísticos de ajuste, mas evidenciou ter melhor distribuição dos erros no gráfico de resíduos e histogramas. Isso mostra a importância da inclusão da variável altura para diminuir tendenciosidades, principalmente nos menores volumes e diâmetros, conforme evidencia tanto o gráfico de resíduos quanto o histograma para o modelo.

Este aspecto é devido ao caso das árvores com diâmetros equivalentes apresentarem variações notórias em sua altura, supondo que se sucederam no aspecto competitivo entre as árvores, o que faz com que apenas a variável *dap* suscite maiores valores residuais (MACHADO et al., 2008). Mas observa-se que alguns modelos de simples entrada com apenas a variável *dap* e suas transformações, obtiveram parâmetros semelhantes aos modelos de dupla entrada, porém com maiores tendenciosidades na dispersão dos resíduos nas menores classes de volume.

Os resultados aqui apresentados pelo modelo de Schumacher e Hall (log) foram superiores aos encontrados por Rufini et al. (2010), com espécies do Cerrado *stricto sensu*, onde foram testados os modelos de Spurr e Schumacher e Hall, logaritmizados, em que o melhor modelo foi o de Schumacher e Hall, com erros percentuais de 35% e  $R^2$  de 97%. Segundo Rezende et al. (2006), erros de 15 a 30% são aceitáveis devido à grande variedade de formas de fustes e copas, que é uma característica regular da vegetação do Cerrado e ocorre tanto entre espécies como dentro da mesma espécie. Apesar da semelhança no resultado, vale ressaltar que o estudo não validou as equações com dados que não foram utilizados para o ajuste das mesmas, o que evidencia a ótima precisão dos modelos aqui testados.

Lima (2014), trabalhando com espécies da Caatinga, inferiu que modelos de simples entrada com a inserção do diâmetro na base (*Db* ou *das*) são menos capazes de obter melhores estimativas, com erros de 37 a 47% e coeficiente de determinação ( $R^2_{aj.}$ ) de 0,67 a 0,83. Obteve melhores estimativas apenas quando a variável altura foi incluída nos modelos, com erros de 19 a 25% e  $R^2_{aj.}$  de 0,90 a 0,94, o que reforça a importância dos modelos de dupla entrada. O autor inferiu que o modelo de Meyer apresentou os melhores parâmetros estatísticos e distribuição

dos resíduos, em conjunto com o modelo de Schumacher e Hall (log). Esse mesmo comportamento foi observado por Araújo et al. (2015), ao comparar o modelo de Schumacher e Hall, de várias fitofisionomias do estado de Minas Gerais, com redes neurais, onde para a Caatinga arbórea foi obtido um erro percentual (RMSE%) de 25% e correlação de 0,98.

Portanto, o modelo que obteve a melhor forma de ajuste e com menos tendenciosidades no gráfico de resíduos e histograma de frequência dos erros, foi o de Schumacher e Hall, logaritmizado (modelo 7). Como não houve diferenças notórias nos parâmetros estatísticos entre os modelos testados, principalmente no momento de validação da técnica, a definição de sua escolha se deu a partir da análise gráfica dos resíduos, sobretudo com ênfase no comportamento do histograma de frequência dos erros percentuais.

Com base no teste da falta de ajuste, observou-se que a hipótese de nulidade foi aceita, pois a estatística F não foi significativa para a falta de ajuste, apresentando um valor de P maior que o nível de significância escolhido para o teste ( $\alpha = 0,05$ ), portanto, não há problemas no ajuste do modelo (Tabela 5).

**Tabela 5** – Tabela com os valores da análise de variância e teste da falta de ajuste do modelo de Schumacher e Hall (log) (modelo 7).

Fonte	GL	SQ	QM	F-valor	P-valor
<i>Indap</i>	1	236,02	236,02	3579,15	< 2,2e-16
<i>lnHt</i>	1	4,217	4,217	63,948	9,38e-14
Resíduo	204	13,452	0,066	-	-
Falta de ajuste	183	12,418	0,068	1,3782	0,1967
Erro puro	21	1,034	0,049	-	-
<b>Total</b>	<b>205</b>	<b>240,237</b>	-	-	-

### 3.2. Redes evolutivas e modelos de regressão para estimativa de volume

As redes NEAT evidenciaram melhores resultados referentes às principais medidas de precisão avaliadas em comparação às equações lineares e não lineares, conforme inferem os valores da raiz do erro quadrado médio (RMSE%), a correlação ( $r_{yy'}$ ) e os valores de AIC (Tabela 6).

Observou-se que houve uma preponderância do *dap* nas melhores redes para cada população e, a variável *das*, apenas auxiliou na obtenção do melhor



desempenho das redes, também em conjunto com a variável *Ht*, não consolidando bons resultados quando trabalhada isoladamente. Lima (2014), ao avaliar aspectos volumétricos da Caatinga, observou que apenas o diâmetro na base (*das*) conferiu as piores estimativas tanto para modelos de regressão quanto para redes neurais do tipo MLP. Este aspecto pode ser explicado devido à forma geométrica da árvore, criando a alusão de afilamento do fuste entre as primeiras seções até o seguimento de 1,3 m, o que torna compatível à ideia do formato cônico, sobretudo em gerar uma possível relação de dependência do *das* ao *dap*.

Geralmente as seções próximas à base são susceptíveis a maiores diâmetros, que devem estar atrelados ao fato de serem regiões com maiores deformidades no fuste. Foi observado, no caso específico da FLONA, que os intervalos contêm anormalidades devido ao corte realizado em anos anteriores, apresentando características de rebrota.

**Tabela 6** – Parâmetros estatísticos referentes às redes evolutivas *Neurevolution of Augmenting Topologies (NEAT)* com as principais medidas de precisão avaliadas para validação da técnica, na estimativa de volume comercial com casca (VC<sub>cc</sub>).

Entrada	RNA	Tamanho da população	Densidade inicial	Treinamento			Validação		
				RMSE%	ryy'	AIC	RMSE%	ryy'	AIC
<i>dap; das; Ht</i>	1	300	0,1	40,03	0,9791	-675,61	33,05	0,9910	-305,28
<i>dap</i>	2	300	0,5	47,26	0,9699	-647,72	30,37	0,9912	-317,02
<i>dap; das; Ht</i>	3	600	0,1	36,88	0,9818	-688,89	31,01	0,9898	-311,76
<i>dap; das; Ht</i>	4	600	0,5	43,14	0,9757	-662,17	27,61	0,9909	-320,80
<i>dap; Ht</i>	5	800	0,1	38,70	0,9813	-683,72	32,93	0,9872	-308,77
<i>dap; das</i>	6	800	0,5	39,49	0,9795	-679,82	27,36	0,9913	-323,95
<b><i>dap</i></b>	<b>7</b>	<b>1000</b>	<b>0,1</b>	<b>41,82</b>	<b>0,9769</b>	<b>-671,32</b>	<b>27,42</b>	<b>0,9905</b>	<b>-325,32</b>
<i>dap; das</i>	8	1000	0,5	46,26	0,9718	-651,63	28,72	0,9913	-319,40

RMSE% = raiz do erro quadrático médio, em percentual; ryy' = coeficiente de correlação linear de Pearson.

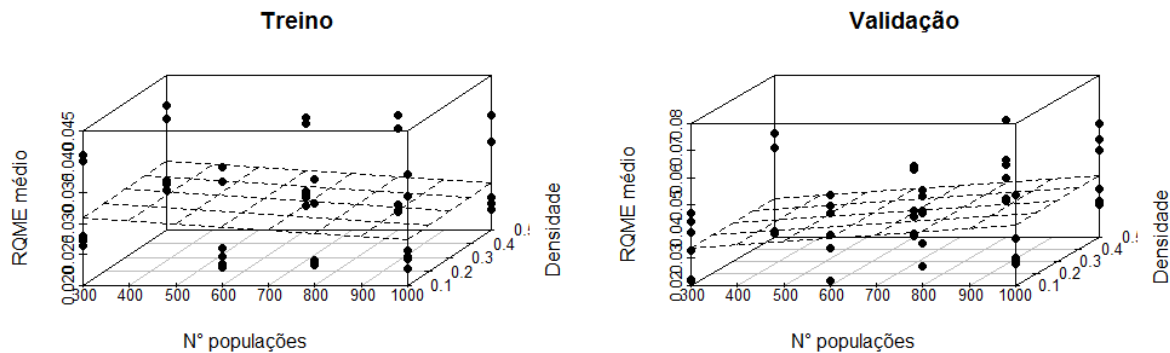
A medida na base (*das* ou diâmetro a 0,3m) tem se tornado uma importante variável para estimativa de volume em florestas nativas e bastante utilizada nos inventários e em volumetria (REZENDE et al., 2006; MACHADO et al., 2008; IMAÑAS-ENCINAS et al., 2009; RUFINI et al., 2010). A escolha se dá pelo fato de grande parte das fitofisionomias manifestarem fustes bastante perfilados na altura do *dap*, isentando o manejador na coleta de duas ou mais medidas e a transformação da variável pelo diâmetro equivalente.

Contudo, observou-se que o *das* traz grandes variações que podem enfraquecer a relação diâmetro/volume, por ser uma área crítica e que possui grandes deformidades no fuste. Outro aspecto limitador é que seu valor não é fiel ao explicar o volume individual do fuste, principalmente quando há um grande número de bifurcações, o que interfere nas relações alométricas. Este foi o principal fator para que a variável, isoladamente, não obtivesse melhores estimativas se comparada ao diâmetro a 1,3 m (*dap*), mesmo tendo surgido em combinação com as variáveis *dap* e *Ht*, em cinco das oito melhores redes selecionadas (Tabela 6). Isso infere na necessidade da coleta do *dap* de cada fuste perfilado, bem como, posteriormente, a transformação dos diâmetros pela forma equivalente, evitando assim o uso do *das*.

As redes NEAT indicaram valores variados se analisarmos cada número de indivíduos e densidades iniciais utilizadas. Isso porque foram retidas apenas as melhores redes, necessitando de uma análise mais apurada para verificar se há ou não influências entre as populações e densidades iniciais aplicadas na diminuição do erro absoluto.

A Figura 4 apresenta graficamente as dimensões do erro para as duas etapas de avaliação das redes NEAT, através da distribuição da média da raiz do erro quadrático médio (absoluto), especialmente se os fatores impactam diretamente no seu desempenho.

Observou-se que no momento de treinamento das redes, quanto maior for o número de indivíduos melhor é o desempenho das mesmas para a tarefa pretendida. No entanto, este comportamento foi antagônico no momento de validação, mesmo que pouco significativo. Isto porque, com maiores indivíduos iniciais, habilita a rede em ampliar a área de busca e a probabilidade em encontrar o menor erro, estendendo o número de variações das topologias para então selecionar a melhor e mais simples estrutura que resolva o problema proposto (STANLEY e MIKKULAINEN, 2002; 2004; STANLEY, 2004). Entretanto, maiores indivíduos nas populações iniciais, apesar de melhorar o desempenho, exigem que o algoritmo necessite de maiores recursos computacionais e trabalhe por um período de tempo acima do convencional, se comparado a outras topologias (BRAGA et al., 2014).

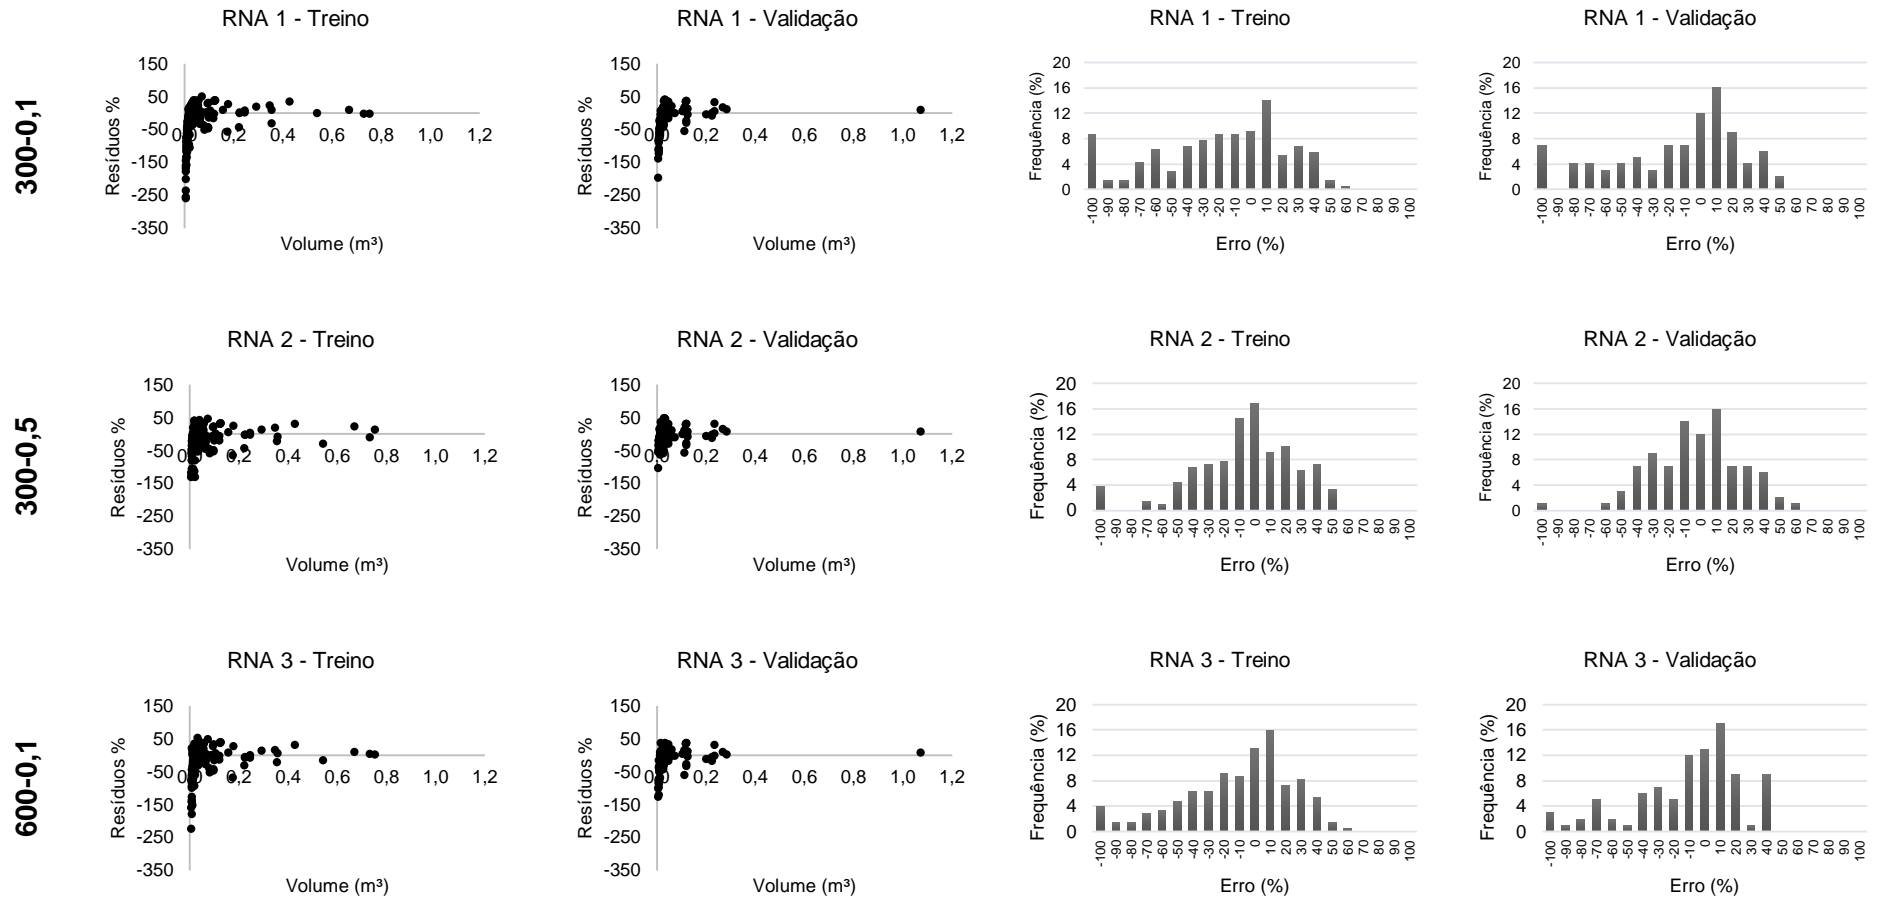


**Figura 4** – Comportamento do erro médio absoluto em função do número de indivíduos por população, densidades iniciais e todas as variáveis de entrada, pelo algoritmo NEAT.

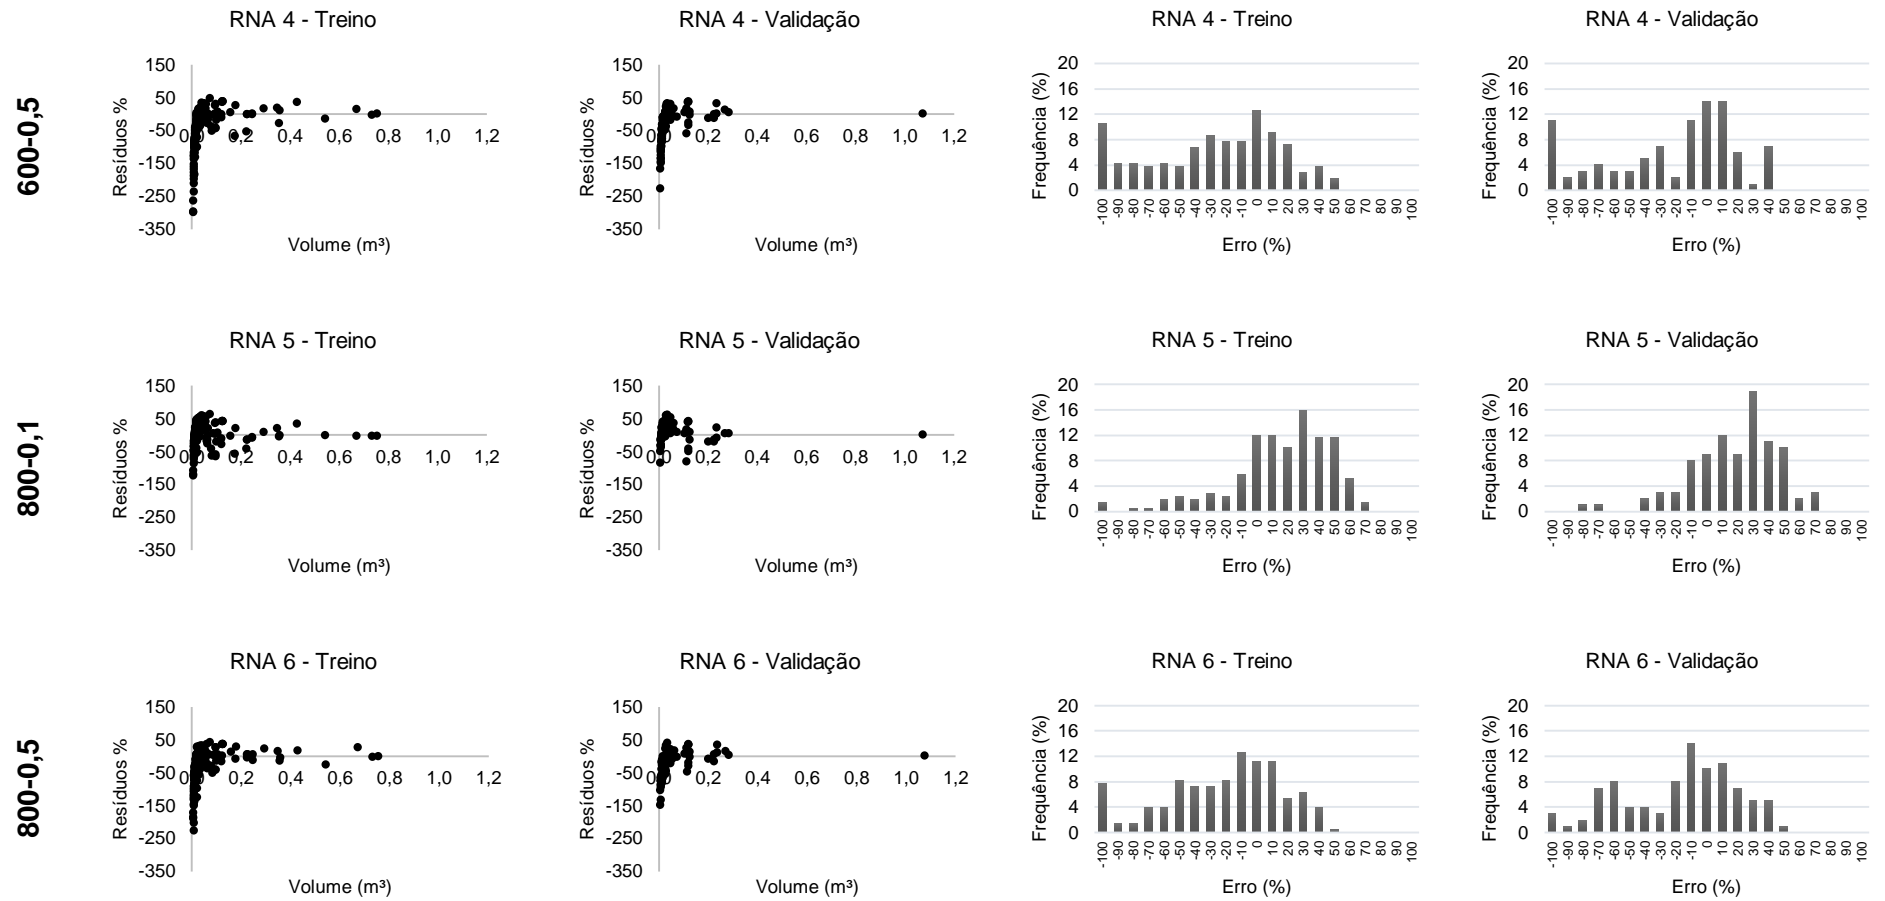
Vale ressaltar que, apesar da diferenciação no momento de validação, esta análise do algoritmo deve ser feita através do seu comportamento no processo de treinamento. A etapa é menos interferida pelo aspecto probabilístico do algoritmo, mostrando-se mais facilmente estável nos resultados do erro por ser mais sensível à inclusão de parâmetros na rede, a exemplo das variáveis de entrada, e menos influenciada pela aleatoriedade. Segundo Braga et al. (2014), as redes que possuem estes algoritmos se baseiam na computação evolucionária e algoritmos genéticos que utilizam regras de transição probabilísticas, com aleatoriedade baseada em históricos da rede de forma interativa.

Assim, a rede que obteve o melhor desempenho e equilíbrio entre os dois processos foi a RNA 7, com 1.000 indivíduos e densidade inicial de 0,1, conforme mostra o gráfico de dispersão de resíduos e histograma de frequência dos erros percentuais (Figura 5).


Conforme justificado pelas estatísticas geradas, as redes obtiveram melhores resultados e menos tendenciosidades no momento de validação, se confrontado ao processo de treinamento. Isto evidencia que todas as redes selecionadas possuíram um caráter evolutivo que contemplou a premissa básica que deve ser evitada, ou seja, a de não possuírem capacidade de generalização (ou *overfitting*) quando dados desconhecidos são inseridos (Figura 5).



**Figura 5** – Gráficos da dispersão dos erros residuais em função do volume observado ( $V_{Ccc}$ ) e histograma dos erros percentuais para cada configuração de redes com o algoritmo *Neuroevolution of Augmenting Topologies (NEAT)*. “Continua”



**Figura 5** – Gráficos da dispersão dos erros residuais em função do volume observado ( $VC_{cc}$ ) e histograma dos erros percentuais para cada configuração de redes com o algoritmo *Neuroevolution of Augmenting Topologies (NEAT)*. “Continuação”



**Figura 5** – Gráficos da dispersão dos erros residuais em função do volume observado ( $VC_{cc}$ ) e histograma dos erros percentuais para cada configuração de redes com o algoritmo *Neuroevolution of Augmenting Topologies (NEAT)*.

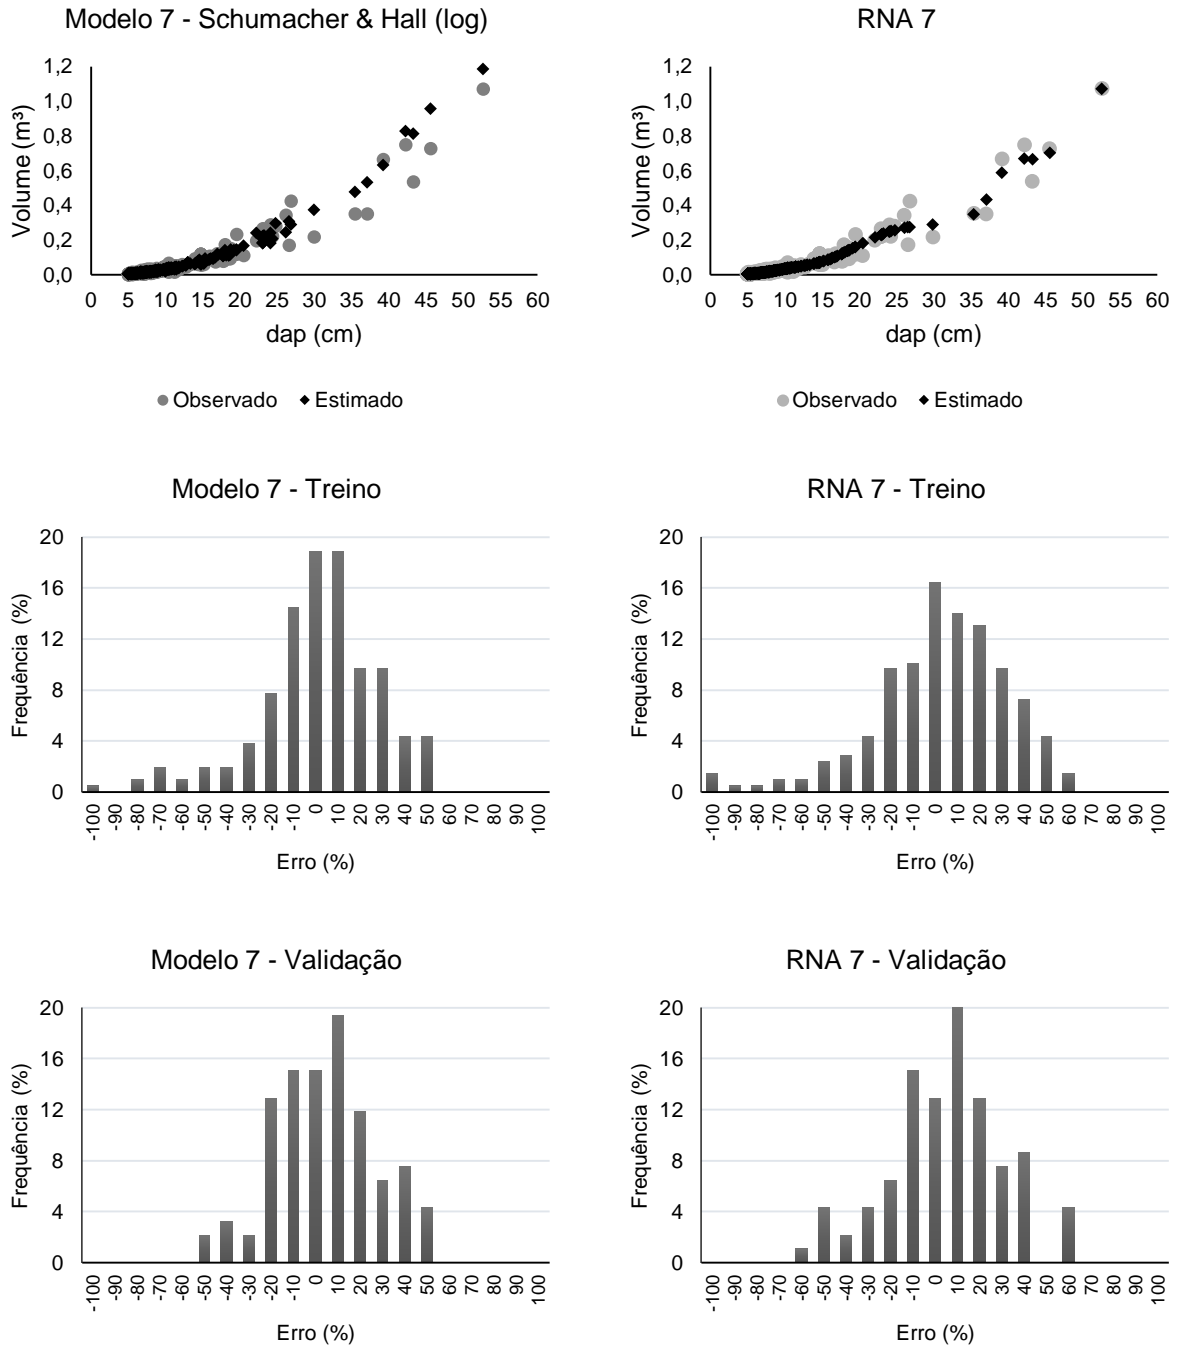
Nota-se que todas as redes obtiveram uma alta tendência à superestimativa nos menores volumes, com erros concentrados majoritariamente nos intervalos de -40 a 30% nas melhores redes. Apesar de o algoritmo ter obtido as melhores estatísticas, a técnica não se mostrou eficaz em diminuir as superestimativas nas árvores de menores diâmetros, o que é um problema recorrente na volumetria de espécies nativas em diversas fitofisionomias (LIMA, 2014, ARAÚJO et al., 2015). Assim, as redes evidenciaram dispersões semelhantes se comparadas ao melhor modelo ajustado, possuindo, visualmente, ocorrência de viés nos desvios em ambas as técnicas, devido ao impacto das árvores de menores diâmetros às relações alométricas. Porém, as redes foram mais eficazes em obter melhores ajustes aos valores reais de volume (Figuras 5 e 6).

O modelo de Schumacher e Hall (log), além de necessitar a inclusão da variável altura, consegue explicar melhor as variações nas árvores de menores diâmetros, o que o torna menos tendencioso se comparado à RNA. Isto pode ser evidenciado ao analisar os diâmetros compreendidos no intervalo entre 5 a 25 cm de diâmetro no gráfico, o que não ocorreu na rede NEAT (Figura 6).

Vale ressaltar que a performance da rede se deu através da inserção simples de dois neurônios na camada de entrada (o *dap* e o *bias*), o que torna interessante no aspecto operacional do inventário, já que a variável altura possui um viés complicador por ser de difícil aquisição, sobretudo por gerar bastante ruído nas bases de dados principalmente em florestas nativas. Entretanto, para alguns modelos de regressão, a inclusão desta variável pode contribuir no sentido de amenizar as discrepâncias ocorridas nas árvores menores, que neste trabalho obteve uma concentração de 64% dos dados na primeira classe diamétrica.

A maior incidência de árvores com menor volume, como era esperado, pode ser explicada pelo histórico da área, que houve supressão por parte de uma empresa mineradora (IBAMA, 2006) e atualmente encontra-se em fase inicial de regeneração. Este aspecto causa um forte impacto nos ajustes tanto para os modelos de regressão quanto para as redes e, é o maior responsável pelo efeito negativo em ambas as técnicas. Esta problemática já foi relatada em diversos trabalhos com nativas (REZENDE et al., 2006; IMAÑAS-ENCINAS et al., 2009; LIMA, 2014; ARAÚJO et al., 2015). Áreas perturbadas tendem a oferecer uma dinâmica diferenciada na recomposição da flora, o que explica as variações no

crescimento das espécies, evidenciando o aspecto descontínuo da floresta em seus primeiros estágios e, portanto, variando seu volume.



**Figura 6** – Análise comparativa da performance das duas técnicas avaliadas, referente ao melhor modelo de regressão e a melhor rede NEAT escolhida e os histogramas de frequência dos erros percentuais para estimativa do volume comercial (VC<sub>cc</sub>).



Nesse sentido, as redes NEAT, por serem de caráter probabilístico e não determinístico, são capazes de percorrer um diferente caminho para atingir soluções coerentes à tarefa incumbida. Este aspecto é que torna o uso dos algoritmos genéticos (AGs) um processo vantajoso na tomada de decisões, bem como, quando são contemplados às RNA quadros distintos e bases de dados bastante ruidosas. A Figura 6 mostra as várias nuances nos valores estimados pelo algoritmo em perfazer um caminho que contemple o comportamento não linear dos dados, através de aproximações que desenvolvam o menor erro cabível.

Assim, o algoritmo obteve uma diminuição percentual no erro (RMSE%) em torno de 7,65% no momento de validação, em comparação ao modelo de Schumacher & Hall (log). Araújo (2015a), em trabalho pioneiro com o NEAT, observou que o algoritmo obteve melhores performances ao compará-lo com o modelo de Schumacher & Hall, obtendo um decréscimo de aproximadamente 6% no erro (RMSE), com a mesma quantidade de indivíduos e densidades iniciais, em que o modelo obteve um RMSE de 25% e a NEAT 19%, no momento de validação para Caatinga arbórea.

Lima (2014) concluiu que, tanto o uso da equação de Schumacher & Hall quanto as redes MLP com algoritmo *backpropagation*, foram eficazes na estimativa de volume do fuste da Caatinga, em Pernambuco. Contudo, tanto a forma logarítmica quanto a não linear do modelo, foram melhores no momento de validação dos dados se comparados às RNA. Observou também a dificuldade em obter uma ótima configuração no momento de treinamento da rede, o que pode ser um entrave para a escolha da técnica, por exigir um maior grau de processamento, conhecimento prévio sobre a melhor arquitetura e dispêndio de tempo na tomada de decisões.


Nesse sentido, os algoritmos de caráter evolutivo se tornam uma interessante ferramenta por isentar o caráter empírico a respeito da melhor arquitetura das RNA, por funcionar de forma contínua e iterativa em busca da melhor configuração que cumpra o objetivo final proposto. No entanto, sua busca pela melhor conformação que atenda aos pressupostos mínimos de boa performance, demanda maior consumo de processamento da máquina (BRAGA et al., 2014), o que pode ser improfícuo, tendo em vista as limitações tecnológicas por parte do manejador.

Em relação ao teste F de Graybill e de identidade entre os métodos, observa-se que os dois métodos propostos são diferentes estatisticamente, em que  $F(H_0)$  foi significativo para ambas as etapas, portanto significa que o  $\beta_0$  e o  $\beta_1$  são, ao mesmo tempo e respectivamente, diferentes de 0 e 1 (Tabela 7), rejeitando-se, assim, a hipótese de nulidade. Este aspecto pode ser reforçado ao observar o comportamento da linha de tendência da equação linear em ambas as etapas (Figura 7), tanto para treino e validação, sendo que na etapa de generalização, a curva média gerada pela equação foi mais acurada e atende aos princípios recomendados por Leite e Oliveira (2002). Portanto, o que pode ser verificado ao analisar os resultados das significâncias, simultaneamente, tanto para a estatística F,  $t_{\bar{e}}$  e a correlação ( $R_{YYP} \geq 1 - |\bar{e}|$ ), é que os métodos não são iguais estatisticamente, o que confere à RNA o melhor desempenho.

**Tabela 7 – Resultados do teste sugerido por Leite e Oliveira (2002).**

Etapa	Método		n	$\beta_0$	$\beta_1$	$R_{YYP}$	F(H <sub>0</sub> )	$\bar{e}$	$t_{\bar{e}}$	$R_{YYP} \geq (1 -  \bar{e} )$	Conc.
	Padrão	Altern.									
T	Mod. 7	NEAT	207	0,007 <sup>a</sup>	0,824 <sup>a</sup>	0,988	16,11*	0,0007	-0,06 <sup>ns</sup>	Não	Y ≠ Y <sub>p</sub>
V	Mod. 7	NEAT	93	0,004 <sup>a</sup>	0,926 <sup>a</sup>	0,995	11,24*	0,0066	-0,47 <sup>ns</sup>	Sim	Y ≠ Y <sub>p</sub>

<sup>a</sup>: valores significativos pelo teste t ( $\alpha = 0,05$ ); \*: valores significativos pelo teste F de Graybill ( $\alpha = 0,05$ ); ns: valores não significativos ( $\alpha = 0,05$ ); T: Treino; V: Validação;  $\bar{e}$ : erro médio;  $t_{\bar{e}}$ : t calculado do erro médio;  $R_{YYP}$ : correlação entre a técnica alternativa e a padrão; n: número de observações.



**Figura 7 – Relação entre as estimativas do método padrão (modelo 7) e método alternativo (NEAT), com as respectivas linhas de tendência geradas pela equação linear simples, para o teste de identidade entre os métodos e teste F de Graybill.**

Isso mostra que o caráter evolutivo das redes NEAT favoreceram no momento de generalização para dados desconhecidos, o que evidencia uma alta performance de ajuste para os dados apresentados, se comparada ao modelo. Outra vantagem é que a topologia escolhida consegue captar os padrões da floresta com apenas uma variável de entrada (o *dap*), o que em termos operacionais se torna mais vantajoso por isentar, a depender da escolha do manejador, a coleta da variável altura nos inventários, caso esta seja operacionalmente dificultosa.

As técnicas aqui apresentadas obtiveram bons resultados e podem servir de subsídio para a tomada de decisão quanto à forma de manejo que deverá ser adotada em áreas afins, com melhor acurácia ao utilizar as redes evolutivas com o NEAT. As espécies da Caatinga possuem grande potencial econômico e, nos últimos anos, tem crescido o interesse por parte do estoque volumétrico dessa vegetação, a fim de suprir a grande demanda por energia e outros produtos originados da madeira.

#### 4. CONCLUSÕES

O modelo de Schumacher & Hall (log) foi o que gerou as menores tendenciosidades nos menores e maiores volumes, portanto foi escolhido como o melhor dentre todos os modelos ajustados.

Todos os modelos possuem capacidade de generalização equivalentes e obtiveram menores erros se comparados ao processo de ajuste, o que mostra a eficácia da técnica para estimativas de volume.

As redes com o NEAT obtiveram melhores valores das estatísticas referentes às medidas de precisão avaliadas, porém evidenciou semelhante tendência em superestimar o volume na distribuição dos resíduos e histogramas, quando comparadas ao modelo de Schumacher & Hall (log).

A melhor configuração de rede com o NEAT se deu apenas com uma variável de entrada (o *dap*), 1.000 indivíduos e densidade inicial de 0,1. A variável *das*, utilizada individualmente, conferiu às redes piores estimativas e, portanto, não deve ser escolhida.

A rede evolutiva foi mais eficaz em buscar padrões de reconhecimento do comportamento dos dados, diminuindo o erro em 7,65% na generalização, o que a configura como a técnica mais acurada na estimativa de volume comercial das espécies da Caatinga arbórea.

## 5. REFERÊNCIAS

- ALVES JÚNIOR, F. T. **Estrutura, biomassa e volumetria de uma área de Caatinga, Floresta – PE**. Recife-PE: UFRPE, 2010, 123 p. Tese (Doutorado em Ciências Florestais) – Universidade Federal Rural de Pernambuco.
- ARAÚJO, A. C. da S. C. BINOTI, M. L. M. da S.; LEITE, H. G.; BINOTI, D. H. B.; XIMENES, L. C.; NOGUEIRA, G. S.; CARNEIRO, J. A. Artificial Neural Networks with Skip Layer connections to estimate the volume of forest formations in the state of Minas Gerais. **Australian Journal of Basic and Applied Sciences**, v. 36, n. 9, p. 319-327, 2015.
- ARAÚJO, A. C. da S. C. **Redes neurais artificiais para quantificação volumétrica de florestas nativas no estado de Minas Gerais**. Diamantina-MG: UFVJM, 2015a, 73 p. Dissertação (Mestrado em Ciências Florestais) – Universidade Federal dos Vales do Jequitinhonha e Mucuri.
- ARAÚJO, B. H. P. de. **Modelagem da altura, volume e afilamento de *Calycophyllum spruceanum* Benth. empregando regressão e redes neurais artificiais**. Manaus-AM: INPA, 2015b, 53 p. Dissertação (Mestrado em Ciências de Florestas Tropicais) – Instituto Nacional de Pesquisas da Amazônia.
- BINOTI, D. H. B.; BINOTI, M. L. M. da S.; LEITE, H. G. Configuração de redes neurais artificiais para estimação do volume de árvores. **Ciência da Madeira**, v. 5, n. 1, p. 58-67, 2014.
- BINOTI, M. L. M. **Emprego de redes neurais artificiais em mensuração e manejo florestal**. Viçosa-MG: UFV, 2012, 130 p. Tese (Doutorado em Ciências Florestais) – Universidade Federal de Viçosa.
- BINOTI, M. L. M. **Redes neurais artificiais para prognose da produção de povoamentos não desbastados de eucalipto**. Viçosa-MG: UFV, 2010, 54 p. Dissertação (Mestrado em Ciências Florestais) – Universidade Federal de Viçosa.
- BRAGA, A. P.; CARVALHO, A. P. L. F.; LUDERMIR, T. B. **Redes neurais artificiais: teoria e aplicações**. 2. ed.- [Reimpr.], LTC, Rio de Janeiro, 2014, 226 p.
- BRASIL. **Lei nº 9.985, de 18 de Julho de 2000**. Regulamenta o artigo 225, § 1º, incisos I, II, III e VII da Constituição Federal, institui o Sistema Nacional de Unidades de Conservação da Natureza e dá outras providências. Ministério do Meio Ambiente, Brasília.
- BRASILEIRO, R. S. Alternativas de desenvolvimento sustentável no semiárido nordestino: da degradação à conservação. **Scientia Plena**, v. 5, n. 5, 2009.

BURNHAM, K. P.; ANDERSON, D. R. **Model selection and multimodel inference: a practical information theoretic approach**. 2 ed. Springer, New York, 2002, 488 p.

BURNHAM, K. P.; ANDERSON, D. R.; HUYVAERT, K. P. AIC model selection and multimodel inference in behavioral ecology: some background, observations, and comparisons. **Behavioral Ecology and Sociobiology**, v. 65, n. 1, p. 23-35, 2010.

COLPINI, C.; TRAVAGIN, D. P.; SOARES, T. S.; SILVA, V. S. M. Determinação do volume, do fator de forma e da porcentagem de casca de árvores individuais em uma Floresta Ombrófila Aberta na região noroeste de Mato Grosso. **Acta Amazônica**, v. 39, n.1, p. 97-104, 2009.

FIGUEIREDO, E. O.; SCHROEDER, R.; PAPA, D. de A. Fatores de Forma para 20 Espécies Florestais comerciais da Amazônia. **Comunicado Técnico**, n. 173. Embrapa: Rio Branco, AC, 2009.

FRANCO, S. A. P. **Estrutura e volume de povoamento de um remanescente de floresta estacional semidecidual em Curvelo, MG**. Diamantina-MG: UFVJM, 2012, 67 p. Dissertação (Mestrado em Ciências Florestais) – Universidade Federal dos Vales do Jequitinhonha e Mucuri.

GAMA, A. T.; CABACINHA, C. D.; MEIRA, M. R.; LEITE, M. V. S. Estimativas Volumétricas y Hipsométricas para el Barbatimão en el Norte de Minas Gerais. **Revista Flor@m**, v. 22, n. 4, p. 483-493, 2015.

GRAYBILL, F.A. **Theory and Application of the Linear Model**. Duxbury Press, Belmont, 1976, 704 p.

HAYKIN, S. **Neural networks and learning machines**. 3. ed. Prentice Hall, New York, 2009, 906 p.

HAYKIN, S. **Redes neurais: princípios e prática**. 2. ed. Bookman, Porto Alegre, 2001, 900p.

IBAMA – Instituto Brasileiro de Meio Ambiente e dos Recursos Naturais Renováveis. **Plano de Manejo**: Floresta Nacional Contendas do Sincorá, Volume I. MMA, Brasília, 2006.

IMAÑAS-ENCINAS, J.; SANTANA, Q. A.; PAULA, J. E. de; IMAÑA, C. R. Equações de volume de madeira para o cerrado de Planaltina de Goiás. **Floresta**, v. 39, n. 1, p. 107-116, 2009.

INEMA – Instituto do Meio Ambiente e Recursos Hídricos do Estado da Bahia. **Regiões de Planejamento e Gestão das Águas – RPGA e Solos**. Governo do Estado da Bahia, 2014.

LEITE, H. G.; OLIVEIRA, F. H. T. Statistical procedure to test the identity of analytical methods. **Communications in Soil Science and Plant Analysis**, v. 33, p.1105-1118, 2002

LIMA, R. B. de. **Distribuição diamétrica e volumetria em vegetação de caatinga arbustiva-arbórea, Floresta-PE**. Recife-PE: UFRPE, 2014, 134 p. Dissertação (Mestrado em Ciências Florestais) – Universidade Federal Rural de Pernambuco.

LOPES, C. G. R.; FERRAZ, E. M. N.; CASTRO, C. C. de; LIMA, E. N. de; SANTOS, J. M. F. F. dos; SANTOS, D. M. dos; ARAÚJO, E. de L. Forest succession and distance from preserved patches in the Brazilian semiarid region. **Forest Ecology and Management**, v. 271, p. 115-123, 2012.

MACHADO, S. do A.; FIGURA, M. A.; SILVA, L. C. R. da; TÊO, S. J.; STOLLE, L.; URBANO, E. Modelagem volumétrica para Bracatinga (*Mimosa scabrella*) em povoamentos da Região Metropolitana de Curitiba. **Pesquisa Florestal Brasileira**, n. 56, p.17-29, 2008

MEHTÄTALO, L; MALTAMO, M; KANGAS, A. The Use of Quantile Trees in the Prediction of the Diameter Distribution of a Stand. **Silva Fennica**, v. 40, n. 3, 2006.

ÖZÇELİK, R.; DIAMANTAPOULOU, M. J.; BROOKS, J. R.; WIANT J. R. H. V. Estimating tree bole volume using artificial neural network models for four species in Turkey. **Journal of Environmental Managing**, v. 91, n. 3, p. 742-753, 2010.

REZENDE, A. V.; VALE, A. T.; SANQUETTA, C. R.; FIGUEIREDO FILHO, A.; FELFILI, J. M. Comparação de modelos matemáticos para estimativa do volume, biomassa e estoque de carbono da vegetação lenhosa de um cerrado *sensu stricto* em Brasília, DF. **Scientia Forestalis**, n. 71, p. 65-76, 2006.

RStudio Team (2016). RStudio: Integrated Development for R. RStudio, Inc., Boston, MA. Disponível em: <<http://www.rstudio.com/>>. Acesso em: 25 jan. 2016.

RUFINI, A. L.; SCOLFORO, J. R. S.; OLIVEIRA, A. D. de; MELLO, J. M. de. Equações volumétricas para o cerrado *Sensu Strictu* em Minas Gerais. **Cerne**, v. 16, n. 1, p. 1-11, 2010.

SCOLFORO, J. R. S.; SILVA, S. T. O conceito de “floresta balanceada de Meyer” como opção para intervenção em cerrado *sensu stricto*. In: CONGRESSO FLORESTAL BRASILEIRO, 7, 1993, Curitiba. **Anais...** Curitiba: SBS, 1993. v. 1, p. 378-381.

SERINOLI, C. **Planejamentos experimentais em modelos de regressão linear**. São Paulo-SP: IME, 2009, 95 p. Dissertação (Mestrado em Ciências) – Instituto de Matemática e Estatística.

SOUZA, A. L. de; SOARES, C. P. B. **Florestas nativas: estrutura dinâmica e manejo.** UFV, Viçosa, 2013, 322 p.

STANLEY, K. O. **Efficient Evolution of Neural Networks through Complexification.** Austin-TX: UT, 2004, 165 p. Tesis (Doctor of Philosophy) – The University of Texas.

STANLEY, K. O.; MIIKKULAINEN, R. Competitive Coevolution through Evolutionary Complexification. **Journal of Artificial Intelligence Research**, v. 21, p. 63-100, 2004.

STANLEY, K. O.; MIIKKULAINEN, R. Evolving Neural Networks through augmenting Topologies. **Evolutionary Computation**, v. 10, n. 2, p. 99-127, 2002.



## CONCLUSÕES GERAIS

Atualmente, os desafios na área computacional concentram esforços em aprimorar o desempenho dos algoritmos já elaborados como também em obter a melhor configuração de rede que evite o processo de memorização dos dados. Entretanto, no campo florestal, o caráter empírico das RNA convencionais ainda possui uma lacuna no conhecimento quanto ao modo de ação desses algoritmos para cada situação, o que torna o processo cada vez mais moroso, bem como longe de tornar-se padronizado. Nesse sentido, poucos trabalhos foram eficazes em determinar a melhor estrutura de rede e baseiam-se exclusivamente na validação da técnica em comparação às técnicas já consagradas na literatura florestal.

Este aspecto, apesar de importante, tem conseguido trazer à tona informações majoritariamente acerca das espécies plantadas de interesse econômico e de maior evidência no país, com poucas experimentações para o manejo de florestas nativas. E, mesmo assim, parâmetros que fidelizem padrões de comportamento das redes para cada situação apresentada ainda são escassos e com pouco enfoque na parametrização das redes. Por fim, é importante que um ponto de partida seja gerado para a sumarização das informações e avanço, no sentido de buscar a melhor configuração de rede em florestas com alta heterogeneidade.

Assim, os algoritmos aqui testados, foram eficientes em reconhecer os padrões da floresta estudada. Apesar do algoritmo *Resilient propagation* ser a atualização do *backpropagation*, com a premissa de resolver supostos problemas de codificação e vias de busca do mínimo global, foi o algoritmo que obteve as piores estatísticas se comparado às redes treinadas com os algoritmos *Skip-layer*, NEAT e redes do tipo RBF. Contudo, foi um dos algoritmos que apresentou melhores distribuições nos histogramas dos erros percentuais, em conjunto com as redes obtidas pelo *Skip-layer connections*, e o único que não conseguiu convergir após treiná-lo com as funções de ativação Sigmoid e Softmax.

Os resultados evidenciam a importância da análise “algoritmo + variável de entrada + função de ativação”, em que todas influenciam no aspecto de desempenho da rede. Nesse sentido, a variável *das*, utilizada isoladamente, não foi eficiente em nenhuma das configurações testadas. Porém, em conjunto com as

variáveis tradicionais  $dap$  e  $Ht$ , auxiliou na diminuição do erro nas estimativas e nas tendenciosidades dos gráficos do erro residual.

Outro aspecto importante foi definir o momento de parada da rede. Assim, as redes MLP obtidas pelo *Resilient propagation*, o *Skip-layer*, apresentaram número de ciclos similares, evidenciando estabilidade a partir de 100 ciclos, tanto para treinamento quanto para validação. Já as redes treinadas pelo NEAT, seu comportamento foi diferenciado e possuindo um ponto satisfatório na marca de 1.000 ciclos, podendo ou não obter perda de precisão após este ponto devido ao seu aspecto probabilístico. Nas redes do tipo RBF, o erro passou a ser estabilizado a partir de 500 ciclos.

Através dos erros médios absolutos, observou-se que o número de indivíduos iniciais e sua densidade influenciam no caráter evolutivo das redes NEAT. Por este ângulo, redes com maiores indivíduos e menos densas são mais favoráveis à obtenção de melhores estimativas e performances. Portanto, os melhores resultados podem ser adquiridos com redes que possuem 800 indivíduos e 0,1 de densidade inicial, sendo recomendado o uso de 1.000 indivíduos para a mesma densidade. O algoritmo foi o que obteve os melhores parâmetros de rede e com menos viés nos gráficos.

Em comparação aos dois tipos de redes, as RBF obtiveram boa performance em relação às redes MLP, com resultados equivalentes. Este aspecto se contrapõe ao que já foi evidenciado na literatura em que as RBF apresentaram resultados bem inferiores às MLP.

Tanto os modelos quanto as RNA foram eficazes no sentido de generalização dos dados. O modelo de Schumacher e Hall (log) foi o que evidenciou menores tendenciosidades, apesar das estatísticas desfavoráveis. Entretanto, o algoritmo NEAT possuiu uma maior dinâmica em captar a alta heterogeneidade dos dados apresentados e desenvolver o melhor caminho para a resolução do problema, o que reforça a vantagem em utilizar algoritmos evolutivos nessas circunstâncias, por também isentarem a necessidade do caráter empírico característico de outros tipos de algoritmos.

## **APÉNDICE**

**APÊNDICE A – Lista das espécies cubadas da comunidade lenhosa identificadas por família botânica e, seus respectivos volumes comerciais, na Floresta Nacional Contendas do Sincorá-BA. “*Continua*”**

Família	Nome científico	Nº Ind.	Vol. Total (m³)	Média	Min. (Vol.)	Máx. (Vol.)
Apocynaceae	<i>Aspidosperma parvifolium</i> A. DC.	10	0,33941	0,03394	0,01036	0,09673
	<i>Aspidosperma</i> sp.	15	0,31790	0,02119	0,00379	0,12458
Bignoniaceae	<i>Tabebuia roseoalba</i> (Ridl.) Sandwith	8	0,23679	0,02960	0,00354	0,15486
Boraginaceae	<i>Cordia</i> sp.	1	0,00693	0,00693	0,00693	0,00693
	<i>Cordia trichotoma</i> (Vell.) Arráb. ex Steud.	11	0,30076	0,02734	0,00504	0,12320
	<i>Patagonula americana</i> L.	1	0,01185	0,01185	0,01185	0,01185
	<i>Patagonula bahiensis</i> Moric.	17	0,27763	0,01633	0,00912	0,04488
Burseraceae	<i>Commiphora leptophloeos</i> (Mart.) J.B. Gillett	48	6,12877	0,12768	0,00627	1,07307
Celastraceae	<i>Maytenus rigida</i> Mart.	1	0,00466	0,00466	0,00466	0,00466
Combretaceae	<i>Combretum monetaria</i> Mart.	8	0,21031	0,02629	0,00815	0,03947
Euphorbiaceae	<i>Alchornea triplinervia</i> (Spreng.) Müll Arg.	1	0,01711	0,01711	0,01711	0,01711
	<i>Cnidoscolus vitifolius</i> (Mill.) Pohl	3	0,04491	0,01497	0,01431	0,01563
	<i>Croton argyrophyllus</i> Kunth	7	0,84118	0,12017	0,11735	0,12251
	<i>Croton piptocalyx</i> Müll. Arg.	4	0,11401	0,02850	0,00935	0,06303
	<i>Croton</i> sp.	1	0,05630	0,05630	0,05630	0,05630
	<i>Jatropha mollissima</i> (Pohl) Baill.	11	0,12454	0,01132	0,00539	0,02639
	<i>Jatropha urens</i> Kunth	1	0,06255	0,06255	0,06255	0,06255
	<i>Manihot carthaginensis</i> (Jacq.) Müll. Arg.	1	0,00614	0,00614	0,00614	0,00614
	<i>Maprounea guianensis</i> Aubl.	2	0,05545	0,02772	0,01291	0,04254
	<i>Sapium</i> sp.	4	0,09386	0,02347	0,01074	0,03539
	<i>Sebastiania brasiliensis</i> Spreng.	9	0,19019	0,02113	0,00522	0,05097
Fabaceae	<i>Chloroleucon foliolosum</i> (Benth.) G.P. Lewis	8	0,09187	0,01148	0,00584	0,01843
	<i>Coursetia rostrata</i> Benth.	1	0,01844	0,01844	0,01844	0,01844
	<i>Mimosa ophthalmocentra</i> Mart. ex Benth.	4	0,06697	0,01674	0,00606	0,04364
Lamiaceae	<i>Vitex</i> sp.	1	0,00986	0,00986	0,00986	0,00986
Malvaceae	<i>Pseudobombax simplicifolium</i> A. Robyns	27	3,23816	0,11993	0,00730	0,75007
Polygonaceae	<i>Coccoloba alnifolia</i> Casar.	3	0,29922	0,09974	0,07969	0,11716
	<i>Coccoloba bullata</i> R.A. Howard	4	0,13085	0,03271	0,01517	0,06034
Rutaceae	<i>Esenbeckia febrifuga</i> (A. St.-Hil.) A. Juss. ex Mart.	1	0,02153	0,02153	0,02153	0,02153
	<i>Morfoespécie 1</i>	15	0,54176	0,03612	0,00458	0,23472
	<i>Morfoespécie 2</i>	1	0,04011	0,04011	0,04011	0,04011
	<i>Morfoespécie 3</i>	5	0,13270	0,02654	0,00900	0,04564
	<i>Morfoespécie 4</i>	1	0,03860	0,03860	0,03860	0,03860
	<i>Morfoespécie 5</i>	1	0,03865	0,03865	0,03865	0,03865
	<i>Morfoespécie 6</i>	3	0,07651	0,02550	0,02071	0,03500
	<i>Morfoespécie 7</i>	1	0,01746	0,01746	0,01746	0,01746
	<i>Morfoespécie 8</i>	1	0,00773	0,00773	0,00773	0,00773
	<i>Morfoespécie 9</i>	2	0,11156	0,05578	0,02791	0,08365
	<i>Morfoespécie 10</i>	1	0,02633	0,02633	0,02633	0,02633
	<i>Morfoespécie 11</i>	1	0,11270	0,11270	0,11270	0,11270

**APÊNDICE A – Lista das espécies cubadas da comunidade lenhosa identificadas por família botânica e, seus respectivos volumes comerciais, na Floresta Nacional Contendas do Sincorá-BA. “Continuação”**

<b>Família</b>	<b>Nome científico</b>	<b>Nº Ind.</b>	<b>Vol. Total (m³)</b>	<b>Média</b>	<b>Min. (Vol.)</b>	<b>Máx. (Vol.)</b>
	<i>Morfoespécie 12</i>	1	0,00733	0,00733	0,00733	0,00733
	<i>Morfoespécie 13</i>	1	0,01842	0,01842	0,01842	0,01842
	<i>Morfoespécie 14</i>	1	0,04133	0,04133	0,04133	0,04133
	<i>Morfoespécie 15</i>	2	0,03079	0,01540	0,01059	0,02020
	<i>Morfoespécie 16</i>	1	0,02960	0,02960	0,02960	0,02960
	<i>Morfoespécie 17</i>	1	0,02774	0,02774	0,02774	0,02774
	<i>Morfoespécie 18</i>	1	0,02664	0,02664	0,02664	0,02664
	<i>Morfoespécie 19</i>	1	0,11859	0,11859	0,11859	0,11859
	<i>Morfoespécie 20</i>	1	0,11621	0,11621	0,11621	0,11621
	<i>Morfoespécie 21</i>	1	0,00359	0,00359	0,00359	0,00359
	<i>Morfoespécie 22</i>	1	0,00680	0,00680	0,00680	0,00680
	<i>Morfoespécie 23</i>	1	0,00535	0,00535	0,00535	0,00535
	<i>Morfoespécie 24</i>	1	0,00647	0,00647	0,00647	0,00647
	<i>Morfoespécie 25</i>	1	0,00674	0,00674	0,00674	0,00674
	<i>Morfoespécie 26</i>	1	0,00806	0,00806	0,00806	0,00806
	<i>Morfoespécie 27</i>	1	0,00713	0,00713	0,00713	0,00713
	<i>Morfoespécie 28</i>	1	0,01255	0,01255	0,01255	0,01255
	<i>Morfoespécie 29</i>	1	0,01150	0,01150	0,01150	0,01150
	<i>Morfoespécie 30</i>	1	0,00885	0,00885	0,00885	0,00885
	<i>Morfoespécie 31</i>	1	0,00852	0,00852	0,00852	0,00852
	<i>Morfoespécie 32</i>	1	0,01164	0,01164	0,01164	0,01164
	<i>Morfoespécie 33</i>	1	0,01318	0,01318	0,01318	0,01318
	<i>Morfoespécie 34</i>	1	0,02741	0,02741	0,02741	0,02741
	<i>Morfoespécie 35</i>	1	0,01757	0,01757	0,01757	0,01757
	<i>Morfoespécie 36</i>	1	0,02896	0,02896	0,02896	0,02896
	<i>Morfoespécie 37</i>	1	0,02901	0,02901	0,02901	0,02901
	<i>Morfoespécie 38</i>	1	0,01924	0,01924	0,01924	0,01924
	<i>Morfoespécie 39</i>	1	0,02057	0,02057	0,02057	0,02057
	<i>Morfoespécie 40</i>	1	0,02065	0,02065	0,02065	0,02065
	<i>Morfoespécie 41</i>	1	0,01464	0,01464	0,01464	0,01464
	<i>Morfoespécie 42</i>	1	0,01691	0,01691	0,01691	0,01691
	<i>Morfoespécie 43</i>	1	0,01798	0,01798	0,01798	0,01798
	<i>Morfoespécie 44</i>	1	0,02422	0,02422	0,02422	0,02422
	<i>Morfoespécie 45</i>	1	0,01948	0,01948	0,01948	0,01948
	<i>Morfoespécie 46</i>	1	0,03128	0,03128	0,03128	0,03128
	<i>Morfoespécie 47</i>	1	0,04712	0,04712	0,04712	0,04712
	<i>Morfoespécie 48</i>	1	0,04681	0,04681	0,04681	0,04681
	<i>Morfoespécie 49</i>	1	0,03184	0,03184	0,03184	0,03184
	<i>Morfoespécie 50</i>	1	0,02996	0,02996	0,02996	0,02996
	<i>Morfoespécie 51</i>	1	0,03854	0,03854	0,03854	0,03854
	<i>Morfoespécie 52</i>	1	0,04524	0,04524	0,04524	0,04524
	<i>Morfoespécie 53</i>	1	0,05725	0,05725	0,05725	0,05725

**APÊNDICE A** – Lista das espécies cubadas da comunidade lenhosa identificadas por família botânica e, seus respectivos volumes comerciais, na Floresta Nacional Contendas do Sincorá-BA. “*Continuação*”

<b>Família</b>	<b>Nome científico</b>	<b>Nº Ind.</b>	<b>Vol. Total (m³)</b>	<b>Média</b>	<b>Min. (Vol.)</b>	<b>Máx. (Vol.)</b>
	<i>Morfoespécie 54</i>	1	0,05668	0,05668	0,05668	0,05668
	<i>Morfoespécie 55</i>	1	0,09257	0,09257	0,09257	0,09257
	<i>Morfoespécie 56</i>	1	0,08384	0,08384	0,08384	0,08384
	<i>Morfoespécie 57</i>	1	0,17579	0,17579	0,17579	0,17579
	<i>Morfoespécie 58</i>	1	0,22262	0,22262	0,22262	0,22262
	<i>Morfoespécie 59</i>	1	0,23403	0,23403	0,23403	0,23403
	<i>Morfoespécie 60</i>	1	0,22279	0,22279	0,22279	0,22279
	<i>Morfoespécie 61</i>	1	0,22145	0,22145	0,22145	0,22145
	<i>Morfoespécie 62</i>	1	0,26815	0,26815	0,26815	0,26815
	<i>Morfoespécie 63</i>	3	0,07742	0,02581	0,00796	0,03571
	<b>TOTAL</b>	<b>300</b>	<b>17,22926</b>	-	-	-