

**UNIVERSIDADE FEDERAL DOS VALES DO JEQUITINHONHA E MUCURI –
UFVJM**

Mestrado em Ciência Florestal

Paula Ventura da Silva

**EMPREGO DE REDES NEURAS ARTIFICIAIS COM *SKIP-LAYER*
CONNECTIONS NA MENSURAÇÃO FLORESTAL**

DIAMANTINA – MG
2015

Paula Ventura da Silva

EMPREGO DE REDES NEURAIAS ARTIFICIAIS COM *SKIP-LAYER CONNECTIONS* NA MENSURAÇÃO FLORESTAL

Dissertação apresentada à Universidade Federal dos Vales do Jequitinhonha e Mucuri, como parte das exigências do Programa de Pós-Graduação em Ciência Florestal, área de concentração em Silvicultura e Manejo Florestal, para obtenção do título de Mestre.

Orientadora: Mayra Luiza M. da Silva Binoti

DIAMANTINA – MG
2015

Ficha Catalográfica – Serviço de Bibliotecas/UFVJM
Bibliotecário Anderson César de Oliveira Silva, CRB6 – 2618.

S586e	<p>Silva, Paula Ventura da Emprego de Redes Neurais Artificiais com Skip-layer connections na mensuração florestal / Paula Ventura da Silva. – Diamantina, 2016. 56 p. : il.</p> <p>Orientador: Mayra Luiza Marques da Silva Binoti</p> <p>Dissertação (Mestrado – Programa de Pós-Graduação em Ciência Florestal) - Faculdade de Ciências Agrárias, Universidade Federal dos Vales do Jequitinhonha e Mucuri.</p> <p>1. Mensuração florestal. 2. Redes Neurais Artificiais. 3. Eucalipto. I. Título II. Universidade Federal dos Vales do Jequitinhonha e Mucuri.</p>
-------	--

CDD 634.9

Elaborado com os dados fornecidos pelo(a) autor(a).

Paula Ventura da Silva

EMPREGO DE REDES NEURAIS ARTIFICIAIS COM *SKIP-LAYER CONNECTIONS* NA MENSURAÇÃO FLORESTAL

Dissertação apresentada à Universidade Federal dos Vales do Jequitinhonha e Mucuri, como parte das exigências do Programa de Pós-Graduação em Ciência Florestal, área de concentração em Silvicultura e Manejo Florestal, para obtenção do título de Mestre.

Orientadora: Mayra Luiza M. da Silva Binoti

Data da aprovação: 11/12/2015

Prof^a Dr^a Mayra Luiza Marques da Silva Binoti - Orientadora
Universidade Federal dos Vales do Jequitinhonha e Mucuri – UFVJM – PRESIDENTE

Prof. Dr. Helio Garcia Leite
Universidade Federal de Viçosa – UFV

Dr. Antonilmar Araújo Lopes da Silva
Cenibra

Prof. Dr. José Marinaldo Gleriani
Universidade Federal de Viçosa – UFV

DIAMANTINA – MG
2015

*Aos meus pais, Paulo e Eliane, por serem meus
exemplos de caráter, dignidade e perseverança.*

Vocês são meu maior orgulho!

AGRADECIMENTOS

Agradeço a Deus, por me dar força e fé durante todo este percurso e por todas as bênçãos.

À Universidade Federal dos Vales do Jequitinhonha e Mucuri (UFVJM) e ao Departamento de Engenharia Florestal, pela oportunidade de desenvolver este trabalho.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pelo apoio financeiro.

À professora Mayra Luiza Marques da Silva Binoti, pela orientação, pela dedicação, pelos conhecimentos compartilhados e por toda paciência.

Ao professor Helio Garcia Leite, pela constante e valiosa ajuda, pelo apoio, pela amizade e por aceitar fazer parte da banca.

Ao professor José Marinaldo Gleriani e ao Antonilmar Araújo Lopes da Silva, por aceitarem fazer parte da banca e pelas valiosas sugestões.

Ao Daniel Binoti, pela preciosa ajuda e pela enorme paciência e apoio.

Aos grandes amores da minha vida, meus pais, Paulo Afonso e Eliane, por estarem sempre ao meu lado, apoiando, incentivando e vivenciando comigo todas as fases da minha vida. O amor de vocês me dá força e me faz querer ser sempre uma pessoa melhor. Agradeço também por realizarem a editoração e a revisão linguística da minha dissertação. É uma honra ter a participação direta de vocês em mais esta etapa da minha vida.

Às minhas irmãs, Carolina e Patrícia, pelo amor incondicional e pela constante presença na minha vida. Ao Bernardo, meu sobrinho, por trazer luz à minha vida.

Ao meu amor, Vitor, por toda paciência, calma e carinho durante esta etapa, pelo amor, pela dedicação e pelo incentivo constante.

A todos os amigos adquiridos no mestrado, por tornarem tudo mais fácil e divertido, em especial a Lud, Marcelino, Kaio e Karyn.

Aos meus anjos, Ana Carolina e Tarço, por não me deixarem desanimar e por toda preciosa ajuda.

À Dominic e Marcela, grandes amigas e irmãs que escolhi, por estarem sempre comigo, apesar da distância. Às queridas amigas de Diamantina, em especial à Josi, Sory e Ana, por terem sido as melhores companheiras e por terem se tornado família.

A todos que, direta ou indiretamente, contribuíram para a realização deste trabalho: Muito obrigada!

BIOGRAFIA

PAULA VENTURA DA SILVA é filha de Paulo Afonso da Silva e de Eliane Ventura da Silva, nasceu em 28 de março de 1989, em Visconde do Rio Branco, Minas Gerais.

Em agosto de 2008, iniciou o curso de graduação em Engenharia Florestal na Universidade Federal de Viçosa, Viçosa, Minas Gerais.

De agosto de 2011 a agosto de 2012, foi bolsista de iniciação científica pelo PIBIC/CNPq, sob a orientação do professor Helio Garcia Leite.

Em março de 2014, formou-se e em abril do mesmo ano ingressou no mestrado na Universidade Federal dos Vales do Jequitinhonha e Mucuri, Diamantina, Minas Gerais, submetendo-se à defesa de dissertação em 11 de dezembro de 2015.

RESUMO

SILVA, Paula Ventura da, M.Sc., **Emprego de redes neurais artificiais com *Skip-Layer Connections* na mensuração florestal**. 2015. 46 f. Dissertação (Mestrado em Ciência Florestal) – Universidade Federal dos Vales do Jequitinhonha e Mucuri, Diamantina, 2015.

O objetivo principal deste estudo foi avaliar a aplicação de Redes Neurais Artificiais (RNA) utilizando a técnica *Skip-layer connections*, com e sem recorrência, para estimação do volume individual e da altura total de árvores de eucalipto. Os objetivos específicos foram testar e avaliar as reduções no tamanho da base de dados do conjunto de ajuste (treinamento) para estimação dessas variáveis. Os dados utilizados foram provenientes de árvores abatidas para cubagem (estimação do volume individual) e de medições de parcelas permanentes de inventários florestais contínuos (estimação da altura total), em área de povoamentos de eucalipto localizados no sul da Bahia, Brasil. Foram treinadas redes do tipo *Multilayer Perceptron* (MLP), utilizando a função de ativação logística nas camadas intermediária e de saída e oito neurônios na camada oculta. O número de neurônios na camada de entrada variou conforme o número e o tipo de variável (qualitativa ou quantitativa) em cada estudo. Os critérios de parada foram o erro médio quadrático de 0,0001 ou 3.000 ciclos (épocas). Em seguida, as RNA selecionadas foram aplicadas em parte dos dados separados, para generalização (validação). O *software* utilizado para o treinamento e a generalização das RNA foi o *NeuroForest 3.3*. Para comparação dos resultados obtidos pelas RNA, foram ajustados os modelos tradicionais de regressão tanto para volume, quanto para altura, e também foram treinadas e aplicadas RNA usando o algoritmo *Resilient Propagation*, comumente utilizado em aplicações da mensuração florestal. A avaliação dos resultados gerados pelas RNA e pelos modelos de regressão foi feita por meio do coeficiente de correlação entre os valores observados e estimados, de gráficos de dispersão e de histogramas de frequência percentual dos erros percentuais. As Redes Neurais Artificiais utilizando *Skip-layer connections* apresentaram resultados satisfatórios para estimação de volume e de altura de árvores de eucalipto, o que evidencia a possibilidade de aplicar a técnica em mensuração e manejo florestal e uma expressiva redução das bases de dados para treinamento das RNA.

Palavras-chave: Mensuração florestal; Redes Neurais Artificiais; Eucalipto.

ABSTRACT

SILVA, Paula Ventura da, M.Sc. **Artificial neural networks with skip-layer connections in forest measurement**. 2015. 46 f. Dissertation (Master in Forest Science) – Universidade Federal dos Vales do Jequitinhonha e Mucuri, Diamantina, 2015.

The aim of this study was to evaluate the application of Artificial Neural Networks (ANN) using the Skip-layer connections technique, with and without recurrence, to estimate the individual volume and total eucalyptus trees height. Its specific objectives were to test and evaluate reduction in the size of the adjustment assembly database (training) for estimating these variables. The data came from trees felled for scaling (estimation of individual volume) and measurements of permanent plots of continuous forest inventories (estimation of the total height), in eucalypt plantation area located in the south of Bahia, Brazil. Multilayer Perceptron (MLP) network type, using the logistic activation function in the intermediate and output layers and eight neurons in the hidden layer, were trained. The neurons number in the input layer varied according to the number and type of the variable (qualitative or quantitative) in each study. The stopping criteria were the root mean square error 0.0001 or 3,000 cycles (seasons). The software used for the RNA training and generalization was the NeuroForest 3.3. To compare the results obtained by RNA, traditional regression models were set for both the volume and the height, as well as RNA were trained and applied using the Resilient Propagation algorithm, commonly used in forest measurement applications. The evaluation of the results generated by the RNA and by the regression models was made via the correlation coefficient between observed and estimated values, scatter plots and histograms percentage frequency of the percentage errors. Artificial Neural Networks using Skip-layer connections showed satisfactory results for the estimation of volume and eucalyptus trees height, demonstrating the possibility of applying the technique in measuring and forest management and a significant reduction of databases for RNA training.

Keywords: Forest Mensuration; Artificial Neural Networks; Eucalyptus.

LISTA DE FIGURAS

Página

Capítulo 1

- Figura 1 – MLP com três neurônios de entrada, dois neurônios ocultos e um neurônio de saída, com três *skip-layer connections* 17
- Figura 2 – (a) Gráfico de dispersão da relação volumes estimados (m^3) pelo ajuste do modelo de Schumacher e Hall (eixo y) e volumes observados (m^3) (eixo x); (b) gráfico de dispersão dos erros percentuais dos volumes totais estimados (m^3) pelo ajuste do modelo de Schumacher e Hall (eixo y), em função dos volumes observados (m^3) (eixo x); e (c) histograma de frequência percentual (eixo y) dos erros percentuais (eixo x) das estimativas de volume obtido pelo ajuste do modelo de Schumacher e Hall 19
- Figura 3 – Gráficos de dispersão da relação volumes estimados (m^3) pelas RNA (eixo y) para o conjunto de generalização e os volumes observados (m^3) (eixo x) 21
- Figura 4 – Gráficos de dispersão dos erros percentuais dos volumes estimados pelas RNA (eixo y) para o conjunto de generalização e volumes observados (m^3) (eixo x), em função dos volumes observados (m^3) (eixo x) 24
- Figura 5 – Histogramas de frequência percentual (eixo y) dos erros percentuais (eixo x) das estimativas das RNA para volume para o conjunto de generalização 27

Capítulo 2

- Figura 1 – MLP com três neurônios de entrada, dois neurônios ocultos e um neurônio de saída, com três *skip-layer connections* 39
- Figura 2 – (a) Gráfico de dispersão da relação alturas estimadas (m) pelo ajuste do modelo hipsométrico (eixo y) e alturas observadas (m) (eixo x); (b) gráfico de dispersão dos erros percentuais das alturas totais estimadas (m) pelo ajuste do modelo hipsométrico (eixo y), em função das alturas totais observadas (m) (eixo x); e (c) histograma de frequência percentual (eixo y) dos erros percentuais (eixo x) das estimativas de altura obtido pelo ajuste do modelo hipsométrico 41
- Figura 3 – Gráficos de dispersão da relação alturas estimadas (m) pelas RNA (eixo y) para o conjunto de generalização e alturas observadas (m) (eixo x) 43
- Figura 4 – Gráficos de dispersão dos erros percentuais das alturas totais estimadas (m) pelas RNA (eixo y) para o conjunto de generalização, em função das alturas totais observadas (m) (eixo x) 46
- Figura 5 – Histogramas de frequência percentual (eixo y) dos erros percentuais (eixo x) das estimativas das RNA para altura total para o conjunto de generalização 49

LISTA DE TABELAS

Página

Capítulo 1

Tabela 1 – Análise descritiva dos dados utilizados.....	15
Tabela 2 – Estatísticas para dados de treinamento e generalização de cada alternativa de estimação do volume total.....	20

Capítulo 2

Tabela 1 – Estatísticas descritivas para as variáveis quantitativas observadas	37
Tabela 2 – Estatísticas para dados de treinamento e generalização de cada alternativa de estimação da altura total	42

SUMÁRIO

	Página
INTRODUÇÃO	10
REFERÊNCIAS BIBLIOGRÁFICAS	12
CAPITULO 1	13
REDES NEURAI ARTIFICIAIS COM <i>SKIP-LAYER CONNECTIONS</i> PARA ESTIMATIVA DE VOLUME DE ÁRVORES INDIVIDUAIS	13
1 INTRODUÇÃO	13
2 MATERIAL E MÉTODOS	15
2.1 Descrição dos dados.....	15
2.2 Redes Neurais Artificiais	15
2.2.1 <i>Skip-Layer Connections</i>	16
2.3 Modelo volumétrico.....	17
2.4 Avaliações das RNA.....	17
3 RESULTADOS.....	19
4 DISCUSSÃO.....	30
5 CONCLUSÃO	32
6 REFERÊNCIAS.....	33
CAPÍTULO 2	35
REDES NEURAI ARTIFICIAIS COM <i>SKIP-LAYER CONNECTIONS</i> PARA ESTIMATIVA DA ALTURA DE POVOAMENTOS DE EUCALIPTO.....	35
1. INTRODUÇÃO	35
2 MATERIAL E MÉTODOS	37
2.1 Dados.....	37
2.2 Alternativas de estimação da altura total	37
2.3 Avaliação das estimativas.....	39
3. RESULTADOS.....	41
4 DISCUSSÃO.....	52
5 CONCLUSÕES.....	53
6 REFERÊNCIAS.....	54

INTRODUÇÃO

Em virtude das variações de clima e solo e da grande extensão de território, o Brasil apresenta grande potencial para produção florestal. Dentre as espécies exóticas introduzidas no País, o eucalipto foi uma das que melhor se adaptou. Inicialmente o eucalipto foi introduzido para atender à produção de lenha, e hoje é utilizado para produção de celulose, madeira serrada, carvão e de produtos não madeireiros. O cultivo desse gênero já se estende por 5,5 milhões de hectares pelo País, e grande parte dessa área está localizada no Estado de Minas Gerais (TRUGILHO *et al.*, 2001; IBÁ, 2015).

Os empreendimentos florestais que possuem o cultivo de eucalipto como base, independentemente de o objetivo principal ser econômico, ambiental ou social, exigem o planejamento de suas ações. Portanto, é necessário um planejamento florestal consistente, que permita a obtenção de informações acerca do futuro do empreendimento, bem como de sua viabilidade. Este deve abranger todas as atividades a serem realizadas, além de garantir o correto uso dos recursos físicos e financeiros, distribuídos ao longo de um período (VOLPI, 1997).

Para que se faça o gerenciamento da floresta e o planejamento das operações ao longo dos anos, é necessário conhecer o comportamento de determinadas características da floresta, por exemplo, sua produtividade e o estoque de madeira presente e futuro. Como, na prática, a altura de todas as árvores e o volume total de uma floresta são inviáveis de se obter de forma direta, são utilizadas ferramentas de mensuração e modelos de regressão para estimar, com certo grau de exatidão aceitável, o valor dessas variáveis. Essas ferramentas compõem o inventário florestal, que é a base para a tomada de decisões de grande parte das operações florestais (BIENERT *et al.*, 2006; CAMPOS; LEITE, 2013).

As Redes Neurais Artificiais (RNA) tem sido amplamente utilizadas na Ciência Florestal como método alternativo aos modelos de regressão, para estimação de volume (DIAMANTOPOULOU, 2005; GÖRGENS, 2006; SILVA *et al.*, 2009; DIAMANTOPOULOU; MILIOS, 2010; LEITE *et al.*, 2010; SILVA, 2010; BINOTI, 2012), altura de árvores (BINOTI, 2012; DIAMANTOPOULOU, 2012; ÖZÇELİK *et al.*, 2013), afilamento do fuste (LEITE *et al.*, 2010, MARTINS, 2015), prognose da produção florestal (BINOTI, 2012; ALCÂNTARA, 2015), dentre outros.

As RNA são uma simplificação matemática das redes de neurônios encontradas no cérebro humano. Podem ser definidas como um sistema de processamento de informação massiva e paralelamente distribuído que simula o funcionamento de neurônios no cérebro

humano, ao computar e ponderar sinais de entrada e processá-los por meio de funções matemáticas, gerando um novo sinal de saída (HAYKIN, 2001; BRAGA, 2007).

Apesar da grande atratividade, a utilização de redes depende da definição de sua arquitetura e de sua topologia, ou seja, do número de camadas, do número de neurônios em cada camada e dos tipos de conexões, uma vez que esses parâmetros restringem o tipo de problema que pode ser solucionado por elas (BRAGA, 2007). Essas configurações têm sido testadas aleatoriamente até que os resultados apresentem erros aceitáveis, o que exige maior tempo e conhecimento do usuário.

A técnica *Skip-layer connections* permite que os neurônios da camada de entrada se conectem diretamente ao(s) neurônio(s) da camada de saída, o que torna o ajuste mais flexível, permitindo a obtenção de estimativas mais exatas (RIPLEY, 1996; VELTEN, 2009). Os estudos de viabilidade dessa técnica para as aplicações na mensuração e no manejo florestal têm sido muito promissores.

Esta dissertação foi dividida em dois capítulos. No capítulo 1 foi avaliada a aplicação de RNA utilizando a técnica *Skip-layer connections*, com e sem recorrência, para estimação de volumes de árvores individuais de eucalipto. Também foram testadas reduções nas porcentagens de árvores cubadas por estrato. No capítulo 2, a mesma metodologia foi testada para estimação de alturas totais de árvores de eucalipto.

REFERÊNCIAS BIBLIOGRÁFICAS

- ALCÂNTARA, A. E. M de. **Redes neurais artificiais para prognose do crescimento e da produção de povoamentos de eucalipto em Minas Gerais**. 2015. 43 f. Tese (Doutorado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa, MG, 2015.
- BRAGA, A. P.; LUDEMIR, T. B.; CARVALHO, A. P. L. F. de. **Redes neurais artificiais: Teoria e aplicações**. 2. ed. Rio de Janeiro: LTC, 2007.
- BIENERT, A.; MAAS, H. G.; SCHELLER, S. Analysis of the information content of terrestrial laser scanner point clouds for the automatic determination of forest inventory parameters. In: WORKSHOP ON 3D REMOTE SENSING IN FOREST, 14-15. Vienna, 2006.
- BINOTI, M. L. M. S. **Emprego de redes neurais artificiais em mensuração e manejo florestal**. 2012. 130 f. Tese (Doutorado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa, MG, 2012
- CAMPOS, J. C. C.; LEITE, H. G. **Mensuração florestal: perguntas e respostas**. 4. ed. atual. ampl. Viçosa: Ed. UFV, 2013. 605 p.
- DIAMANTOPOULOU, M. Assessing a reliable modeling approach of features of trees through neural network models for sustainable forests. **Sustainable computing: Informatics and Systems**, v. 2, p. 190-197, 2012.
- HAYKIN, S. **Redes neurais: princípios e prática**. Porto Alegre: Bookman, 2001. 900 p.
- IBÁ. Indústria Brasileira de Árvores. Ano Base 2015 / IBÁ. 78 p. Brasília, 2015.
- LEITE, H. G.; SILVA, M. L. M.; BINOTI, D. H. B.; FARDIN, L.; TAKIZAWA, F. H. Estimation of inside-bark diameter and heartwood diameter for *Tectona grandis* Linn. trees using artificial neural networks. **European Journal of Forest Research**, v. 130, n.2, p.263-269, 2010.
- MARTINS, E. dos R. **Configuração de redes neurais artificiais na mensuração florestal**. 2015. 62 f. Dissertação (Mestrado em Ciência Florestal) – Universidade Federal dos Vales do Jequitinhonha e Mucuri, Diamantina, MG, 2015.
- PÉLLICO NETO, S.; BRENA, D. A. **Inventário florestal**. Curitiba: editado pelos autores, 1997. 316 p.
- RIPLEY, B. D. **Pattern recognition and neural networks**. 1 ed., Cambridge: Cambridge University Press, p. 144, 172, 157, 1996.
- VELTEN, K. **Mathematical modeling and simulation: Introduction for Scientists and Engineers**. Weinheim: Wiley-VCH, 2009. 364 p.
- VOLPI, N. M P. **O impacto de perturbações estocásticas em um modelo de planejamento florestal**. Curitiba, PR: UFPR, 1997. Tese de Doutorado. Universidade Federal do Paraná, 1997.

CAPITULO 1

REDES NEURAIAS ARTIFICIAIS COM *SKIP-LAYER CONNECTIONS* PARA ESTIMATIVA DE VOLUME DE ÁRVORES INDIVIDUAIS

1 INTRODUÇÃO

Para obtenção de produtos florestais de forma sustentável e econômica, é necessário o criterioso planejamento das operações florestais. Quando o produto de interesse é a madeira, é essencial o conhecimento do volume disponível nos povoamentos, de modo a garantir o manejo eficiente da floresta. Uma das ferramentas mais importantes para a quantificação volumétrica é o inventário florestal, que consiste em realizar medições e análises para conhecer a situação qualitativa e quantitativa da floresta (MACHADO *et al.*, 2002).

O volume das árvores fornece um ponto inicial para obtenção do volume do povoamento, no entanto medir o volume real de uma árvore é uma operação onerosa econômica e temporalmente. Com isso, são utilizadas técnicas estatísticas para estimar, com um determinado grau de confiança, o volume das árvores, o que poupa tempo e recursos financeiros. Uma dessas técnicas é a cubagem, na qual são abatidas e cubadas árvores-amostra que representem as variações de todas as características existentes na população. A partir da medição das seções do tronco são empregadas fórmulas aproximativas de volume, como as de Huber, Newton e Smalian, para calcular o volume total da árvore (CAMPOS; LEITE, 2013).

O volume das demais árvores das parcelas é geralmente estimado por meio da utilização de modelos volumétricos, lineares ou não lineares, que o correlacionam com o diâmetro a 1,30 m de altura e com a altura total ou outras variáveis. Um dos principais modelos volumétricos utilizados no setor florestal é o de Schumacher e Hall (1933). Provavelmente o sucesso da utilização desse modelo é devido às suas estimativas serem, quase sempre, não tendenciosas, às suas propriedades estatísticas e ao fato de o ajuste desse modelo poder ser realizado tanto na forma linear, quanto não linear (CAMPOS; LEITE, 2013).

Uma alternativa promissora para estimação volumétrica em nível de árvores, ou também em nível de povoamentos, é a utilização de técnicas de inteligência computacional, como as Redes Neurais Artificiais (RNA) (DIAMANTOPOULOU, 2005; GÖRGENS, 2006; SILVA *et al.*, 2009; DIAMANTOPOULOU; MILIOS, 2010; LEITE *et al.*, 2010; SILVA, 2010; BINOTI, 2012).

As Redes Neurais Artificiais foram inspiradas na estrutura e no funcionamento do cérebro humano e são uma subespecialidade da inteligência computacional, surgindo da intenção de se implementar computacionalmente versões simplificadas das redes neurais biológicas. Do ponto de vista estrutural, as RNA são constituídas de elementos de processamento simples (neurônios artificiais), conectados entre si de maneira específica, e possuem a finalidade de tornar disponível, para o uso, o conhecimento experimental armazenado previamente nas conexões entre seus elementos (HAYKIN, 2001).

As RNA possuem a capacidade de aprender por meio de exemplos apresentados e generalizar informações, ou seja, são capazes de extrair as características necessárias para representar as informações fornecidas e utilizar o conhecimento adquirido em dados não conhecidos, de mesma natureza, o que faz com que sua utilização seja atrativa. Possuem também a capacidade de retirar informações que não foram apresentadas de forma explícita nos dados (BRAGA, 2007). Além disso, são tolerantes a falhas e ruídos, possuem paralelismo massivo, o que as torna muito eficientes, e possuem analogia neurobiológica e capacidade de modelar problemas não lineares (HAYKIN, 2001; BRAGA, 2007).

Porém, o emprego dessa técnica depende da definição da arquitetura e da topologia das RNA (número de camadas, número de neurônios em cada camada e tipos de conexões), uma vez que esses parâmetros restringem o tipo de problema que pode ser tratado pela rede (BRAGA, 2007). Essas configurações geralmente são testadas de modo aleatório, até que se obtenham resultados em que os erros sejam aceitáveis, o que exige maior tempo e conhecimento do usuário. Assim, técnicas que visam facilitar a parametrização das RNA vêm sendo criadas para tornar seu uso operacional mais simples. Dentre essas técnicas destacam-se as *Skip-layer connections*, que são conexões diretas dos neurônios de entrada (correspondentes às variáveis independentes) para o neurônio de saída que gera a variável resposta (ou independente) (VELTEN, 2009).

Neste trabalho objetivou-se avaliar o desempenho das RNA utilizando conexões do tipo *Skip-layer*, com e sem recorrência, na estimação de volumes de árvores individuais de povoamentos equiâneos de eucalipto. Foi avaliada também a possibilidade de redução da amostra para treinamento das Redes Neurais Artificiais.

2 MATERIAL E MÉTODOS

2.1 Descrição dos dados

Neste estudo foi utilizada uma base de dados provenientes da cubagem de 1.878 árvores de povoamentos clonais de eucalipto, situados no sul da Bahia, Brasil. As árvores-amostra foram abatidas e cubadas em seções com intervalos de 1 m ao longo do fuste, obtendo-se o volume total com casca (V) por meio da aplicação da fórmula de Smalian. O diâmetro a 1,3 m de altura (dap) e a altura total (Ht) também foram medidos.

O banco de dados foi composto por 29 projetos, contemplando 15 genótipos (clones). A descrição das variáveis quantitativas em termos de seus valores mínimo, médio, máximo e o desvio-padrão da média estão na Tabela 1.

Tabela 1 – Análise descritiva dos dados utilizados

Variável	Mínimo	Máximo	Média	Desvio-Padrão
dap (cm)	14,0	29,9	20,1	$\pm 3,5$
Idade (anos)	3	11	7	± 2
Altura total (m)	20,4	43,7	30,6	$\pm 3,9$
Volume (m ³)	0,2000	1,3610	0,4670	$\pm 0,2$

2.2 Redes Neurais Artificiais

Para estimar o volume total de árvores por meio de RNA, foram utilizados o dap , a altura total e a idade como variáveis contínuas (quantitativas) e o projeto e o clone, como variáveis categóricas (qualitativas).

O banco de dados foi separado em nove proporções, de modo a avaliar a quantidade de árvores cubadas em cada estrato, reduzindo de forma gradativa. A simulação consistiu no sorteio das seguintes proporções: 90, 80, 70, 60, 50, 40, 30, 20 e 10% das árvores para treinamento das Redes Neurais Artificiais, e o restante dos dados (10, 20, 30, 40, 50, 60, 70, 80 e 90%, respectivamente) foi utilizado para generalização, ou seja, para avaliar a capacidade de estimação das RNA para dados desconhecidos. Durante o sorteio, as proporções dos dados foram mantidas para cada estrato.

Para cada proporção dos dados de treinamento e generalização, foram avaliadas as seguintes alternativas:

- i) Treinamento com o algoritmo *Resilient propagation*.

- ii) Treinamento com *Skip-layer connections* sem recorrência.
- iii) Treinamento com *Skip-layer connections* com recorrência.

O algoritmo *Resiliente propagation* foi escolhido como base de comparação ao método *Skip-layer connections*, com e sem recorrência, por ter demonstrado resultados superiores aos dos demais algoritmos de treinamento para RNA do tipo *Multilayer Perceptron* (MLP) em aplicações da mensuração florestal (BINOTI *et al.*, 2014).

Para cada alternativa testada, foram treinadas 100 redes do tipo *Multilayer Perceptron* (MLP). A camada de entrada de todas as RNA foi constituída de 44 neurônios, sendo 26 correspondentes à quantidade de projetos, 14 ao número de clones e um para cada variável numérica (*dap*, altura total e idade), totalizando mais três. O último neurônio da camada de entrada é um neurônio fixo que representa o limiar de ativação ou *bias* (HAYKIN, 2001). As RNA possuíram somente uma camada oculta, com oito neurônios. A camada de saída foi constituída por um neurônio, equivalente à variável de interesse, e a função de ativação utilizada na camada oculta e na de saída foi a Logística (Sigmoide).


O *software* utilizado para o treinamento das RNA foi o *NeuroForest 3.3* (BINOTI, 2012), que é gratuito e foi desenvolvido para uso no meio florestal, a fim de resolver os problemas específicos do setor. Os critérios para o *software* finalizar o treinamento foram: o erro quadrático médio igual a 0,0001 ou o número de épocas (ou iterações) igual a 3.000, finalizando quando alcançasse um dos dois critérios.

2.2.1 *Skip-Layer Connections*

Os neurônios artificiais podem estar ligados entre si de várias maneiras, possuindo, assim, diversas possibilidades de arquiteturas. Uma das arquiteturas é a do tipo *Multilayer Perceptron* (MLP), em que a rede neural possui uma camada de entrada, uma camada de saída e pelo menos uma camada intermediária entre elas. As conexões do MLP são de tal forma que uma camada tem todos os seus neurônios ligados apenas às camadas adjacentes.

As redes MLP também podem possuir conexões especiais chamadas de *Skip-layer* (RIPLEY, 1996), que são conexões diretas de cada neurônio de entrada a cada neurônio de saída, ou seja, conexões que não passam pela camada oculta, dando mais flexibilidade às RNA, conforme exemplificado na Figura 1 (VELTEN, 2009). Essas RNA também podem possuir laços de realimentação entre os nós das mesmas camadas ou das camadas próximas, sendo chamados de recorrência.

Figura 1 - MLP com três neurônios de entrada, dois neurônios ocultos e um neurônio de saída, com três skip-layer connections



Fonte: adaptada de Matignon (2005).

2.3 Modelo volumétrico

Para se ter um parâmetro de comparação, ajustou-se o modelo volumétrico (Equação 1) de Schumacher e Hall (1933), em sua forma não linear, com a mesma base de dados utilizada para RNA. A estratificação foi definida com base nas variáveis projeto e clone, obtendo-se um total de 54 estratos.

$$V = \beta_0 dap^{\beta_1} Ht^{\beta_2} + \varepsilon \quad \text{Eq. (1)}$$

em que V é o volume em m^3 ; dap é o diâmetro a 1,3 m de altura, em cm; Ht é a altura total da árvore, em m; β_i são os parâmetros da regressão; e ε é o erro aleatório.

2.4 Avaliações das RNA

A análise dos resultados gerados pelas RNA e pelo modelo de Schumacher e Hall (1933) foi feita por meio do coeficiente de correlação entre os volumes observados e os estimados, gráficos de dispersão e histogramas de frequência percentual dos erros relativos percentuais ($e\%$). Os erros relativos para gerar ambos os gráficos foram calculados por:

$$e\% = \frac{(V_i - \hat{V}_i)}{V} \times 100 \quad \text{Eq. (2)}$$

em que \hat{V}_i é o volume estimado pela RNA; e V_i é o volume observado.

A raiz quadrada do erro quadrático médio (RQEM% - *Root Mean Square Error*) (Equação 3) foi utilizada para avaliar a diferença quadrática média entre os valores observados e os estimados. Valores de RQEM% são considerados melhores quanto mais próximos de 0 (MEHTÄTALO *et al.*, 2006), devendo ser ressaltado que essa estatística avalia a magnitude média do erro. Utilizou-se também a variância dos erros relativos ou resíduos (Equação 4), para avaliação da qualidade da estimação.

$$RQEM(\%) = \frac{100}{\bar{V}} \sqrt{\frac{\sum_{i=1}^n (V_i - \hat{V}_i)^2}{n}} \quad \text{Eq. (3)}$$

em que \bar{V} é a média dos volumes totais observados; e n é o número total de observações.

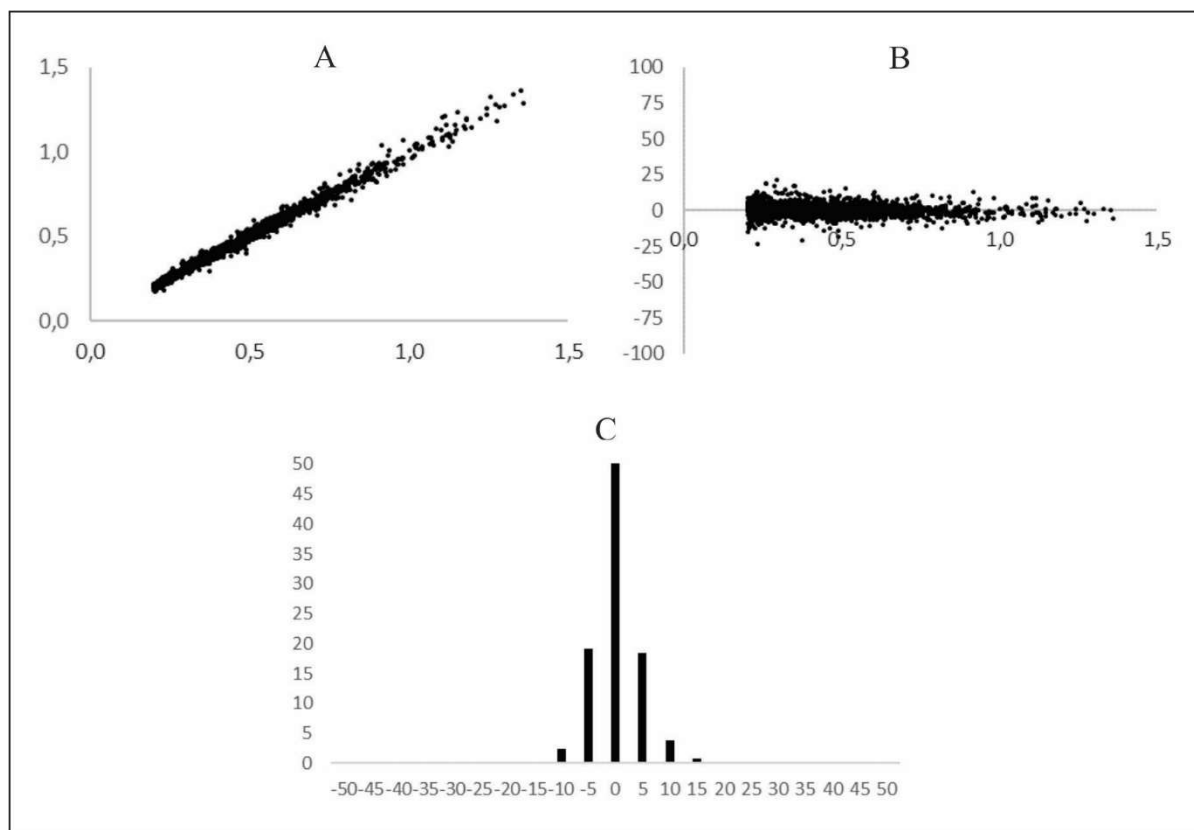
$$s_{e\%}^2 = \frac{\sum_{i=1}^n (e_{\%} - \bar{e}_{\%})^2}{n - 1} \quad \text{Eq. (4)}$$

em que $s_{e\%}^2$ é a variância dos erros relativos; $e_{\%}$ é o erro relativo estimados na i -ésima observação e $\bar{e}_{\%}$ é a média dos erros relativos estimados.

3 RESULTADOS

Os gráficos de dispersão e o histograma da frequência percentual dos erros relativos obtidos pelo ajuste do modelo de Schumacher e Hall (1933) estão na Figura 2. A correlação entre os valores observados dos volumes totais e os obtidos por meio do modelo foi de 0,9956, a variância do resíduo foi de 17,18 e o RQEM (%) foi 4,27.

Figura 2 – (a) Gráfico de dispersão da relação volumes estimados (m^3) pelo ajuste do modelo de Schumacher e Hall (eixo y) e volumes observados (m^3) (eixo x); (b) gráfico de dispersão dos erros percentuais dos volumes totais estimados (m^3) pelo ajuste do modelo de Schumacher e Hall (eixo y), em função dos volumes observados (m^3) (eixo x); e (c) histograma de frequência percentual (eixo y) dos erros percentuais (eixo x) das estimativas de volume obtido pelo ajuste do modelo de Schumacher e Hall



Na Tabela 2 estão a descrição das RNA selecionadas e as estatísticas obtidas pelo treinamento e pela generalização de cada metodologia testada.

As RNA selecionadas no treinamento foram aplicadas para estimação dos volumes das árvores não cubadas de cada parcela, utilizando o *dap*, a altura total, a idade, o projeto e o clone.

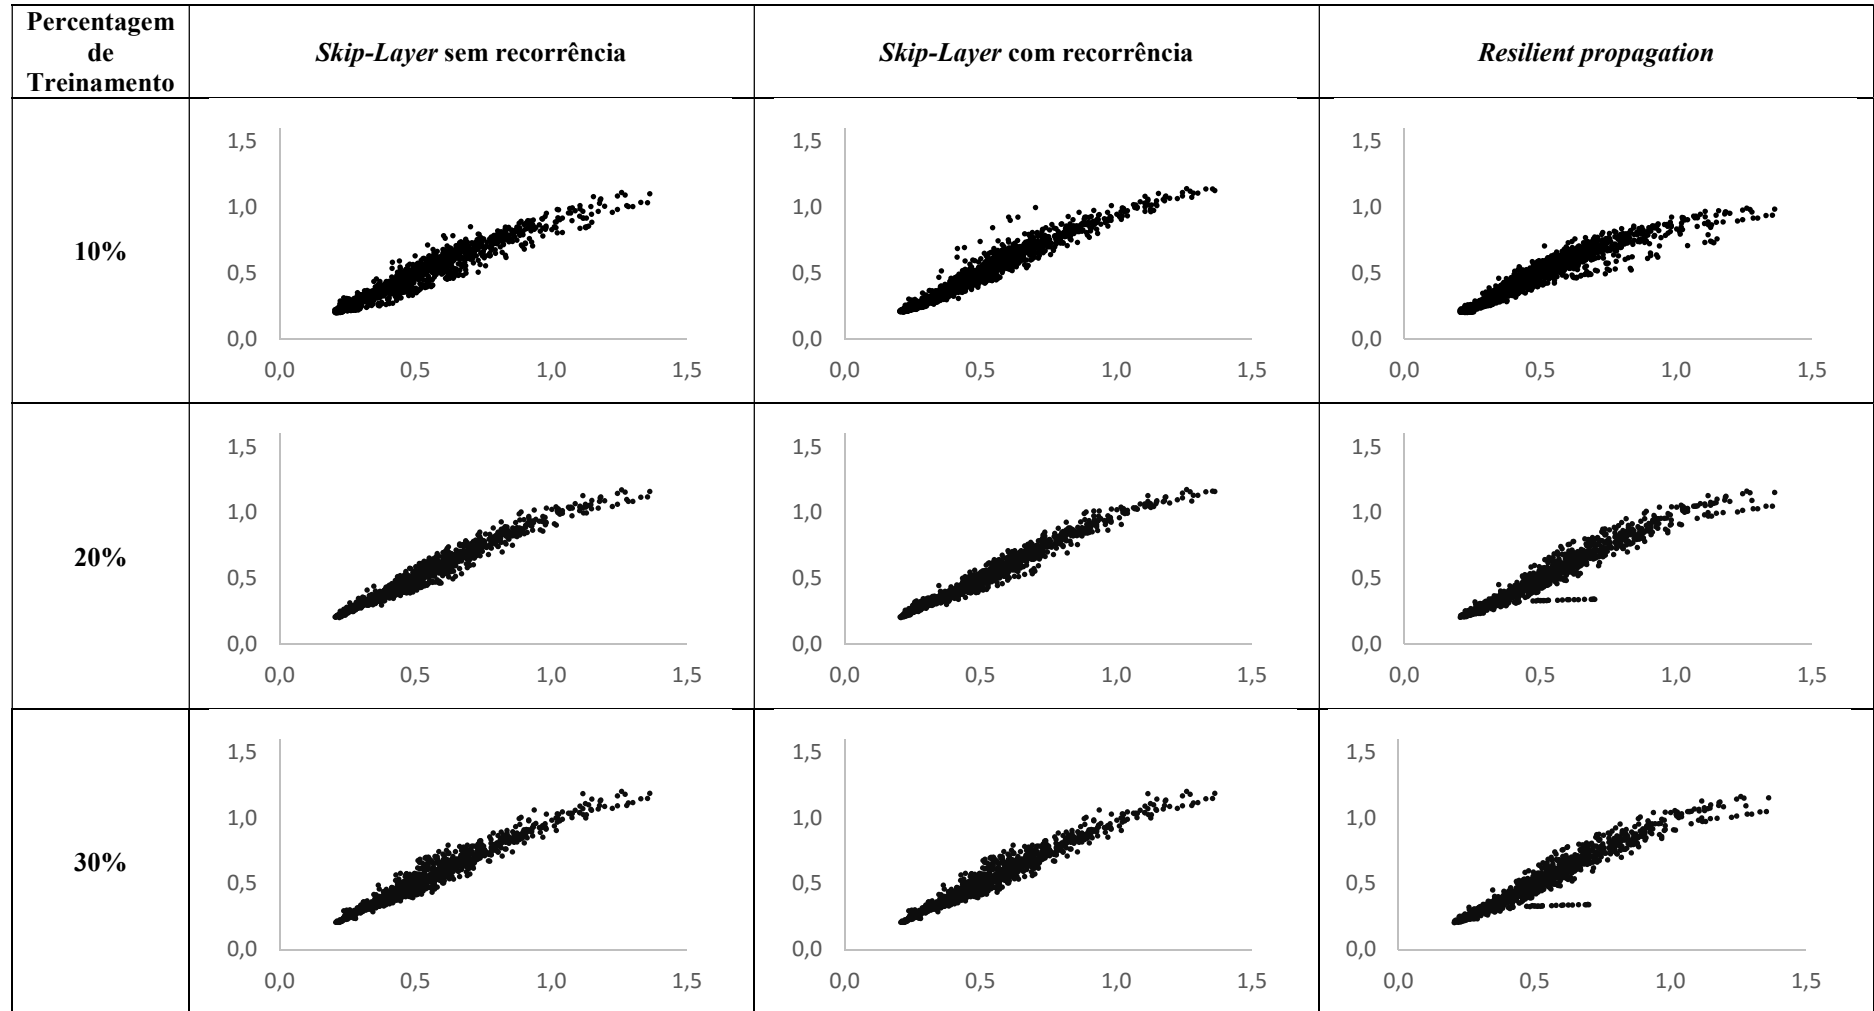
Tabela 2 – Estatísticas para dados de treinamento e generalização de cada alternativa de estimação do volume total

Tipo de RNA	Treino (%)	Treinamento			Generalização		
		r	$s^2_{e\%}$	RQEM%	r	$s^2_{e\%}$	RQEM%
<i>Skip-layer SR</i>	10	0,9964	15,0683	3,8744	0,9645	95,2661	10,1555
<i>Skip-layer CR</i>	10	0,9964	15,0166	3,8730	0,9737	76,9034	8,7679
<i>Resilient Prop.</i>	10	0,9964	15,6471	3,9542	0,9528	92,3091	9,8429
<i>Skip-layer SR</i>	20	0,9975	12,0310	3,4680	0,9802	47,4926	6,8906
<i>Skip-layer CR</i>	20	0,9975	12,5950	3,5468	0,9835	42,1444	6,4902
<i>Resilient Prop.</i>	20	0,9975	13,2132	3,6379	0,9635	85,2915	9,2955
<i>Skip-layer SR</i>	30	0,9963	13,6341	3,6928	0,9728	68,4912	8,3056
<i>Skip-layer CR</i>	30	0,9960	14,3449	3,7885	0,9750	56,6868	7,5366
<i>Resilient Prop.</i>	30	0,9947	18,9715	4,3525	0,9774	58,1592	7,6284
<i>Skip-layer SR</i>	40	0,9949	15,6936	3,9625	0,9806	37,2127	6,1889
<i>Skip-layer CR</i>	40	0,9949	15,7989	3,9758	0,9836	41,5283	6,5060
<i>Resilient Prop.</i>	40	0,9949	15,9980	4,0003	0,9629	58,4115	7,6701
<i>Skip-layer SR</i>	50	0,9951	14,5442	3,8147	0,9803	39,2035	6,3294
<i>Skip-layer CR</i>	50	0,9948	15,3227	3,9158	0,9825	33,6603	5,7984
<i>Resilient Prop.</i>	50	0,9945	15,8478	3,9820	0,9728	51,8227	7,2727
<i>Skip-layer SR</i>	60	0,9947	16,0768	4,0122	0,9833	30,8482	5,5586
<i>Skip-layer CR</i>	60	0,9948	15,7655	3,9718	0,9857	26,1319	5,1348
<i>Resilient Prop.</i>	60	0,9946	16,2244	4,0301	0,9813	32,1492	5,6675
<i>Skip-layer SR</i>	70	0,9946	16,1609	4,0219	0,9865	27,0078	5,2006
<i>Skip-layer CR</i>	70	0,9943	19,0872	4,3770	0,9803	39,8563	6,4070
<i>Resilient Prop.</i>	70	0,9943	17,2671	4,1585	0,9867	28,1150	5,3402
<i>Skip-layer SR</i>	80	0,9945	22,3702	4,7417	0,9862	31,0826	5,7916
<i>Skip-layer CR</i>	80	0,9951	15,9755	3,9986	0,9889	29,6209	5,5127
<i>Resilient Prop.</i>	80	0,9949	18,5490	4,3117	0,9876	27,3695	5,2248
<i>Skip-layer SR</i>	90	0,9953	17,9856	4,2458	0,9911	22,9127	4,9455
<i>Skip-layer CR</i>	90	0,9955	16,4397	4,0583	0,9915	22,8256	4,8998
<i>Resilient Prop.</i>	90	0,9954	16,8698	4,1102	0,9908	26,4056	5,1488

SR = sem recorrência; CR = com recorrência; Prop. = *Propagation*; r = coeficiente de correlação; s^2 = variância dos erros percentuais; e RQEM% = raiz quadrada do erro quadrático médio.

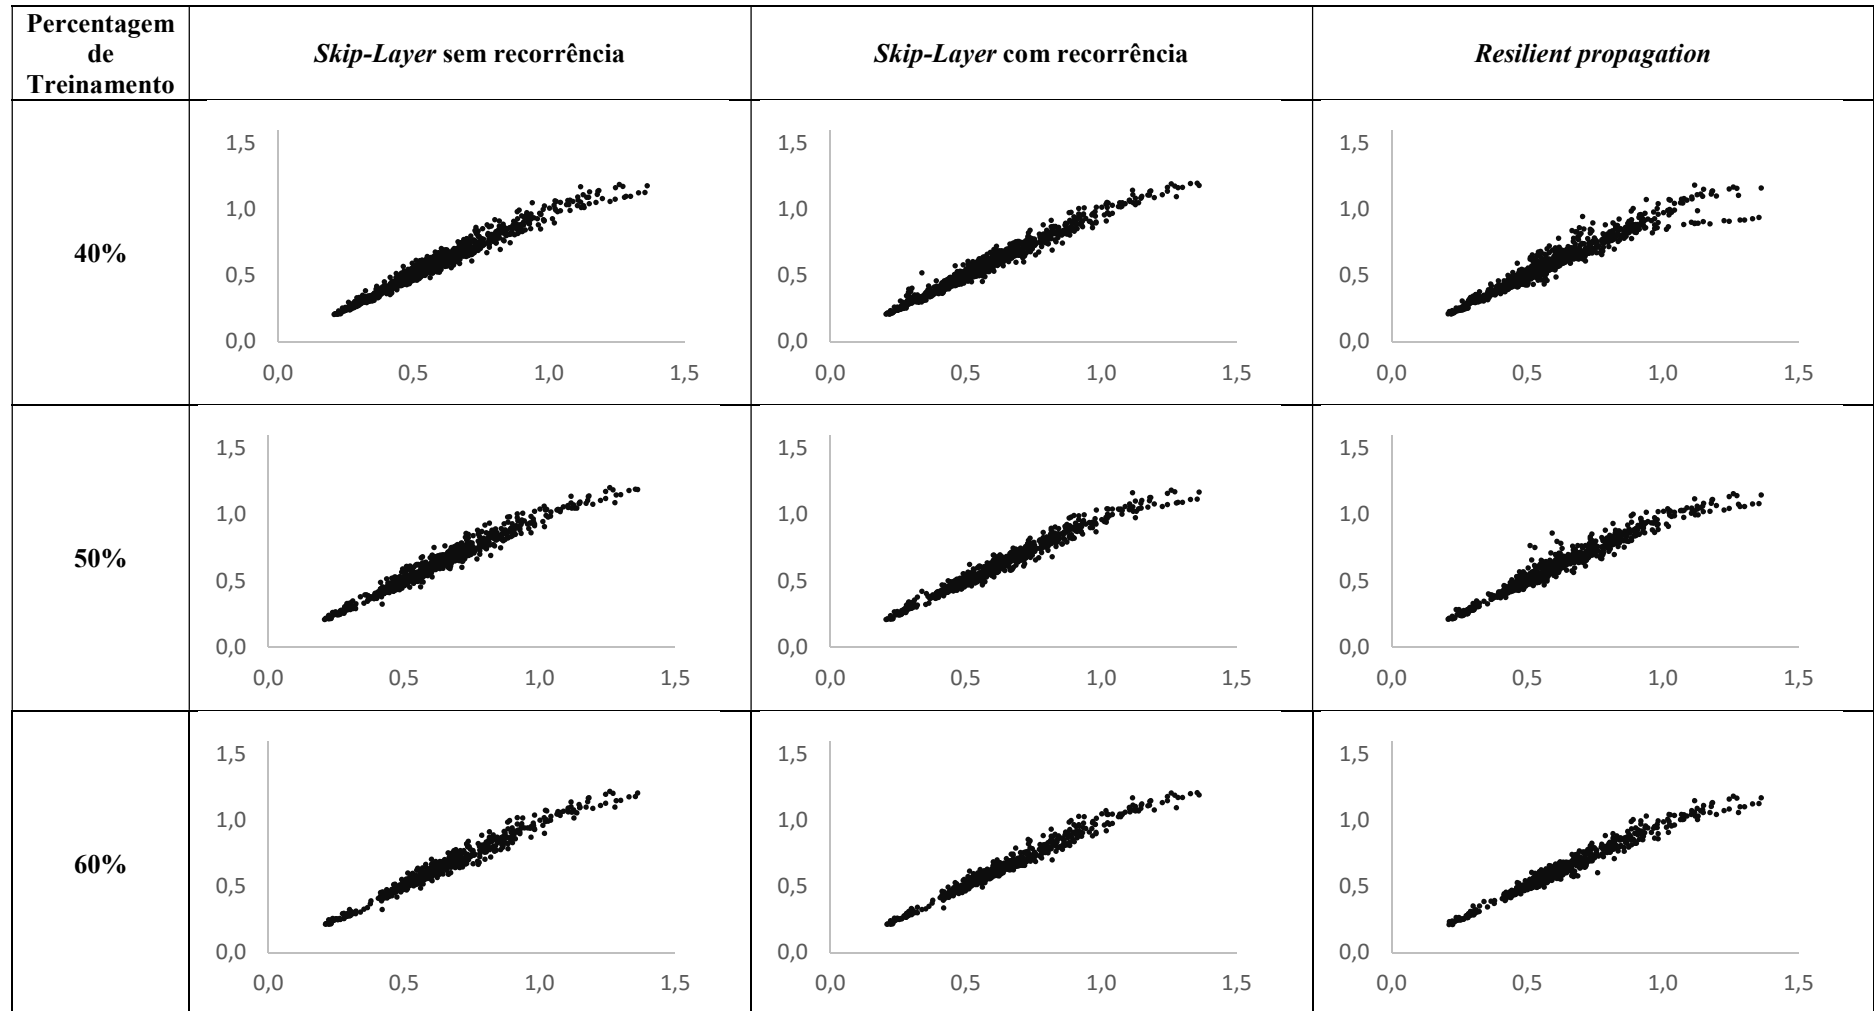
Na Figura 3 estão os gráficos de correlação entre o volume observado e o volume estimado para cada alternativa testada, obtidos pela generalização das RNA selecionadas. Os gráficos de resíduo estão apresentados na Figura 4; e os histogramas de frequência percentual dos erros percentuais das estimativas das RNA para volume estão na Figura 5, ambos para generalização das RNA.

Figura 3 – Gráficos de dispersão da relação volumes estimados (m^3) pelas RNA (eixo y) para o conjunto de generalização e os volumes observados (m^3) (eixo x)



Continua...

Figura 3, Cont.



Continua...

Figura 3, Cont.

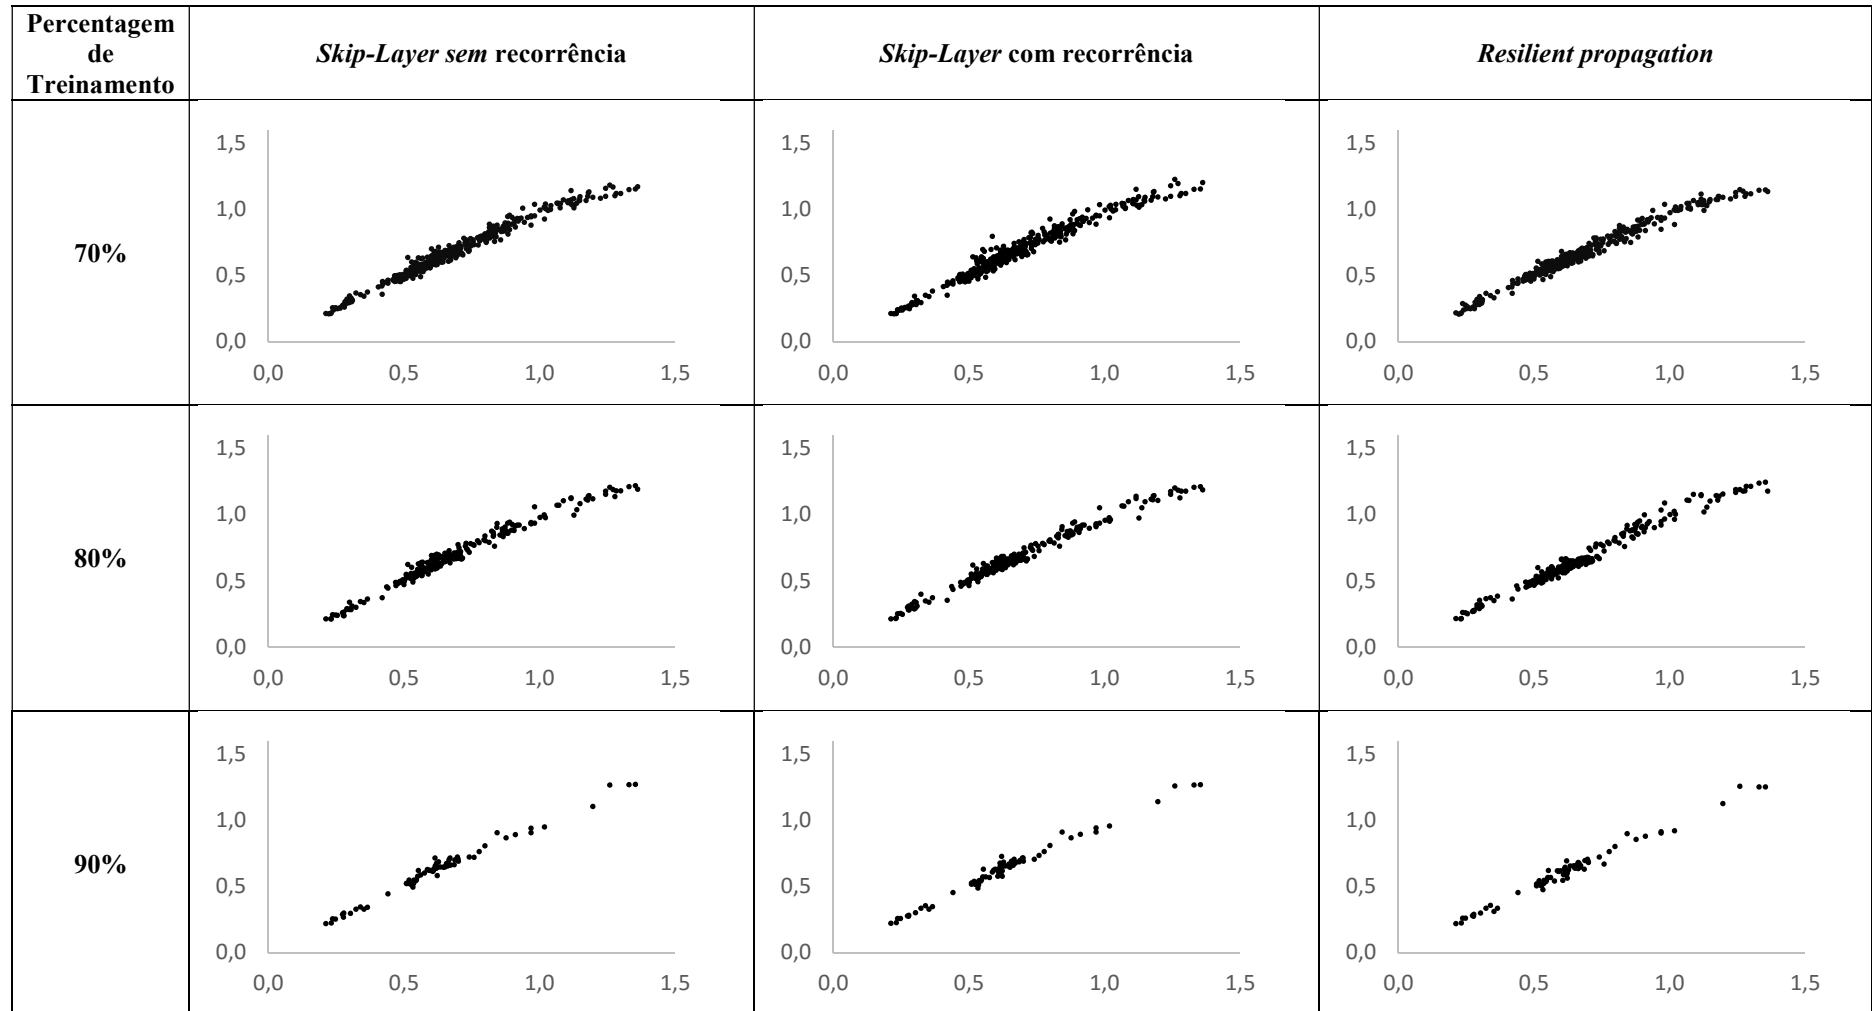
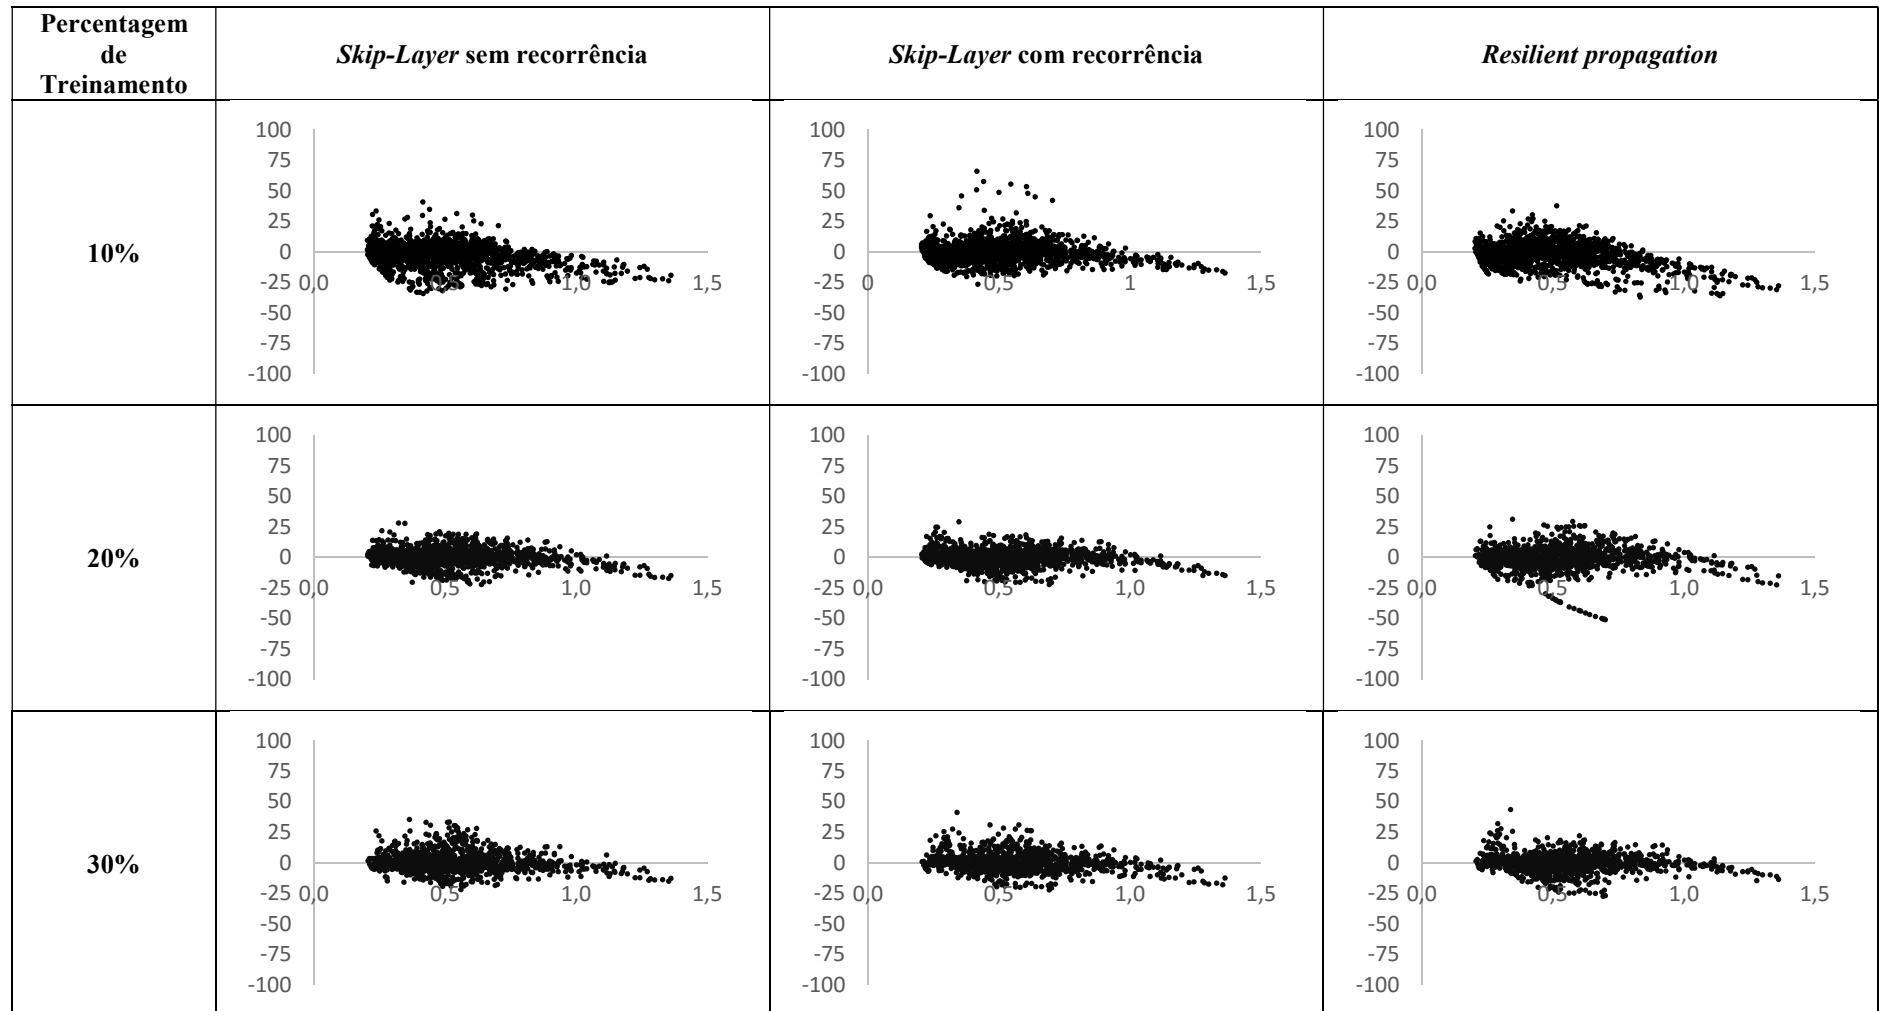
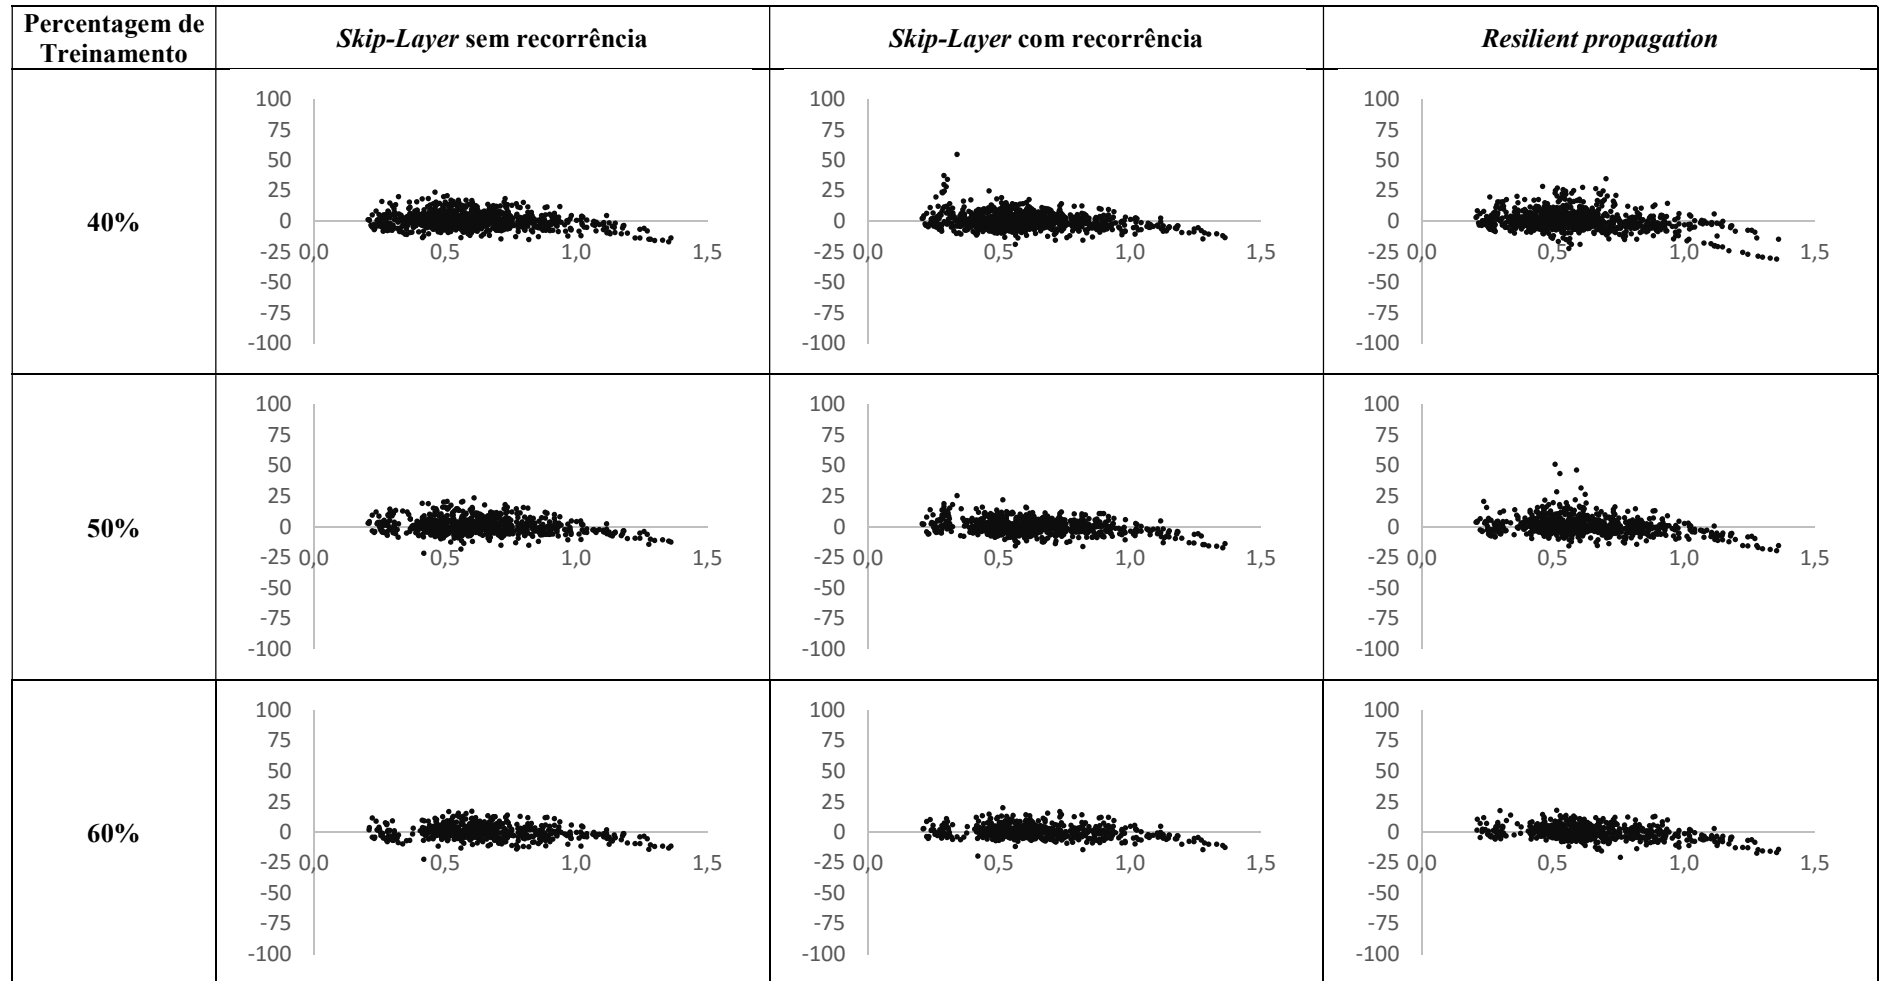


Figura 4 – Gráficos de dispersão dos erros percentuais dos volumes estimados pelas RNA (eixo y) para o conjunto de generalização e volumes observados (m^3) (eixo x), em função dos volumes observados (m^3) (eixo x)



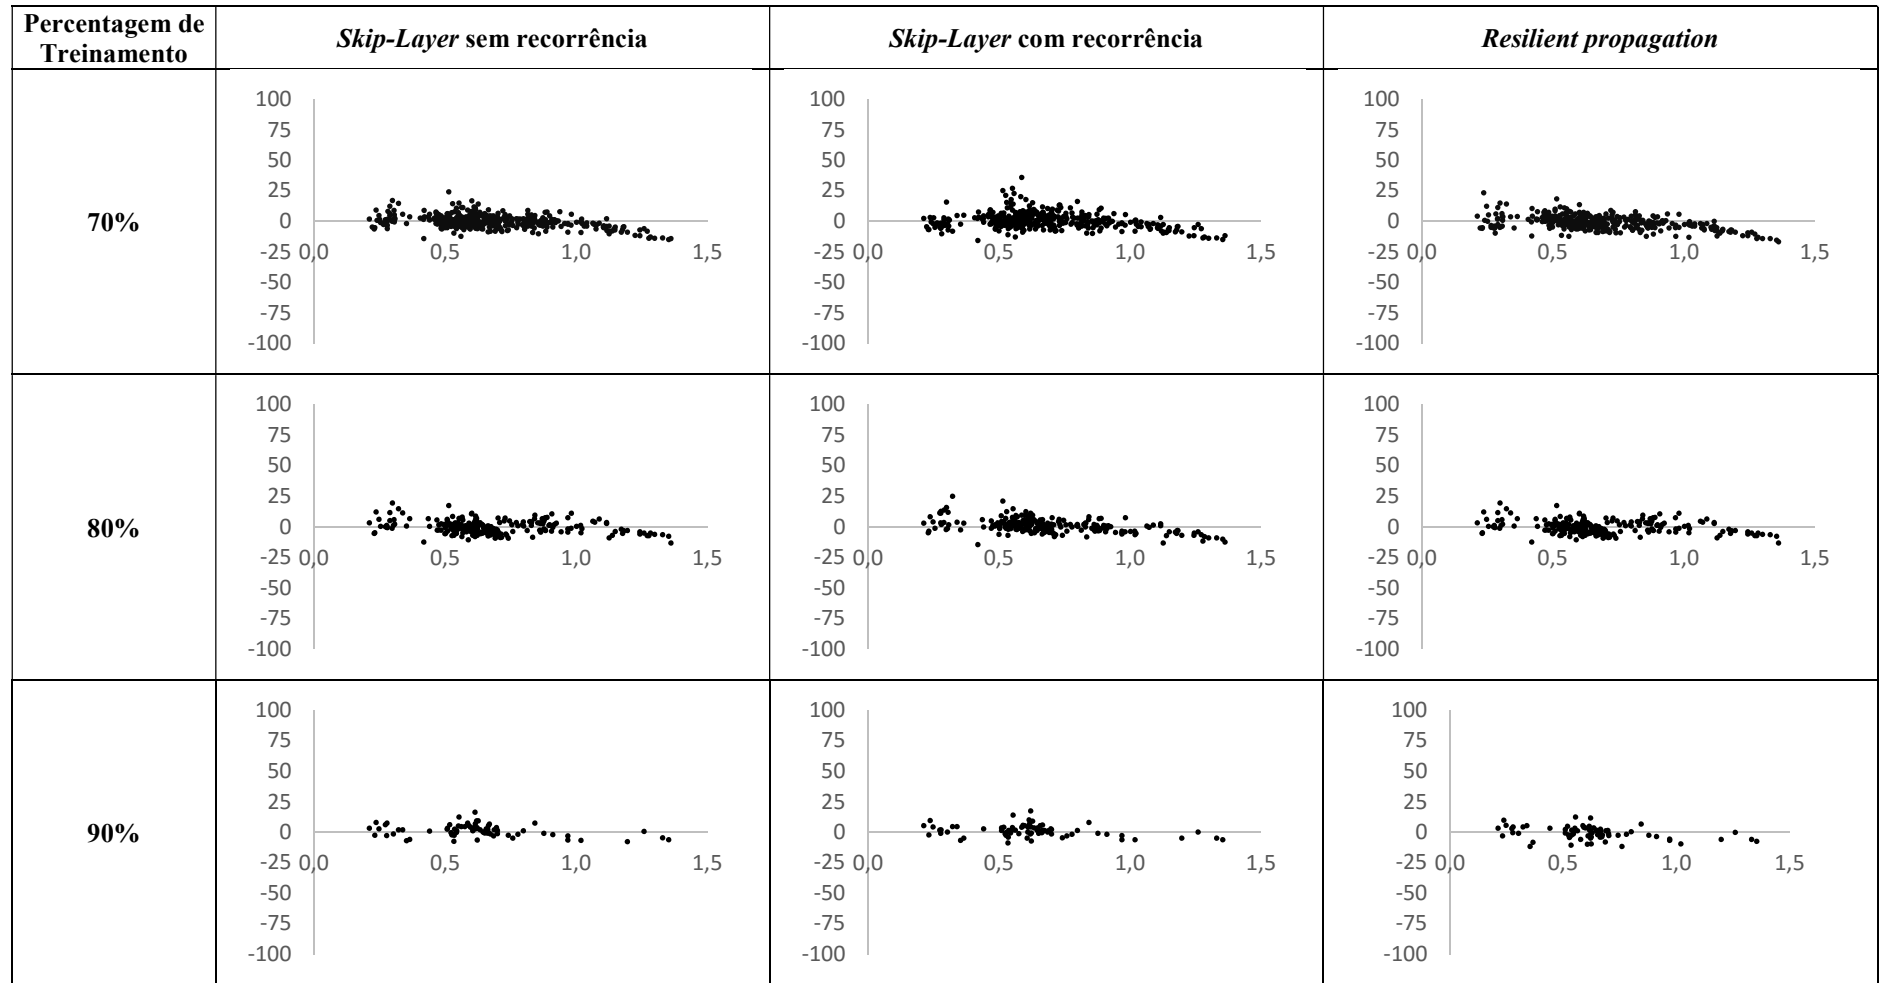
Continua...

Figura 4, Cont.



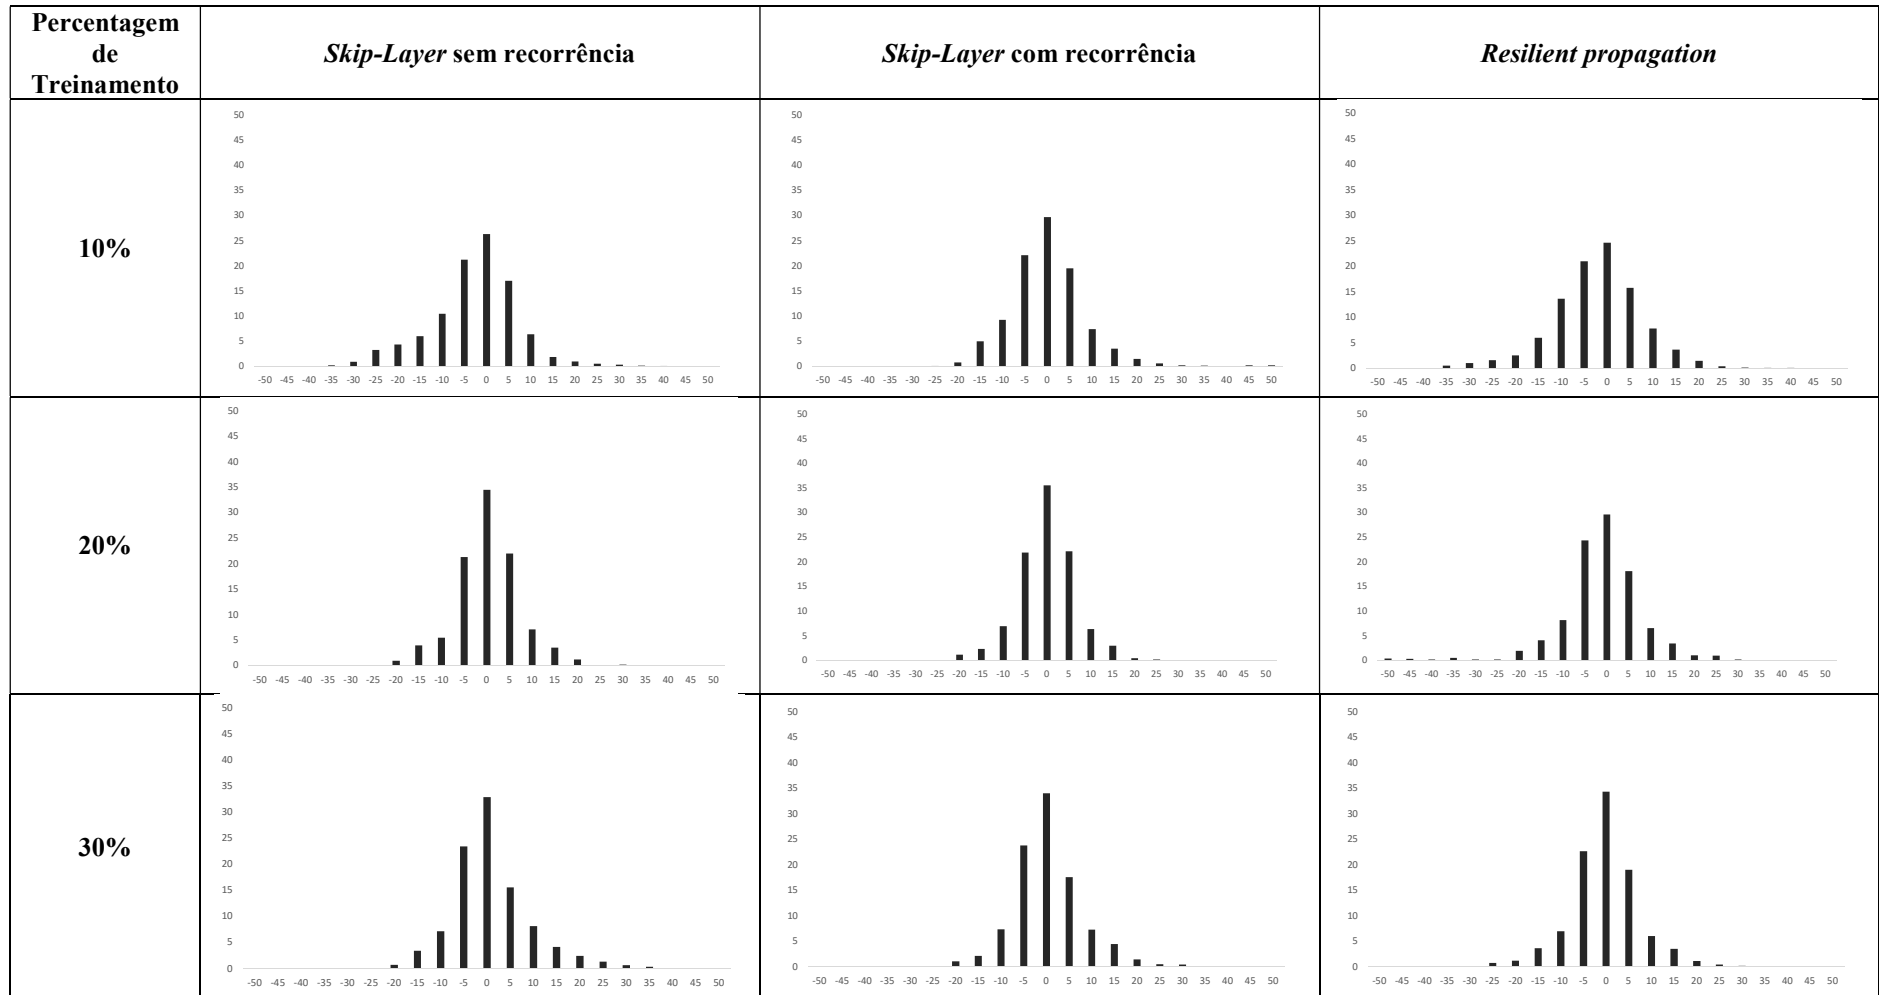
Continua...

Figura 4, Cont.



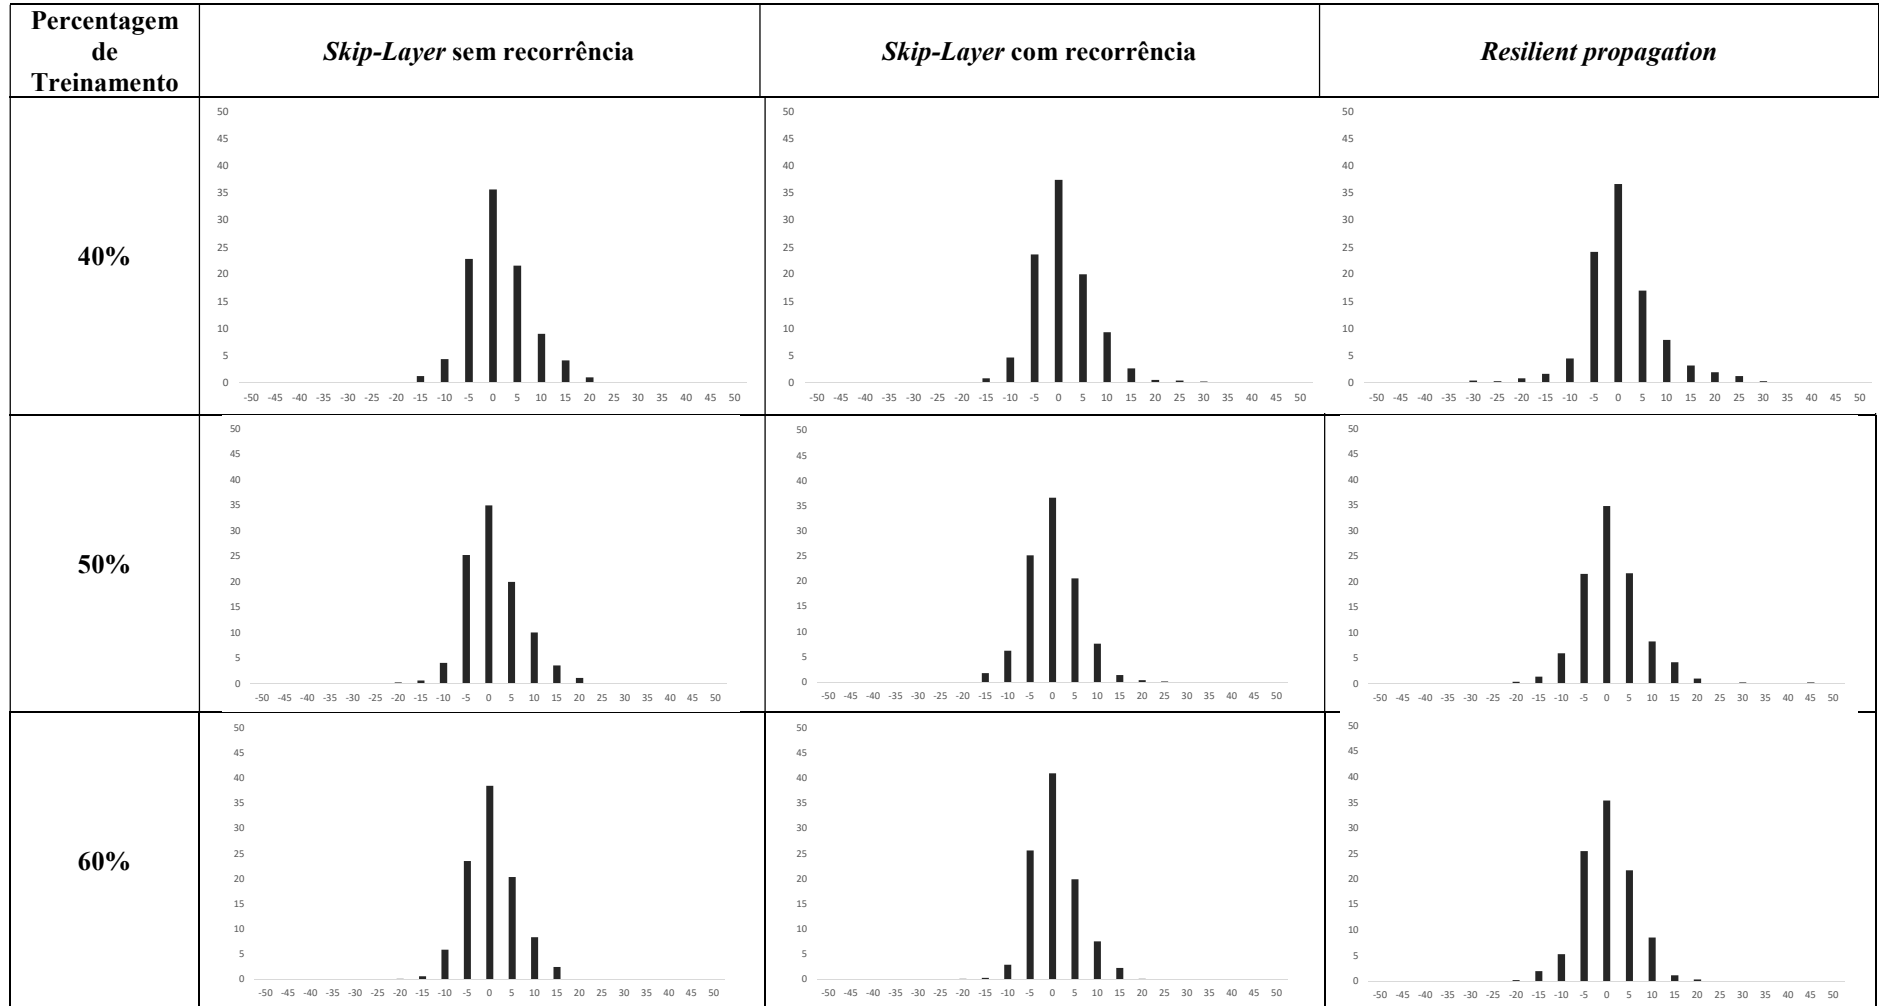
Continua...

Figura 5 – Histogramas de frequência percentual (eixo y) dos erros percentuais (eixo x) das estimativas das RNA para volume para o conjunto de generalização



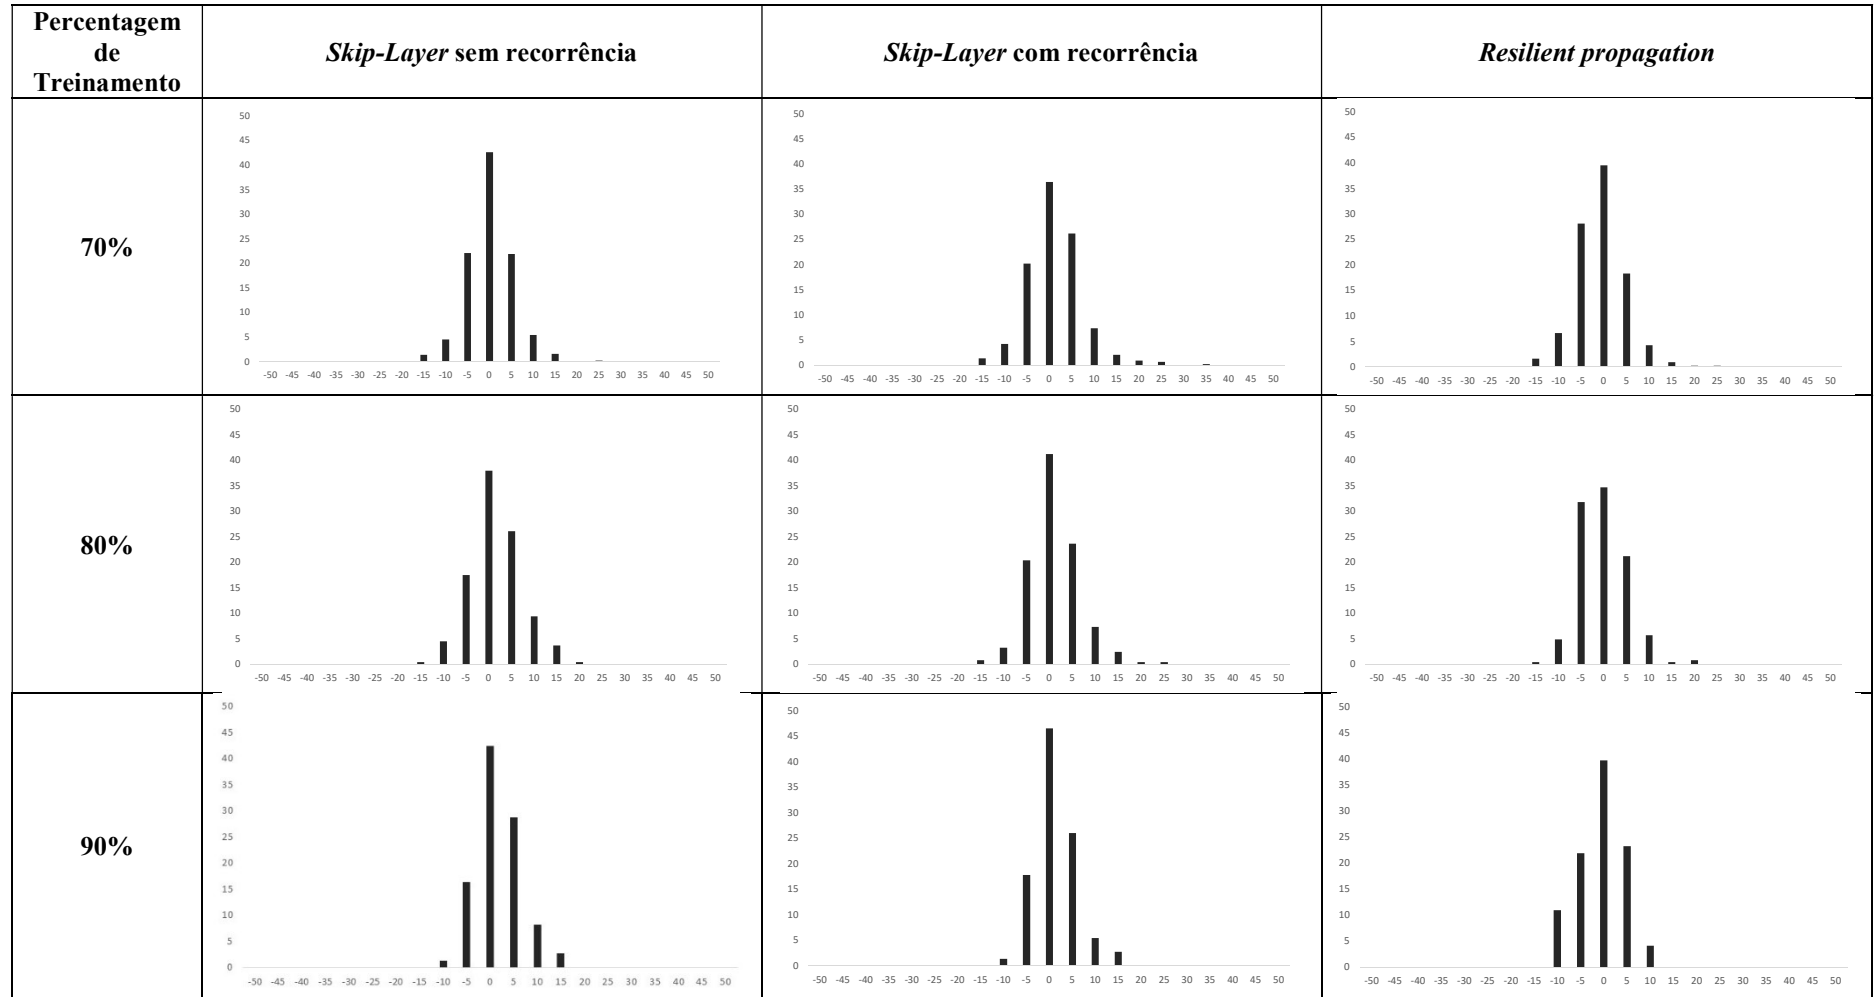
Continua...

Figura 5, Cont.



Continua...

Figura 5, Cont.



4 DISCUSSÃO

O manejo florestal sustentável depende da obtenção de estimativas consistentes e exatas do volume das árvores em campo e, conseqüentemente, dos plantios florestais. Técnicas de regressão linear e não linear têm gerado estimativas precisas na estimação do volume e da altura das árvores (SCHUMACHER; HALL, 1933, BATISTA *et al.*, 2001; HUSCH *et al.*, 2003; LEITE; ANDRADE, 2003; SILVA *et al.*, 2009; ANDRADE; LEITE, 2011).

A estimação do volume de árvores é comumente feita pela regressão do volume de interesse (total, com ou sem casca ou até um diâmetro mínimo de corte) com variáveis do povoamento facilmente mensuradas, como a altura e o diâmetro a 1,3 m de altura (*dap*). O modelo de Schumacher e Hall (1933) é predominantemente empregado na área florestal, devido às suas propriedades estatísticas, à facilidade de ajuste e uso e à geração de estimativas precisas (CAMPOS; LEITE, 2013).

A utilização de Redes Neurais Artificiais (RNA) é uma alternativa promissora em relação às técnicas de regressão para o manejo dos recursos florestais. Diversos trabalhos têm sido desenvolvidos visando à sua adaptação e parametrização para diversas situações, como estimação do volume de árvores (SILVA *et al.*, 2009), crescimento e produção (BINOTI, 2010), *taper* (LEITE *et al.*, 2010), dentre outras aplicações.

A definição da configuração ideal das RNA é a principal dificuldade encontrada por seus usuários para a definição de sua melhor forma de treinamento e aplicação. O usuário deve conhecer bem o problema, para geração consistente da RNA (HIROSE *et al.*, 1991; ARAI, 1993; FUJITA, 1998; BINOTI *et al.*, 2015).

Logo, a utilização de algoritmos e técnicas que possibilitem maior estabilidade no processo de treinamento e aplicação das RNA é fundamental para melhor operacionalização da técnica.

Neste estudo foram obtidos resultados satisfatórios para estimação de volume de árvores de eucalipto utilizando RNA com *Skip-layer connections*, tanto no treinamento quanto na generalização para todas as proporções testadas. Entretanto, os melhores resultados foram constatados na proporção de 90% dos dados para treinamento e 10% para generalização, com valores mais similares das estatísticas nos dois conjuntos de dados (Tabela 2). Os gráficos apresentados nas Figuras 3, 4 e 5 demonstram que houve melhoria nos resultados quando se utilizou *Skip-layer connections* com recorrência.

Já as RNA utilizando o algoritmo *Resilient Propagation* apresentaram resultados tendenciosos nas proporções até 40% (Figuras 3 e 4). Para esse algoritmo, os resultados foram satisfatórios para as proporções maiores que 50%.

O aumento da exatidão das estimativas proporciona maior certeza no processo de decisão sobre as prescrições de manejo que devem ser aplicadas ao povoamento. Contudo, os processos de melhoria contínua e redução de custos aos quais as empresas florestais devem se adequar para garantir melhoria constante dos lucros exige que, além de melhor estimação das características dos plantios florestais, novas técnicas gerem redução significativa dos custos do processo.

A técnica *Skip-layer connections* foi eficiente para estimação volumétrica de plantios florestais (Tabela 2 e Figuras 3, 4 e 5), pois possibilitou estimativas equiparáveis às do modelo de Schumacher e Hall (1993), que é comumente utilizado na área florestal, com uma significativa redução na quantidade de dados de árvores-amostra. Além disso, o emprego de RNA se torna atrativo, uma vez que com apenas uma RNA para todos os estratos da base de dados é possível obter resultados satisfatórios. A técnica permite essa vantagem ao tratar informações como clone e projeto como variáveis de entrada qualitativas ou categóricas. Quando modelos volumétricos são utilizados, é necessário um modelo para cada estrato, o que torna o processo mais complexo.

Também foram obtidos resultados satisfatórios utilizando somente 40%, o que implica uma redução significativa dos custos operacionais de coleta dos dados em campo, bem como do tempo empregado nessa atividade.

Araújo (2015) obteve bons resultados utilizando RNA com *Skip-layer connections* para estimação de volumes de árvores de 11 formações florestais, devendo ser ressaltado que para Caatinga Arbórea, Campo Cerrado, Cerrado, Mata Primária, Mata Secundária e Mata de Transição Cipó as RNA foram superiores ao modelo usual de regressão, comprovando o potencial de uso desse tipo de RNA também na modelagem da produção de vegetações nativas.

A utilização da técnica *Skip-layer connections* para estimação do volume de povoamentos de eucalipto é uma alternativa viável para a melhoria da exatidão das estimativas, com significativa redução no esforço amostral.

Outros estudos podem ser feitos visando contabilizar os ganhos operacionais da implementação da técnica, bem como as possíveis reduções de custos, ao diminuir o número de árvores cubadas. No presente estudo, foi possível reduzir 40% da quantidade de dados utilizados no treinamento das redes, sem que houvesse perda na precisão das estimativas.

5 CONCLUSÃO

A técnica de *Skip-layer connections* é eficiente para o treinamento de Redes Neurais Artificiais, visando à estimação do volume total de árvores de povoamentos equiâneos de eucalipto.

A redução da base de dados de ajuste é viável, tendo, neste estudo, os melhores resultados sido obtidos com a proporção de 90% dos dados para treinamento e 10% dos dados para generalização. Também foi possível reduzir 40% da quantidade de dados utilizados no treinamento das redes, sem que houvesse perda na precisão das estimativas.

6 REFERÊNCIAS

ANDRADE, V. C. L. de; LEITE, H. G. Hipsometric relationship modeling using data sampled in tree scaling and inventory plots. **Revista Árvore**, n. 35, p. 157-164, 2011.

ARAI, M. Bounds on the number of hidden units in binary-valued three-layer neural networks. **Neural Networks**, v. 6, p. 855-860, 1993.

ARAÚJO, A. C. da S. C. **Redes neurais artificiais para quantificação volumétrica de florestas nativas no estado de Minas Gerais**. 2015. 75 f. Dissertação (Mestrado em Ciência Florestal) – Universidade Federal dos Vales do Jequitinhonha e Mucuri, Diamantina, MG, 2015.

BATISTA, J. L. F.; COUTO, H. T. Z.; MARQUESINI, M. Desempenho de modelos de relações hipsométricas: estudo em três tipos de florestas. **Scientia Forestalis**, n. 60, p. 149-163, 2001.

BINOTI, M. L. M. da S. **Redes neurais artificiais para prognose da produção de povoamentos não desbastados de eucalipto**. 2010. 54 f. Dissertação (Mestrado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa, MG, 2010.

BINOTI, M. L. M. S. **Emprego de redes neurais artificiais em mensuração e manejo florestal**. 2012. 130 f. Tese (Doutorado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa, MG, 2012

BINOTI, D. H. B.; BINOTI, M. L. M. da S.; LEITE, H. G. Configuração de redes neurais para estimação do volume de madeira. **Ciência da Madeira**, v. 5, n. 1, p.59-67, 2014.

BINOTI, M. L. M. da S.; LEITE, H. G.; BINOTI, D. H. B.; GLERIANI, J. M. Prognose em nível de povoamento de clones de eucalipto empregando Redes Neurais Artificiais. **Cerne**, v. 21, n. 1, p. 97-105, 2015.

BRAGA, A. P.; CARVALHO, A. P. L. F.; LUDEMIR, T. B. **Redes neurais artificiais: teoria e aplicações**. 2. ed., Rio de Janeiro: LTC, 2007. 226 p.

CAMPOS, J. C. C.; LEITE, H. G. **Mensuração Florestal: perguntas e respostas**. 4. ed. atual. ampl. Viçosa: Ed. UFV, 2013. 605 p.

DIAMANTOPOULOU, M. J. Artificial neural networks as an alternative tool in pine bark volume estimation. **Computers and Electronics in Agriculture**, v. 10, p. 235-244, 2005.

DIAMANTOPOULOU, M.; MILIOS, E. Modelling total volume of dominant pine trees in reforestation via multivariate analysis and artificial neural network models. **Biosystems Engineering**, v. 105, p. 306-315, 2010.

FUJITA, O. Statistical estimation of the number of hidden units for feedforward neural networks. **Neural Networks**, v. 11, p. 851-859, 1998.

GÖRGENS, E. B. **Estimação do volume de árvores utilizando redes neurais artificiais**. 2006. 94 f. Dissertação (Mestrado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa, MG, 2006.

- HAYKIN, S. **Redes neurais: princípios e prática**. Porto Alegre: Bookman, 2001. 900 p.
- HIROSE, Y.; YAMASHITA, K.; HIJIYA, S. Back-propagation algorithm which varies the number of hidden units. **Neural Networks**, v. 4, p. 61-66, 1991.
- HUSCH, B.; BEERS, T. W.; KERSHAW JUNIOR, J. A. **Forest mensuration**. 4. ed. Malabar: Krieger Publishing Company, 2003. 443 p.
- LEITE, H. G.; ANDRADE, V. C. L. Importância das variáveis altura dominante e altura total em equações hipsométricas e volumétricas. **Revista Árvore**, n. 27, p. 301-310, 2003.
- LEITE, H. G.; SILVA, M. L. M.; BINOTI, D. H. B.; FARDIN, L.; TAKIZAWA, F. H. Estimation of inside-bark diameter and heartwood diameter for *Tectona grandis* Linn. trees using artificial neural networks. **European Journal of Forest Research**, v. 130, n. 2, p. 263-269, 2010.
- MACHADO, S. A.; CONCEIÇÃO, M. B.; FIGUEIREDO, D. J. Modelagem do volume individual para diferentes idades e regimes de desbaste em plantações de *Pinus oocarpa*. **Revista Ciências Exatas e Naturais**, Curitiba, v. 4, n. 2, jul./dez. 2002.
- MATIGNON, R. **Neural network modeling using SAS enterprise miner**. Author House, 2005. 604 p.
- 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, p. 501-516, 2006.
- RIPLEY, B. D. **Pattern recognition and neural networks**. 1. ed., Cambridge: Cambridge University Press, 1996. p. 144-172.
- SCHUMACHER, F. X.; HALL, F. S. Logarithmic expression of timber-tree volume. **Journal of Agricultural Research**, v. 47, n. 9, p. 719-734, 1933.
- SILVA, M. L. M.; BINOTI, D. H. B.; GLERIANI, J. M.; LEITE, H. G. Ajuste do modelo de Schumacher e Hall e aplicação de redes neurais artificiais para estimar volume de árvores de eucalipto. **Revista Árvore**, Viçosa, v. 33, n. 6, dez. 2009.
- SILVA, M. L. M. **Redes neurais artificiais para prognose da produção de povoamentos não desbastados de eucalipto**. 2010. 54 f. Dissertação (Mestrado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa, MG, 2010.
- VELTEN, K. **Mathematical modeling and simulation: introduction for scientists and engineers**. Weinheim: Wiley-VCH, 2009. 364 p.

CAPÍTULO 2

REDES NEURAIIS ARTIFICIAIS COM *SKIP-LAYER CONNECTIONS* PARA ESTIMATIVA DA ALTURA DE POVOAMENTOS DE EUCALIPTO

1. INTRODUÇÃO

O diâmetro a 1,3 m (*dap*) e a altura total das árvores são utilizados principalmente para sua estimativa volumétrica e para quantificação do volume total do povoamento. A estimativa de estoques de crescimento e de colheita é um importante elemento no manejo florestal, pois auxilia na definição de planos de manejo e em análises econômicas (AVERY; BURKHART, 1994).

A quantificação do estoque volumétrico é realizada por meio de inventários florestais contínuos (IFC) ou temporários. Em ambos, faz-se a medição do *dap* de todas as árvores das parcelas e de algumas alturas totais e/ou comerciais. As demais alturas são estimadas mediante o emprego de modelos hipsométricos, que utilizam o *dap* como variável independente. O volume total da parcela é obtido pela aplicação de modelos volumétricos, de razão volumétrica ou de afilamento, que em sua maioria possui como variáveis independentes o diâmetro com casca a 1,3 m de altura (*dap*) e a altura total da árvore (HUSCH *et al.*, 2003).

Os modelos hipsométricos podem ser locais ou generalistas. Modelos locais são baseados somente no *dap* das árvores, por isso não se adequam a todas as situações possíveis existentes nos povoamentos, sendo necessária a obtenção de equações específicas para cada parcela (CAMPOS; LEITE, 2013). Modelos generalistas consideram, além do *dap* das árvores, variáveis que expressam condições do local, como altura dominante e diâmetro médio e idade, portanto as equações obtidas podem ser aplicadas em nível regional (BARROS *et al.*, 2002; CAMPOS; LEITE, 2013).

Diversos estudos envolvendo técnicas de regressão (CURTIS, 1967; PARRESOL, 1992; FLEWELLING; DE JONG, 1994; COLBERT; LOOTENS, 2002; INOUE; YOSHIDA, 2004; CAMPOS; LEITE, 2013), modelos com efeitos mistos (CASTEDO-DORADO *et al.*, 2006; ADAME *et al.*, 2008; CRECENTE-CAMPO *et al.*, 2009), Redes Neurais Artificiais (BINOTI *et al.*, 2013a; BINOTI *e. al.*, 2013b; ÖZÇELIK *et al.*, 2013), dentre outros, têm sido realizados com o intuito de aperfeiçoar, introduzir e avaliar diferentes métodos para estimativa da altura de árvores de povoamentos florestais.

Técnicas de Redes Neurais Artificiais (RNA) para estimação da altura de árvores também têm sido utilizadas no setor florestal brasileiro de forma crescente, principalmente do gênero *Eucalyptus*. RNA são sistemas computacionais paralelos constituídos por unidades de processamento simples, também denominadas neurônios artificiais ou nodos, conectadas entre si de maneira específica para desempenhar determinada tarefa. Os neurônios artificiais são modelos matemáticos simplificados dos neurônios biológicos e processam as informações recebidas e ponderadas por pesos sinápticos, fornecendo uma única resposta (HAYKIN, 2001; BRAGA *et al.*, 2007).

Uma das principais vantagens da utilização de RNA é a possibilidade de inclusão de características do povoamento nos modelos hipsométricos, como índice de local e idade, e de características qualitativas, como espaçamento, espécie, tipo de solo, dentre outras, resultando na obtenção de estimativas mais precisas e em maior realismo biológico, o que torna o modelo aplicável em diferentes locais. Entretanto, a principal dificuldade na modelagem hipsométrica utilizando muitas características do povoamento e variáveis qualitativas é a definição da melhor topologia para treinamento da RNA para obtenção do menor custo computacional e da boa capacidade de generalização. Neste contexto, metodologias que visem à parametrização automática das RNA são fundamentais para o desenvolvimento e a aplicação operacional (BINOTI, 2014; MARTINS, 2015).

Neste trabalho objetivou-se avaliar a viabilidade de aplicação da técnica de *Skip-layer connections*, em sua forma com e sem recorrência, para o treinamento e a aplicação de RNA na estimação da altura de árvores em povoamentos equiâneos de eucaliptos.

2 MATERIAL E MÉTODOS

2.1 Dados

Os dados utilizados neste estudo foram provenientes de medições de parcelas permanentes de inventários florestais contínuos (IFC) conduzidos em povoamentos de clones de eucalipto localizados no sul da Bahia, Brasil. O povoamento é composto de seis clones, compreendendo cerca de 4.000 árvores em 260 parcelas permanentes, com área média de 215 m², mensuradas em seis ocasiões (idades). Na Tabela 1 estão algumas estatísticas descritivas dos dados utilizados.

Tabela 1 - Estatísticas descritivas para as variáveis quantitativas observadas

Variável	Mínimo	Máximo	Média	Desvio-Padrão
<i>dap</i> (cm)	5,3	32,8	15,5	± 4,3
Idade (meses)	21	137	71	± 31
Altura dominante (m)	7,6	39	26	± 6,7
Altura total (m)	6,9	42,4	23,5	± 6,1

2.2 Alternativas de estimação da altura total

2.2.1 Relação hipsométrica

Para modelagem da relação hipsométrica realizou-se a estratificação em nível de projeto e clone. Para cada estrato ajustou-se o modelo proposto por Campos *et al.* (1984), descrito na Equação 1.

$$\ln(Ht) = \beta_0 + \beta_1 \left(\frac{1}{dap} \right) + \beta_2 \ln(Hd) + \varepsilon \quad \text{Eq. 1}$$

em que β_0 , β_1 e β_2 são os coeficientes do modelo, Ht é a altura total (m), dap é o diâmetro a 1,30 m de altura, Hd é a altura dominante (m) da parcela, \ln é o logaritmo neperiano e ε é o erro aleatório.

2.2.2 Redes Neurais Artificiais

Para estimar a altura total das árvores por meio de RNA, foram utilizados o *dap*, o diâmetro médio e máximo da parcela, a altura dominante da parcela e a idade como variáveis contínuas (quantitativas) e como variáveis categóricas (qualitativas), o projeto e o clone.

Para cada proporção dos dados de treinamento e generalização foram avaliadas as seguintes alternativas:

- i) Treinamento com o algoritmo *Resilient propagation*.
- ii) Treinamento com *Skip-layer connections* sem recorrência.
- iii) Treinamento com *Skip-layer connections* com recorrência.

O algoritmo *Resiliente propagation* foi escolhido como base de comparação ao método *Skip-layer connections*, com e sem recorrência, por ter demonstrado resultados superiores aos demais algoritmos de treinamento para RNA do tipo *Multilayer Perceptron* (MLP) em aplicações da mensuração florestal (BINOTI *et al.*, 2014).

Avaliou-se a quantidade de árvores utilizadas em cada estrato; esta quantidade foi reduzida gradativamente. A simulação consistiu no sorteio das seguintes proporções: 90, 80, 70, 60, 50, 40, 30, 20 e 10% das árvores para treinamento das Redes Neurais Artificiais e o restante dos dados (10, 20, 30, 40, 50, 60, 70, 80 e 90%, respectivamente) foi utilizado para a generalização, ou seja, para avaliar a capacidade de estimação das RNA para dados desconhecidos. Durante o sorteio, foram mantidas as proporções dos dados para cada parcela.

Foram treinadas 100 redes MLP para cada alternativa testada. A camada de entrada de todas as RNA foi constituída de 15 neurônios, sendo quatro correspondentes à quantidade de projetos, seis ao número de clones e um para cada variável numérica (altura dominante, idade, *dap* médio e *dap* máximo), totalizando mais quatro. O último neurônio da camada de entrada é um neurônio fixo, que representa o limiar de ativação ou *bias* (HAYKIN, 2001). As RNA possuíram somente uma camada oculta, com oito neurônios. A camada de saída foi constituída por um neurônio, equivalente à variável de interesse, e a função de ativação utilizada na camada oculta e na de saída foi a Logística (Sigmoid).

O *software* utilizado para o treinamento das RNA foi o NeuroForest 3.3 (BINOTI, 2012), que é gratuito e foi desenvolvido para uso no meio florestal, a fim de resolver os problemas específicos do setor. Os critérios para o *software* finalizar o treinamento foram: o erro quadrático médio igual a 0,0001 ou o número de épocas (ou iterações) igual a 3.000, finalizando quando alcançasse um dos dois critérios.

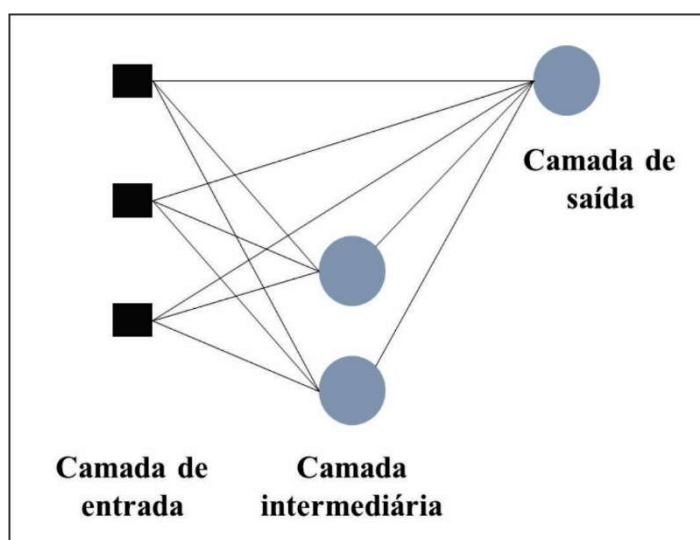
2.2.2.1 *Skip-Layer Connections*

Os neurônios artificiais podem estar ligados entre si de diferentes maneiras, possuindo, assim, diversas possibilidades de arquiteturas. Uma das arquiteturas é a do tipo *Multilayer Perceptron* (MLP), em que a rede neural possui uma camada de entrada, uma camada de saída

e pelo menos uma camada intermediária entre elas. As conexões do MLP são de tal forma que uma camada tem todos os seus neurônios ligados apenas às camadas adjacentes.

As redes MLP também podem possuir conexões especiais chamadas de *Skip-layer* (RIPLEY, 1996), que são conexões diretas de cada neurônio de entrada a cada neurônio de saída, ou seja, conexões que não passam pela camada oculta, dando mais flexibilidade às RNA, conforme exemplificado na Figura 1 (VELTEN, 2009). Essas RNA também podem possuir laços de realimentação entre os nós das mesmas camadas ou das camadas próximas, sendo chamados de recorrência.

Figura 1 – MLP com três neurônios de entrada, dois neurônios ocultos e um neurônio de saída, com três *skip-layer connections*



Fonte: adaptada de Matignon (2005).

2.3 Avaliação das estimativas

A análise dos resultados gerados pelas RNA e pela modelagem tradicional foi feita por meio do coeficiente de correlação entre as alturas observadas e as estimativas obtidas, os gráficos de dispersão dos erros relativos ($e\%$) e os histogramas de frequência percentual dos erros relativos. Os erros relativos para obtenção dos gráficos foram obtidos pela Equação 2.

$$e\% = \frac{(\hat{H}_i - H_i)}{H_i} \times 100 \quad \text{Eq. 2}$$

em que \hat{H}_i é altura estimada e H_i é a altura observada.

Também foi utilizada a raiz quadrada do erro quadrático médio (RQEM% - *Root Mean Square Error*) (Equação 3) para avaliar a diferença quadrática média entre os valores observados e estimados e para avaliar a variância dos resíduos (Equação 4).

$$RQEM(\%) = \frac{100}{\bar{H}} \sqrt{\frac{\sum_{i=1}^n (H_i - \hat{H}_i)^2}{n}} \quad \text{Eq. 3}$$

em que \bar{H} é a média das alturas totais observadas; e n é o número total de observações.

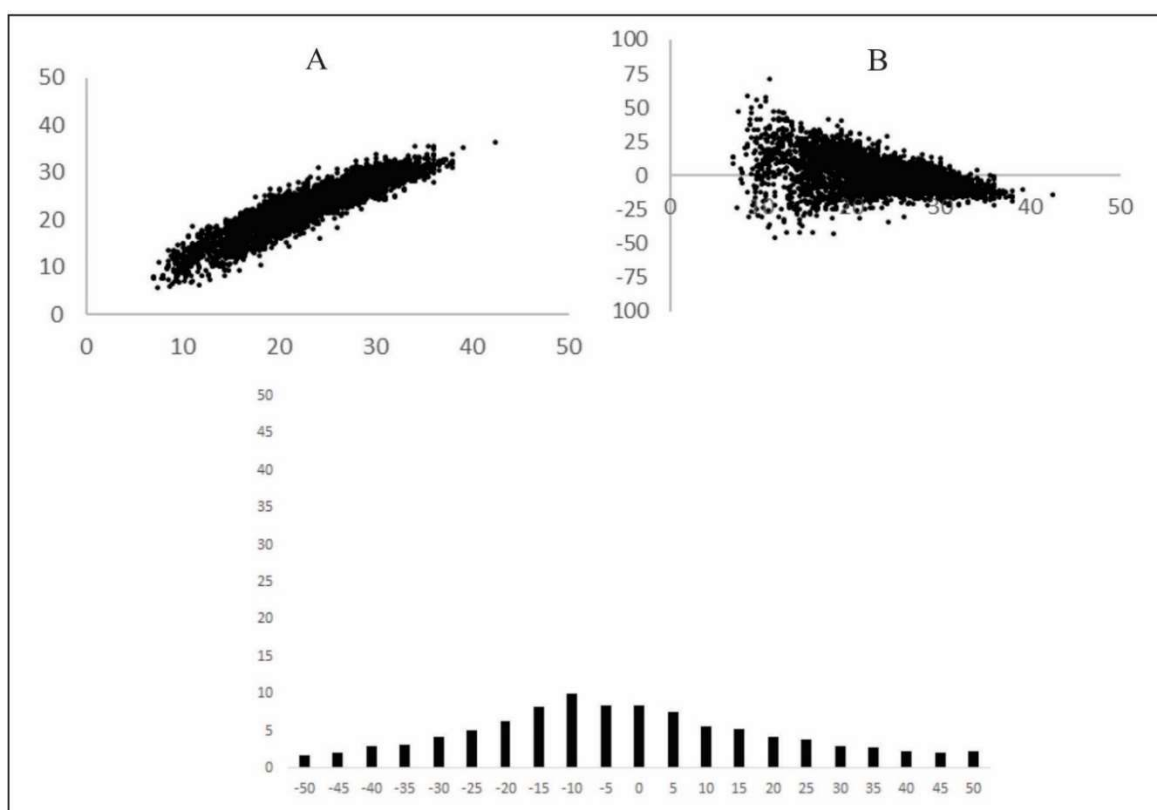
$$s_{e\%}^2 = \frac{\sum_{i=1}^n (e_{\%} - \bar{e}_{\%})^2}{n - 1} \quad \text{Eq. 4}$$

em que $s_{e\%}^2$ é a variância dos erros relativos; $e_{\%}$ é o erro relativo estimados na i -ésima observação e $\bar{e}_{\%}$ é a média dos erros relativos estimados.

3. RESULTADOS

Os gráficos de correlação e dispersão dos erros relativos e o histograma da frequência dos erros percentuais obtidos pelo ajuste do modelo hipsométrico estão na Figura 2. A correlação entre os valores observados das alturas totais e os obtidos por meio do modelo foi de 0,9189, a variância do resíduo foi de 147,2292 e o RQEM (%), 12,1531.

Figura 2 – (a) Gráfico de dispersão da relação alturas estimadas (m) pelo ajuste do modelo hipsométrico (eixo y) e alturas observadas (m) (eixo x); (b) gráfico de dispersão dos erros percentuais das alturas totais estimadas (m) pelo ajuste do modelo hipsométrico (eixo y), em função das alturas totais observadas (m) (eixo x); e (c) histograma de frequência percentual (eixo y) dos erros percentuais (eixo x) das estimativas de altura obtido pelo ajuste do modelo hipsométrico



Na Tabela 2 estão as estatísticas obtidas no treinamento e na generalização da melhor RNA (das 100 geradas) de cada alternativa testada para estimar a altura total.

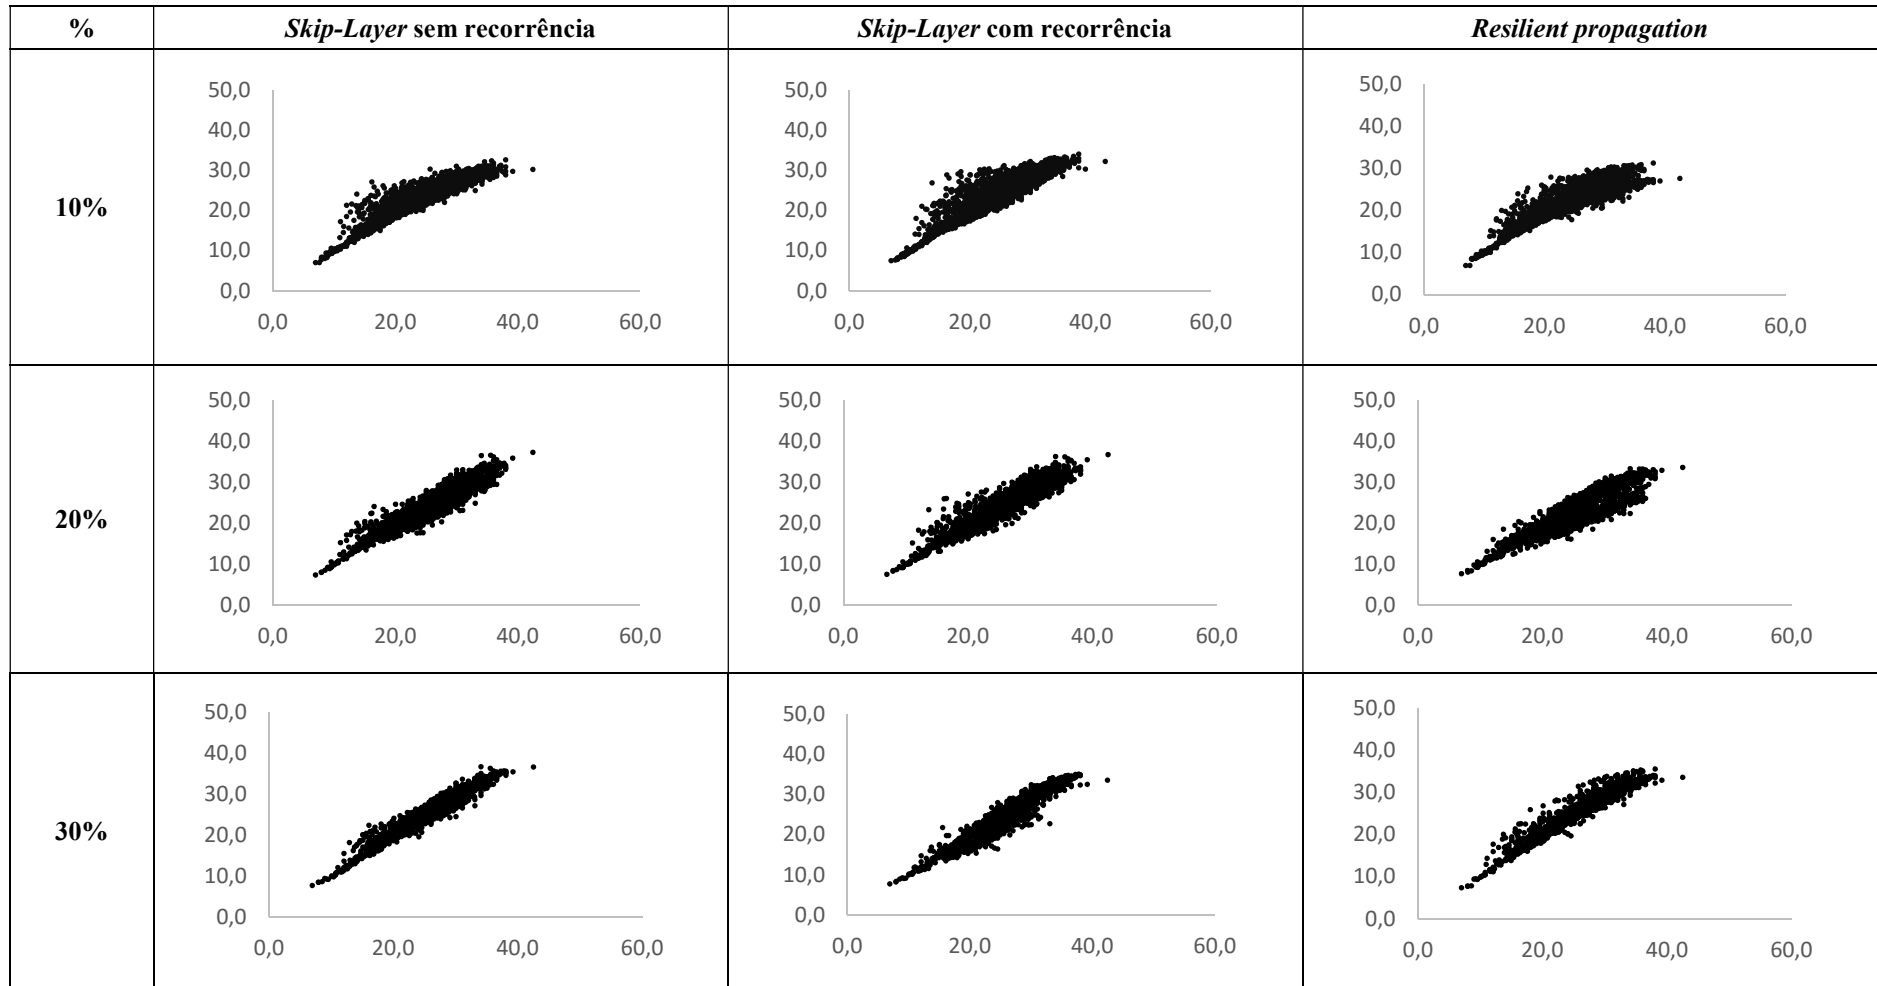
Na Figura 3 estão os gráficos da correlação altura observada x altura estimada para cada metodologia testada, obtidos pela generalização das RNA selecionadas por meio da análise das estatísticas e gráfica. Os gráficos de dispersão dos erros percentuais estão na Figura 4 e os histogramas de frequência percentual dos erros percentuais das estimativas das RNA para altura estão na Figura 5.

Tabela 2 - Estatísticas para dados de treinamento e generalização de cada alternativa de estimação da altura total

Tipo de RNA	% Treino	Treinamento			Generalização		
		r	$s^2_{e\%}$	RQEM%	r	$s^2_{e\%}$	RQEM%
<i>Skip-layer SR</i>	10	0,9954	6,1935	2,4840	0,9381	83,2997	9,6090
<i>Skip-layer CR</i>	10	0,9954	6,7070	2,5862	0,9236	101,1494	10,2765
<i>Resilient Prop.</i>	10	0,9954	6,6976	2,5852	0,9070	91,5153	11,6095
<i>Skip-layer SR</i>	20	0,9964	5,1712	2,2736	0,9419	48,5266	7,6368
<i>Skip-layer CR</i>	20	0,9964	5,5372	2,3522	0,9309	59,1381	8,1707
<i>Resilient Prop.</i>	20	0,9959	6,2073	2,4907	0,8822	75,5211	10,9744
<i>Skip-layer SR</i>	30	0,9954	6,9785	2,6418	0,9745	23,0580	4,8035
<i>Skip-layer CR</i>	30	0,9959	6,4276	2,5356	0,9574	32,4837	5,9905
<i>Resilient Prop.</i>	30	0,9940	9,6612	3,1074	0,9660	31,2141	5,5921
<i>Skip-layer SR</i>	40	0,9955	7,4933	2,7419	0,9760	17,7931	4,4239
<i>Skip-layer CR</i>	40	0,9959	6,3724	2,5249	0,9796	15,0078	4,1493
<i>Resilient Prop.</i>	40	0,9899	19,8272	4,4609	0,9599	35,1815	5,9342
<i>Skip-layer SR</i>	50	0,9950	8,8676	2,9799	0,9806	14,6645	3,8634
<i>Skip-layer CR</i>	50	0,9948	9,4391	3,0751	0,9782	16,1387	4,0946
<i>Resilient Prop.</i>	50	0,9956	7,3133	2,7055	0,9804	14,9812	3,8698
<i>Skip-layer SR</i>	60	0,9952	8,5663	2,9284	0,9849	12,8583	3,6364
<i>Skip-layer CR</i>	60	0,9937	10,6497	3,2648	0,9838	14,6742	3,8430
<i>Resilient Prop.</i>	60	0,9948	8,7304	2,9555	0,9847	13,6495	3,7056
<i>Skip-layer SR</i>	70	0,9940	9,6333	3,1056	0,9870	11,5323	3,4463
<i>Skip-layer CR</i>	70	0,9944	8,4844	2,9142	0,9884	11,3355	3,4217
<i>Resilient Prop.</i>	70	0,9940	10,7825	3,2862	0,9885	11,3104	3,4385
<i>Skip-layer SR</i>	80	0,9943	8,7911	2,9665	0,9895	11,1283	3,3344
<i>Skip-layer CR</i>	80	0,9941	9,4028	3,0682	0,9895	11,2514	3,3712
<i>Resilient Prop.</i>	80	0,9940	10,0676	3,1744	0,9905	9,8702	3,1790
<i>Skip-layer SR</i>	90	0,9934	10,7823	3,2857	0,9928	7,9794	2,8224
<i>Skip-layer CR</i>	90	0,9939	9,4958	3,0831	0,9932	8,4174	2,8994
<i>Resilient Prop.</i>	90	0,9928	12,4270	3,5273	0,9917	11,1261	3,3351

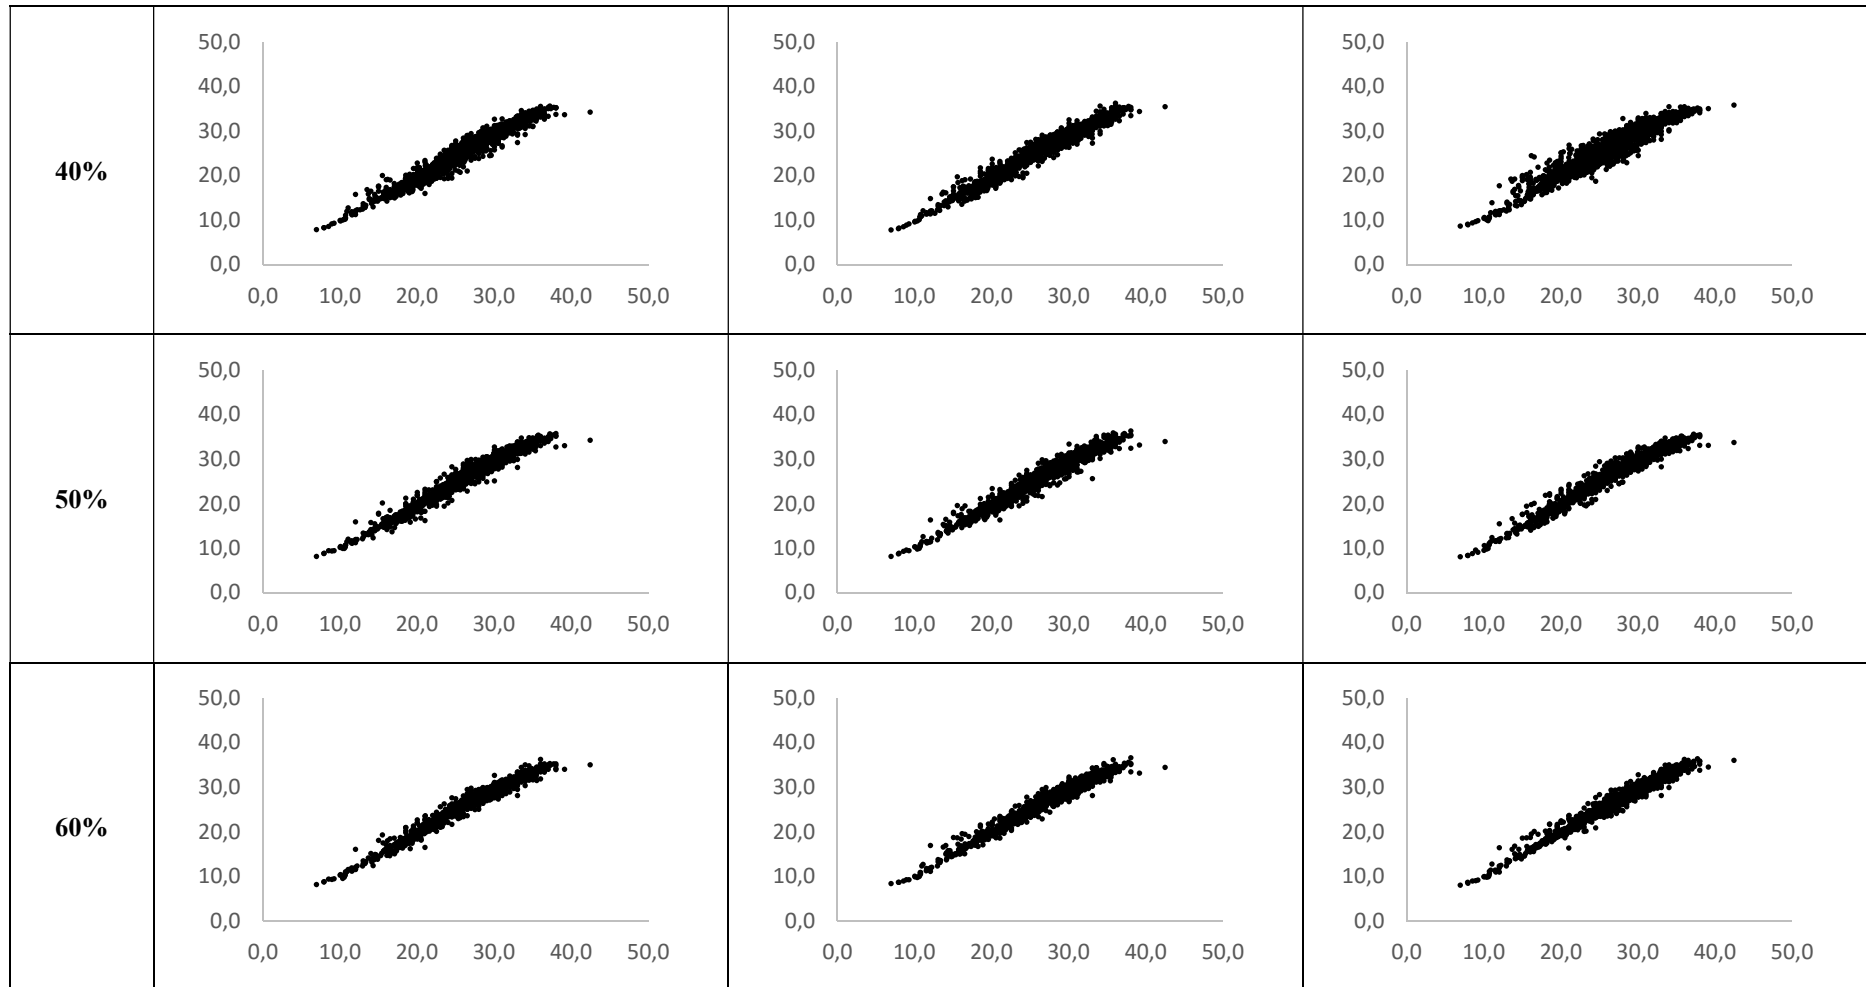
SR = sem recorrência; CR = com recorrência; Prop. = *Propagation*; r = coeficiente de correlação; s^2 = variância dos erros percentuais; e RQEM% = raiz quadrada do erro quadrático médio.

Figura 3 – Gráficos de dispersão da relação alturas estimadas (m) pelas RNA (eixo y) para o conjunto de generalização e alturas observadas (m) (eixo x)



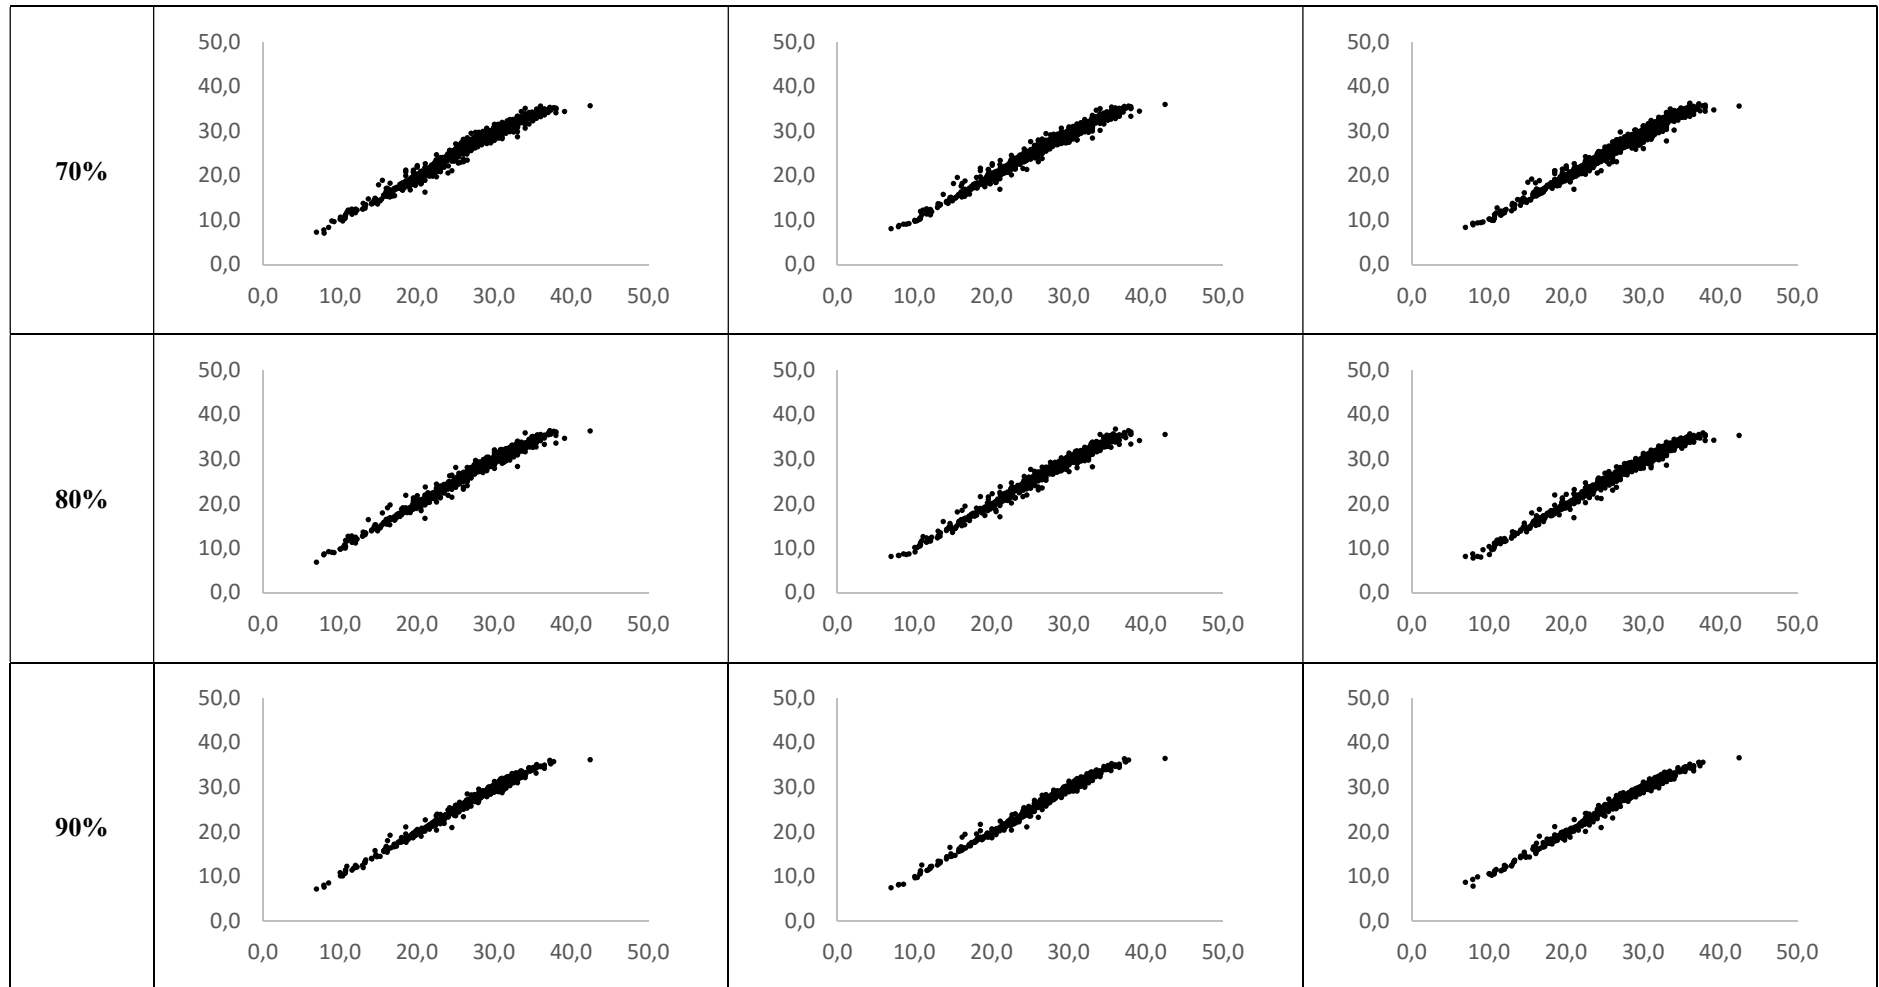
Continua...

Figura 3, Cont.



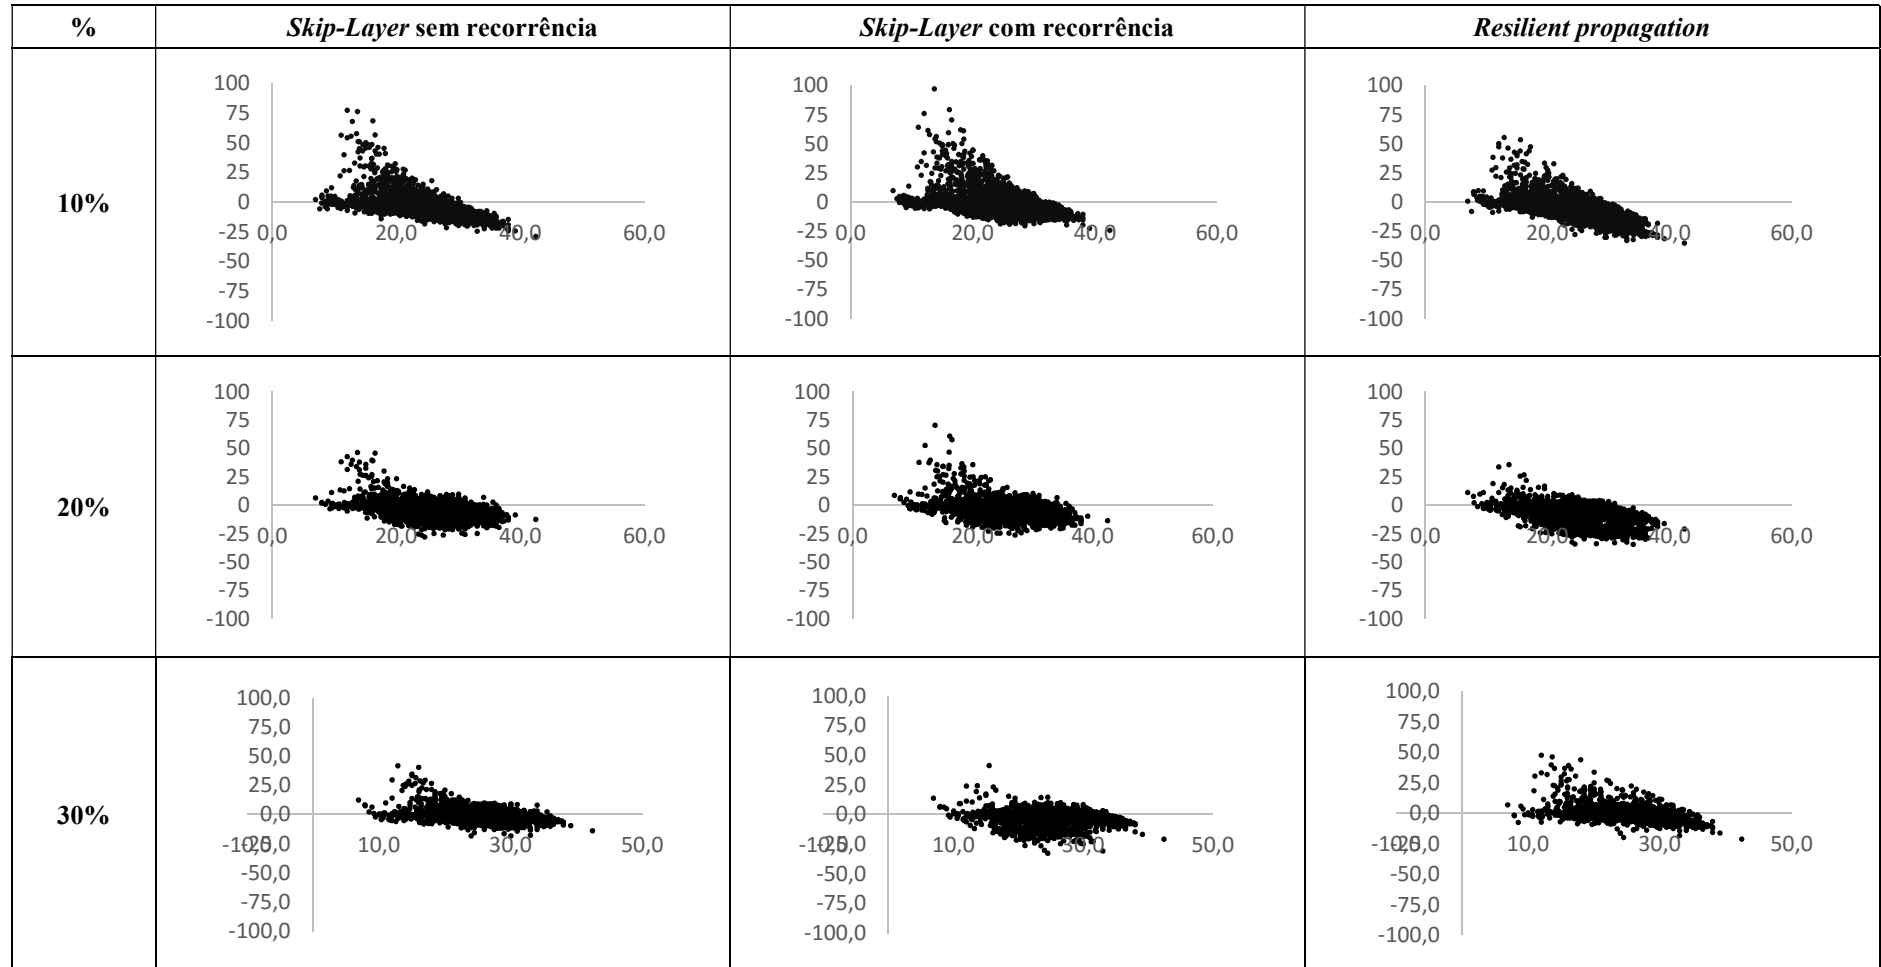
Continua...

Figura 3, Cont.



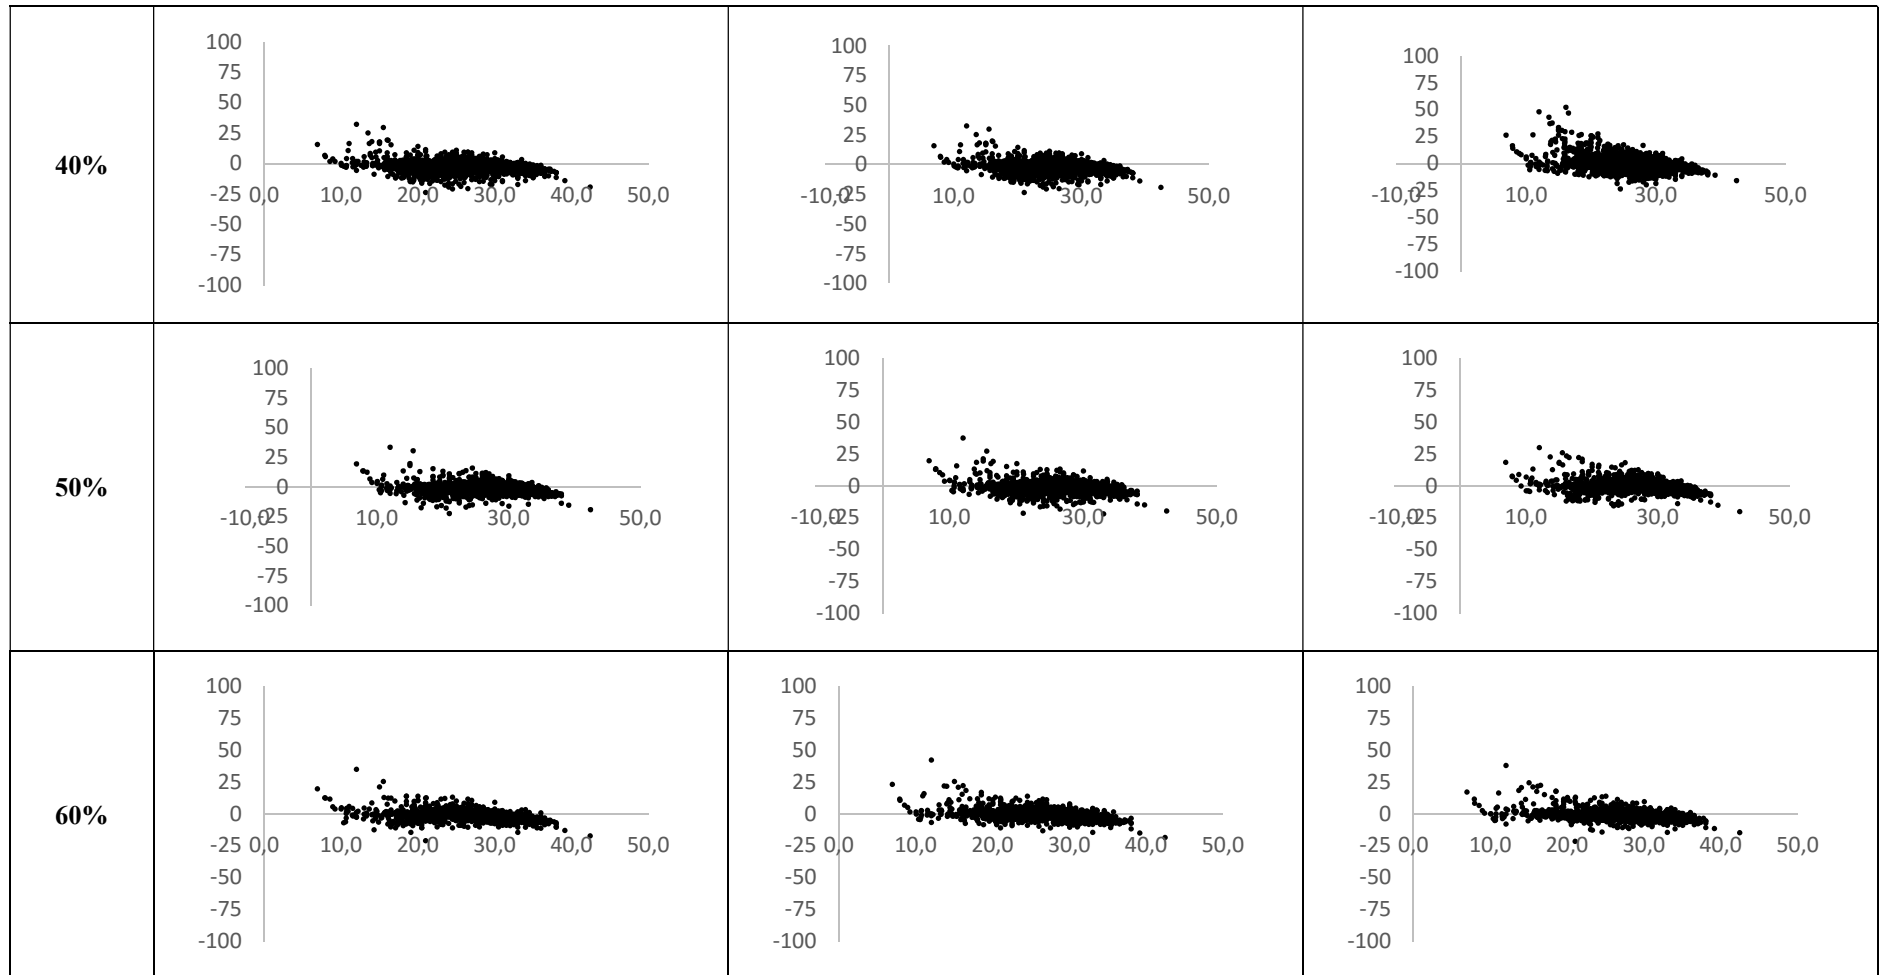
Continua...

Figura 4 – Gráficos de dispersão dos erros percentuais das alturas totais estimadas (m) pelas RNA (eixo y) para o conjunto de generalização, em função das alturas totais observadas (m) (eixo x)



Continua...

Figura 4, Cont.



Continua...

Figura 4, Cont.

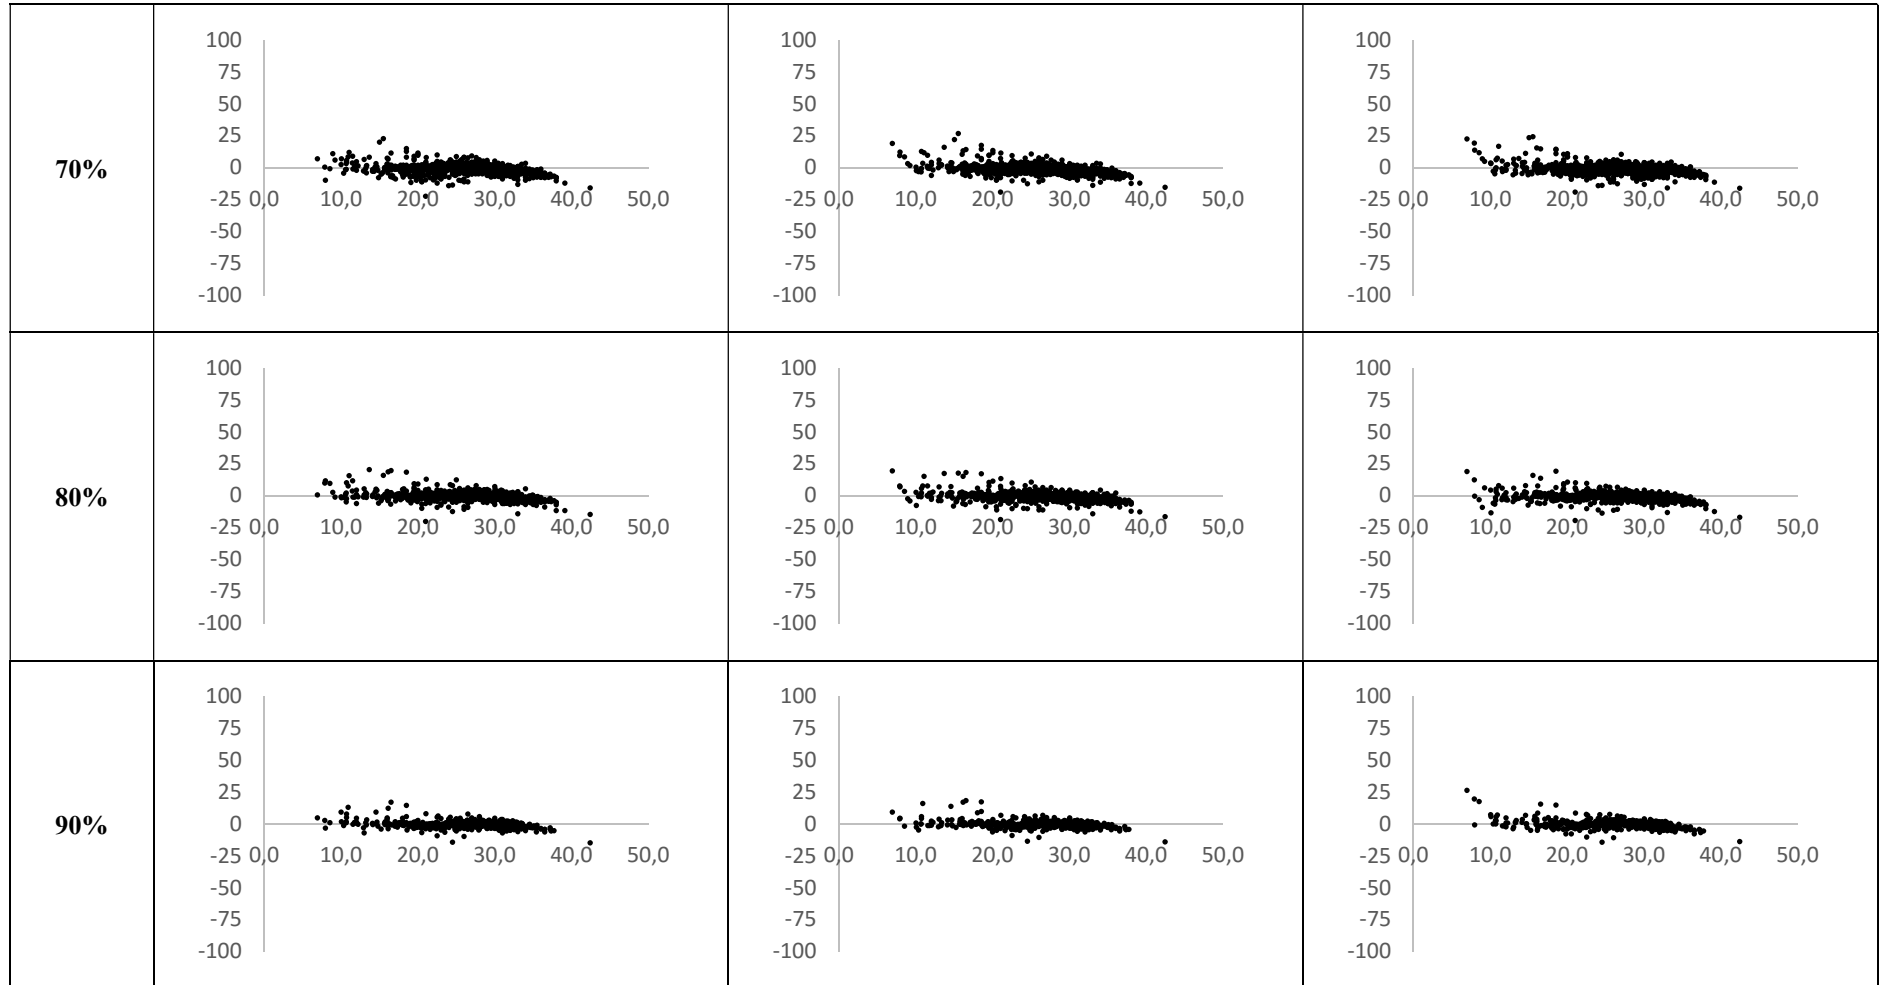
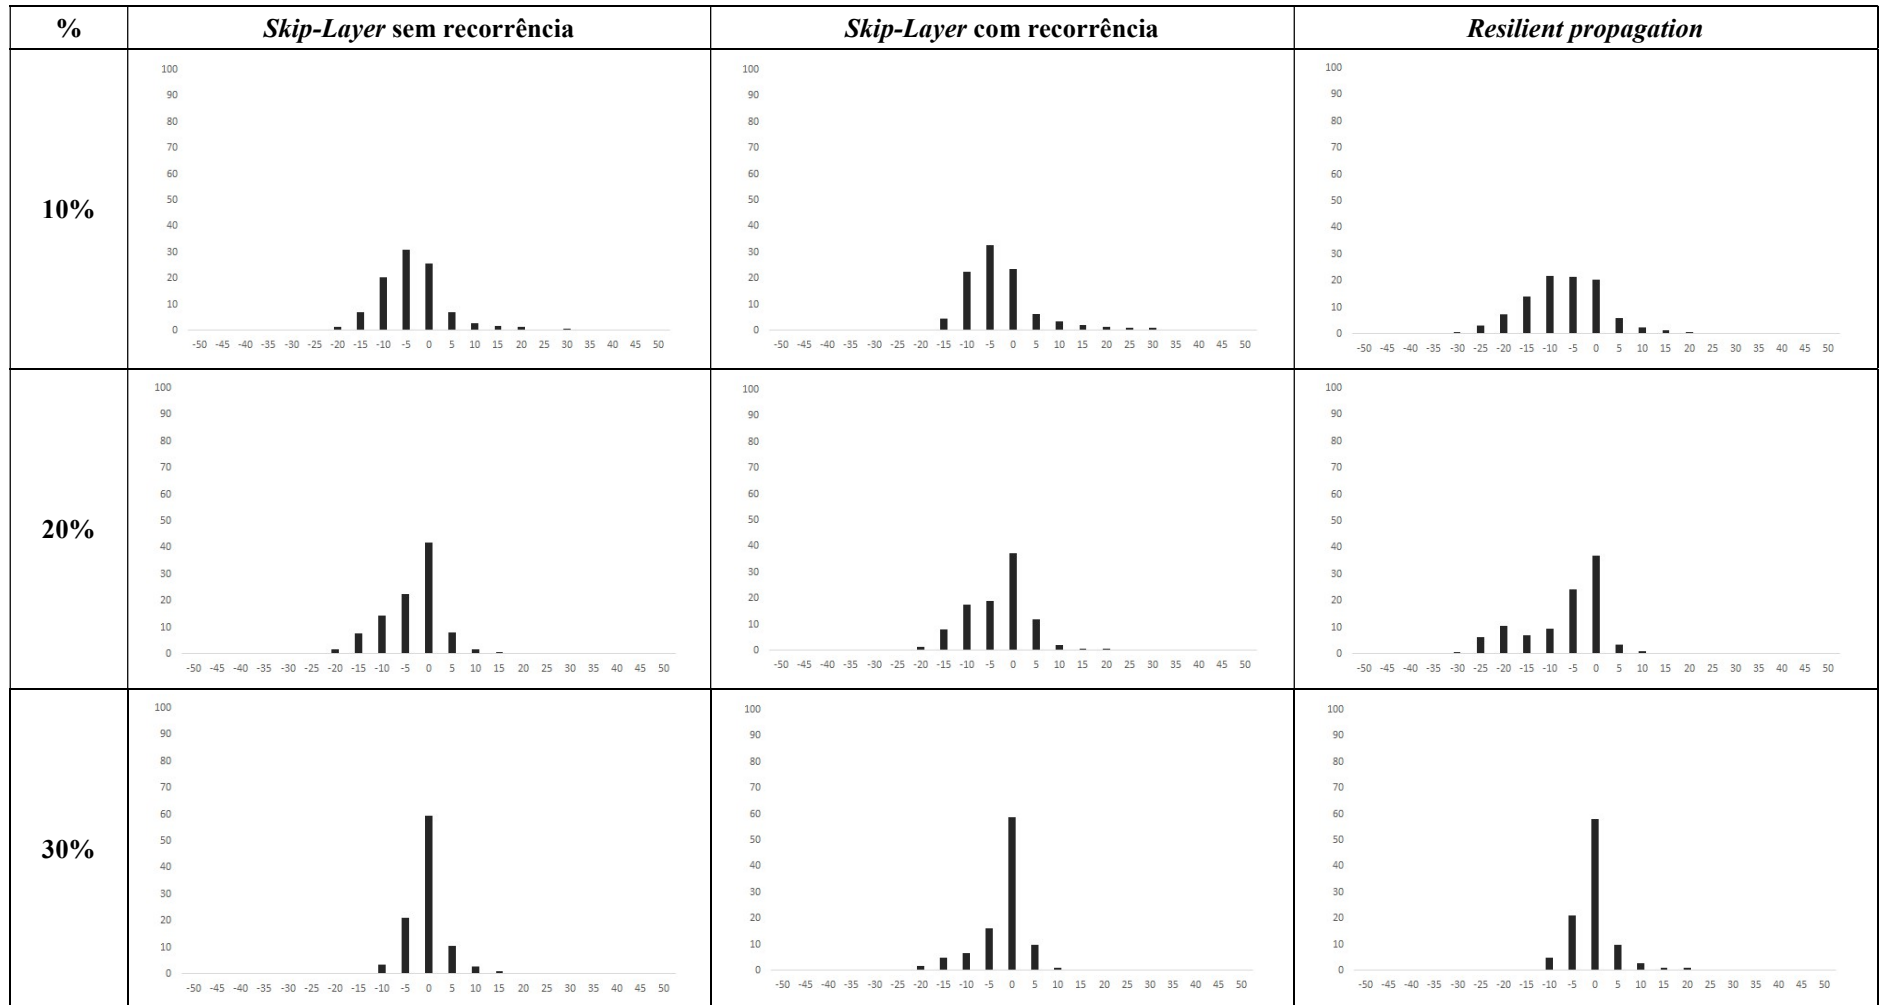


Figura 5 – Histogramas de frequência percentual (eixo y) dos erros percentuais (eixo x) das estimativas das RNA para altura total para o conjunto de generalização



Continua...

Figura 5, Cont.



Continua...

Figura 5, Cont.



4 DISCUSSÃO

O processo de mensuração da altura total de povoamentos florestais não é tão simples como a medição do *dap*. Essa altura é geralmente medida indiretamente com o auxílio de hipsômetros ou clinômetros que se baseiam em medidas de ângulos e distâncias. Além disso, esse processo de medição é dificultado pelas condições climáticas como o vento e a chuva e pela densidade populacional. Devido à dificuldade em medir a altura da árvore e ao custo associado à coleta de dados em campo, e por serem a altura e o diâmetro altamente correlacionados, é prática comum a utilização de modelos hipsométricos para estimação da altura das árvores. Esses modelos são, portanto, essenciais para estimação do estoque volumétrico e, por vezes, para determinação do índice de local e para descrever a dinâmica de crescimento do povoamento (CURTIS, 1967; CAMPOS; LEITE, 2013).

Como alternativa aos modelos hipsométricos, buscando o ganho de precisão e exatidão, além da redução da quantidade de medições de alturas em campo, alguns estudos recentes têm evidenciado a viabilidade de utilizar Redes Neurais Artificiais (RNA) (BINOTI *et al.*, 2013a; BINOTI *et al.*, 2013b; ÖZÇELİK *et al.*, 2013). Entretanto, a seleção da melhor RNA pode ser um processo demorado de tentativa e erro, por se tratar de um método aproximativo ou heurístico. Um método que tem demonstrado melhor o ajuste e a variação da estrutura convencional das RNA para aproximação de função (substituição de uma regressão) é o *Skip-layer connections*, que permite a comunicação direta através de conexões dos neurônios da camada de entrada até a camada de saída (RIPLEY, 1996; VELTEN, 2009; ARAÚJO, 2015).

Neste trabalho, comparou-se a estimação da altura total em função de variáveis do povoamento por meio do modelo hipsométrico mais utilizado na literatura científica e em empresas florestais brasileiras (CAMPOS; LEITE, 2013), com RNA ajustadas com o algoritmo *Resilient Propagation*, *Skip-layer connections*, com e sem recorrência. Constatou-se, pela análise gráfica dos resíduos (Figuras 3, 4 e 5) e pelas estatísticas apresentadas (Tabela 2) para os três tipos de RNA testadas, que os resultados foram satisfatórios em comparação à modelagem hipsométrica tradicional (Figura 2). Em todas as proporções testadas, o erro da estimação das alturas foi menor quando comparado ao da estimação obtida pelo modelo hipsométrico, que foi $\pm 50\%$. Pode-se afirmar que mesmo com somente 40% dos dados utilizados para treinamento obtém-se um bom resultado na aplicação da metodologia para os 60% dos dados restantes que não participaram do processo de treinamento (Figuras 3, 4 e 5).

A possibilidade de medir apenas 40% das alturas das parcelas acarreta economia considerável no custo e no tempo de realização do inventário florestal, uma vez que inúmeras parcelas são mensuradas anualmente.

O treinamento utilizando *Skip-layer connections* apresentou resultado similar ao da utilização da RNA com treinamento com algoritmo tradicional (*Resilient propagation*), conforme pode ser observado nas estatísticas apresentadas na Tabela 2. Houve ganho nas estimativas de altura com a utilização da recorrência pela técnica de *Skip-layer connections*.

A utilização de recorrência em uma RNA é indicada para sistema com maiores complexidades, uma vez que modifica toda a estrutura da rede neural, exigindo a presença de mais ligações e pesos, aumentando, conseqüentemente, o tempo de processamento computacional, atrelado ao ganho na sua capacidade de generalização (BINOTI, 2012).

A utilização da técnica *Skip-layer connections* para estimação da altura de povoamentos de eucaliptos é uma alternativa viável para aumentar a exatidão das estimativas de altura de árvores e redução da base de dados de inventário florestal.

5 CONCLUSÕES

A técnica de *Skip-layer connections* é eficiente para o treinamento de Redes Neurais Artificiais para estimação da altura de povoamentos equiâneos de eucalipto.

A proporção de 40% das alturas da parcela para o treinamento de RNA e 60% para a generalização apresentou resultados satisfatórios para estimação de altura de povoamentos equiâneos de eucalipto, o que resulta em significativa redução de tempo e custo do inventário florestal.

6 REFERÊNCIAS

ADAME, P.; del RÍO, M.; CAÑELLAS, I. A mixed nonlinear height–diameter model for pyrenean oak (*Quercus pyrenaica* Willd.). **Forest Ecology and Management**, v. 256, p. 88-98, 2008.

ARAÚJO, A. C. da S. C. **Redes neurais artificiais para quantificação volumétrica de florestas nativas no estado de Minas Gerais**. 2015. 75 f. Dissertação (Mestrado em Ciência Florestal) – Universidade Federal dos Vales do Jequitinhonha e Mucuri, Diamantina, MG, 2015.

AVERY, T. E.; BURKHART, H. E. **Forest management**. 4. ed. New York: McGraw-Hill, 1994. 432 p.

BARROS, D. A.; MACHADO, S. A.; ACERBI JÚNIOR, F. W.; SCOLFORO, J. R. S. Comportamento de modelos hipsométricos tradicionais e genéricos para plantações de *Pinus oocarpa* em diferentes tratamentos. **Boletim de Pesquisa Florestal**, Colombo, n. 45, p. 3-28, 2002.

BINOTI, M. L. M. S. **Emprego de redes neurais artificiais em mensuração e manejo florestal**. 2012. 130 f. Tese (Doutorado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa, MG, 2012.

BINOTI, M. L. M. da S.; BINOTI, D. H. B.; LEITE, H. G. Aplicação de redes neurais para estimação da altura de povoamentos equiâneos de eucalipto. **Revista Árvore**, v. 37, n. 4, p. 639-645, 2013a.

BINOTI, D. H. B.; BINOTI, M. L. M. da S.; LEITE, H. G.; SILVA, A. Redução dos custos em inventário de povoamentos equiâneos. **Revista Brasileira Ciências Agrárias**, v. 8, n. 1, p. 125-129, 2013b.

BINOTI, D. H. B.; BINOTI, M. L. M. da S.; LEITE, H. G. Configuração de redes neurais para estimação do volume de madeira. **Ciência da Madeira**, v. 5, n. 1, p. 59-67, 2014.

BRAGA, A. P.; CARVALHO, A. P. L. F.; LUDEMIR, T. B. **Redes neurais artificiais: teoria e aplicações**. 2. ed., Rio de Janeiro: LTC, 2007. 226 p.

CAMPOS, J. C. C.; RIBEIRO, J. O.; PAULA NETO, F. **Inventário florestal nacional, reflorestamento**: Minas Gerais. Brasília, DF: IBDF, 1984. 126 p.

CAMPOS, J. C. C.; LEITE, H. G. **Mensuração florestal: perguntas e respostas**. 4. ed. atual. ampl. Viçosa: Ed. UFV, 2013. 605 p.

CASTEDO-DORADO, F.; DIÉGUEZ-ARANDA, U.; BARRIO, M.; SÁNCHEZ, M.; GADOW, K. von. A generalized height-diameter model including random components for radiata pine plantations in northeastern Spain. **Forest Ecology and Management**, v. 229, p. 202-213, 2006.

COLBERT, K. C.; LARSEN, D. R.; LOOTENS, J. R. Height-diameter equations for thirteen midwestern bottomland hardwood species. **Northern Journal of Applied Forestry**. v. 19, n. 4, p. 171-176, 2002.

CRECENTE-CAMPO, F., TOMÉ, M., SOARES, P., DIÉGUEZ-ARANDA, U. A generalized nonlinear mixed-effects height-diameter model for *Eucalyptus globulus* L. in northwestern Spain. **Forest Ecology and Management**, v. 259, p. 943-952, 2010.

CURTIS, R. O. Height-diameter and height-diameter-age equations for second growth *Douglas-fir*. **Forest Science**, v. 13, p. 365-375. 1967.

FLEWELLING, J. R.; DE JONG, R. Considerations in simultaneous curve fitting for repeated height-diameter measurements. **Canadian Journal Forest Research**. v. 24, p. 1408-1414, 1994.

HAYKIN, S. **Redes neurais: princípios e prática**. 2. ed., Porto Alegre: Bookman, 2001. 854 p.

HUSCH, B.; BEERS, T. W.; KERSHAW JR., J. A. **Forest mensuration**. 4. ed. Hoboken, New Jersey: John Wiley & Sons, 2003. 443 p

INOUE, A.; YOSHIDA, S. Allometric model of the height–diameter curve for even-aged pure stands of Japanese cedar (*Cryptomeria japonica*). **Journal Forest Research**, v. 9, p. 325-331, 2004.

MATIGNON, R. **Neural network modeling using SAS enterprise miner**. Author House, 2005. 604 p.

MARTINS, E. dos R. **Configuração de redes neurais artificiais na mensuração florestal**. 2015. 62 f. Dissertação (Mestrado em Ciência Florestal) – Universidade Federal dos Vales do Jequitinhonha e Mucuri, Diamantina, MG, 2015.

ÖZÇELİK, R.; DIAMANTOPOULOU, M. J.; CRECENTE-CAMPO, F.; ELER, U. Estimating *Crimean juniper* tree height using nonlinear regression and artificial neural network models. **Forest Ecology and Management**, v. 306, p. 52-60, 2013.

PARRESOL, B. R. Bald cypress height-diameter equations and their prediction confidence intervals. **Canadian Journal Forest Research**, v. 22, n. 1429-1434, 1992.

RIPLEY, B. D. **Pattern recognition and neural networks**. 1. ed., Cambridge: Cambridge University Press, 1996. p. 144-172.

VELTEN, K. **Mathematical modeling and simulation: introduction for scientists and engineers**. Weinheim: Wiley-VCH, 2009. 364 p.