

VINÍCIUS ANDRADE DE BARROS

**ESTIMAÇÃO DE VARIÁVEIS DENDROMÉTRICAS EM POVOAMENTOS
ADENSADOS DE EUCALIPTO UTILIZANDO REDES NEURAIAS
ARTIFICIAIS**

Monografia, apresentada ao Departamento de Engenharia Florestal da Universidade Federal de Viçosa, como parte das exigências do curso de graduação em Engenharia Florestal.

VIÇOSA
MINAS GERAIS - BRASIL
JULHO – 2014

VINÍCIUS ANDRADE DE BARROS

**ESTIMAÇÃO DE VARIÁVEIS DENDROMÉTRICAS EM POVOAMENTOS
ADENSADOS DE EUCALIPTO UTILIZANDO REDES NEURAIAS
ARTIFICIAIS**

Monografia, apresentada ao Departamento de Engenharia Florestal da Universidade Federal de Viçosa, como parte das exigências do curso de graduação em Engenharia Florestal.

APROVADA: 27 de junho de 2014

Prof. Rafael Rode

Prof. Carlos Pedro Boechat Soares

Pesq. Daniel Binoti (Co-orientador)

Prof. Helio Garcia Leite (orientador)

VIÇOSA
MINAS GERAIS - BRASIL
JULHO – 2014

AGRADECIMENTOS

A minha família, especialmente aos meus pais, José Vicente Bezerra de Barros e Nilva Andrade, por todo apoio e suporte durante a graduação.

A minha namorada, Indyra, pessoa de importância ímpar em minha vida, que me ajudou de forma incomensurável em alguns dos momentos mais difíceis dela e quem eu amo extremamente.

Ao professor Helio Garcia Leite pela amizade, confiança, oportunidade e orientações gentilmente fornecidos.

Ao Daniel Binoti, pela valiosa ajuda e contribuições no presente trabalho.

A Universidade Federal de Viçosa e ao Departamento de Engenharia Florestal, pela minha formação profissional.

Aos amigos que conheci durante a graduação, em especial à turma de Engenharia Florestal de 2009, por terem ajudado a vencer esta etapa da minha vida.

Aos amigos de Viçosa, em especial à Bianca (Bibis), Marcelo, Rafael (Drummis) e Sérgio (Sergin), por sempre estarem ao meu lado, ajudando a crescer como pessoa.

Aos professores e a todos os funcionários do Departamento de Engenharia Florestal da UFV, pela grande contribuição na minha formação intelectual.

BIOGRAFIA

Vinícius Andrade de Barros filho de José Vicente Bezerra de Barros e Nilva Andrade nasceu em 31 de maio de 1989, em Viçosa, Minas Gerais.

Em 2003, concluiu o Ensino Fundamental no Colégio Normal Nossa Senhora do Carmo e em 2006 o Ensino Médio na Escola Estadual Doutor Raimundo Alves Torres, ambas em Viçosa, Minas Gerais.

Em março de 2009 iniciou o curso de Engenharia Florestal na Universidade Federal de Viçosa, sendo o mesmo concluído em agosto de 2014.

“Sanity is not statistical.”

George Orwell

EXTRATO

BARROS, Vinícius Andrade de. Monografia de Graduação. Universidade Federal de Viçosa, abril de 2014. **Estimação de variáveis dendrométricas em povoamentos adensados de eucalipto utilizando redes neurais.** Orientador: Helio Garcia Leite.

O objetivo deste estudo foi treinar, testar e validar a eficiência de redes neurais artificiais (RNA) para realizar a estimação de altura e volume de árvores em povoamentos adensados de eucalipto. Os dados utilizados foram provenientes de plantios realizados em dezembro de 2002 na região do Alto Jequitinhonha, em Minas Gerais. O delineamento experimental foi dividido em blocos (três blocos), sendo testados cinco arranjos espaciais diferentes (3,0 x 0,5; 3,0 x 1,0; 3,0 x 1,5; 3,0 x 2,0; e 3,0 x 3,0 m). Foram utilizadas variáveis numéricas, como altura e diâmetro com e sem casca. Os dados foram divididos de forma aleatória em três grupos: treinamento (60%), teste (20%) e validação (20%). Os dados de treinamento foram utilizados para criar as redes neurais, do tipo perceptrons de múltiplas camadas (MLP) com o software *NeuroForest 3.0*. As RNAs de melhor desempenho no treinamento e teste foram selecionadas para realizar a sua validação. Para se comparar a eficiência das RNAs foram utilizados os modelos de *Husch, Hohenald e Kreen* e *Schumacher e Hall* para estimar o volume e para a altura total foram ajustadas as equações $\ln H = \beta_0 + \beta_1 \times \ln DAP + \varepsilon_i$ e $\ln H = \beta_0 + \beta_1 \times DAP^{-1} + \varepsilon_i$. Sendo que o modelo de *Schumacher e Hall* e a equação $\ln H = \beta_0 + \beta_1 \times DAP^{-1} + \varepsilon_i$ tiveram melhor resposta ao descrever a relação volumétrica e hipsométrica nos arranjos espaciais

estudados. A comparação da eficiência das RNAs com as regressões se deu pela avaliação dos seus erros quadráticos médios (RMSE %) e correlação entre valores observados e estimados ($r_{Y\hat{Y}}$) além da análise gráfica dos resíduos. Conclui-se que as Redes Neurais Artificiais são eficientes para estimar com exatidão tanto o volume de árvores individuais quanto para projeção de altura total em povoamentos adensados.

Sumário

EXTRATO	iv
1- INTRODUÇÃO	1
2- MATERIAL E MÉTODOS	4
2.1- Descrição dos dados	4
2.2- Cálculo e ajuste do volume total por regressão.....	5
2.3- Ajustes de equações para estimar a altura.....	6
2.4- Redes Neurais Artificiais	7
2.4.1- Treinamento das redes neurais artificiais	7
2.4.2- Teste e validação das redes neurais artificiais.....	8
2.4.3- Avaliação da qualidade das redes neurais artificiais.....	8
3- RESULTADOS E DISCUSSÕES	10
3.1- Estimativa volumétrica.....	10
3.2- Altura de árvores	20
4- CONCLUSÕES.....	27
5- REFERÊNCIAS BIBLIOGRÁFICAS	28

1- INTRODUÇÃO

Desde o seu surgimento, a energia elétrica foi sinal de desenvolvimento econômico local. No Brasil, a política energética nacional foi feita de forma monopolista de empresas estatais com grande investimento governamental. Com isso o processo de expansão do sistema elétrico ocorreu de forma rápida, porém desuniforme (OLIVEIRA et al., 1998). Fato este que levou o País a um aumento da diferença do padrão de vida entre as diferentes regiões.

Talvez o meio mais eficaz de diminuir essa desigualdade seria a descentralização da geração de energia, aproveitando fontes renováveis, como: energia eólica; energia solar; energia de biomassa; e pequenas centrais hidrelétricas. A principal vantagem da utilização desses tipos de recursos é a possibilidade de utilização de recursos locais e a flexibilidade de suprimento energéticos em diferentes escalas (OLIVEIRA,2003).

Desta forma, a utilização da biomassa na geração de energia surge como uma tendência mundial, reduzindo as emissões de gases nocivos à atmosfera, assim como uso de combustíveis derivados de fontes fósseis. O plantio de florestas energéticas é considerado um dos melhores meios de se obter insumos para a geração de energia elétrica, uma vez que o sistema de produção aproveita apenas a madeira cortada, deixando resíduos culturais (como galhos, folhas e ponteiros) no local e devolvendo nutrientes para o solo (MULLER, 2005).

Na década de 70 a técnica de plantio adensado de Eucalipto foi amplamente utilizada, com alguns plantios tendo próximos de 40.000 mudas por hectare. Estes

plantios tinham por finalidade a maior produção de biomassa por hectare em um menor espaço de tempo. No entanto, os resultados não foram muito positivos, devido à falta de conhecimento técnico e baixa qualidade silvicultural e genética (MULLER, 2005).

Com o uso de novas espécies, melhores práticas silviculturais e de manejo implantados no final dos anos 80 foi possível se obter grandes ganhos de produtividade dos plantios (COUTO, 1995).

Segundo dados da ABRAF (2013), atualmente a área plantada de Eucalipto destinado a produção de energia corresponde a aproximadamente 19,5% dos 5,10 milhões de hectares plantados no Brasil, sendo um dos maiores responsáveis, pela geração de energia derivada da biomassa, juntamente com o bagaço da cana-de-açúcar.

No manejo florestal, deve-se ter o conhecimento de três elementos essenciais, a classificação de terra, estabelecimento de prescrições e a prognose. A prognose envolve predição ou projeção de estoques de colheita, o que usualmente é feito empregando modelos de crescimento e produção ou técnicas de inteligência artificial. Dados para gerar esses modelos são obtidos de parcelas permanentes e de árvores-amostra abatidas para cubagem nos povoamentos. Para obter o volume das árvores existentes nas parcelas permanentes são empregadas equações de volume, de afilamento (*taper*) ou, também, técnicas de inteligência artificial.

Para se estimar o volume das árvores geralmente se usa a correlação entre o volume total com variáveis mensuráveis em campo como altura e diâmetro a 1,3 metros de altura. Dentre os modelos, estão: *Husch, Hohenald e Kreen* e *Schumacher e Hall*, sendo este último o mais difundido, talvez por que suas estimativas são quase sempre não tendenciosas (CAMPOS E LEITE, 2009).

A estimação da altura das árvores tem um custo significativo no inventário florestal, devido, além da própria operacionalização dos instrumentos, aos fatores como a falta de visibilidade do topo da árvore e a ocorrência de ventos na região, que dificultam a sua medição. Ker e Smith (1957) propuseram que a partir da medição dos DAPs e das alturas de algumas árvores da parcela se estimasse a altura das demais.

Outras formas de se projetar o volume e a altura das árvores é através do emprego de modelos de redes neurais artificiais (RNA) ou de máquinas vetor de suporte (MSV). A aplicação de RNA tem uma série de vantagens como: não-linearidade; mapeamento de entrada-saída; adaptabilidade; tolerância a falhas; uniformidade de análise projeto; analogia neurobiologia; entre outros (HAYKIN, 2001; BULLINARIA, 2013).

O uso de RNA tem sido divulgado para diferentes propósitos na mensuração florestal, como: modelagem do afilamento (LEITE *et al.*, 2011); volume de casca (DIAMANTOPOULOU, 2005); volume de árvores; modelagem em nível de povoamento, modelagem por classe de diâmetro e estimação da altura (BINOTI, 2010; BINOTI, 2012); estimação de biomassa e de carbono (FERRAZ, 2012).

Apesar dos vários estudos já divulgados, sobre o emprego de RNA na mensuração e manejo florestal, principalmente no Brasil, ainda não foi reportada a eficiência de seu uso em povoamentos adensados, seja para quantificar o volume, massa ou carbono fixo, bem como para modelagem do crescimento e da distribuição diamétrica. Portanto, o objetivo deste trabalho visa treinar, aplicar e validar redes neurais artificiais na obtenção de relações hipsométricas e estimativas de volume em plantios adensados de eucalipto.

2- MATERIAL E MÉTODOS

2.1- Descrição dos dados

Os dados utilizados neste estudo originam de um experimento sobre espaçamento inicial entre árvores em povoamentos de clones de eucalipto (híbrido de *Eucalyptus grandis* x *Eucalyptus camaldulensis*), tendo sido implantado em dezembro de 2002 no município de Itamarandiba, na região do alto do Jequitinhonha, Minas Gerais. A altitude da local varia entre 600 e 1000 m. O clima é classificado como subtropical úmido subúmido. A temperatura média anual varia de 19° a 20°C, sendo que a média mínima é de 15,5°C e a média máxima de 24°C. A precipitação média varia de 1150 a 1450 mm com um período de 4 a 6 meses de seca apresentando déficit hídrico de 60 a 120 mm anuais.

O delineamento experimental foi do tipo blocos casualizados com cinco tratamentos e três blocos. Em todos os tratamentos a distância entre linhas foi a mesma (3 metros), variando a distância entre árvores de 0,5 a 3 metros. Assim, os espaçamentos foram: 3,0 x 0,5 m; 3,0 x 1,0 m; 3,0 x 1,5 m; 3,0 x 2,0 m; e 3,0 x 3,0 m.

Foram realizadas cubagens de 185 árvores (Tabela 1) com idades de 48, 61, 77, 85 e 102 meses, medindo os diâmetros do fuste nas posições: 0,1 m (base); 0,3 m; 0,7 m; 1,3 m; 2,0 m; e após os 2 metros foi feita medições de 1 em 1 metro até o diâmetro mínimo de aproximadamente 5.

Tabela 1: Análise descritiva das variáveis numéricas das árvores abatidas para cubagem em Itamarandiba-MG, 2002.

Tratamentos	Arranjo espacial	Volume			Altura			Número de indivíduos
		Mín.	Méd.	Máx.	Mín.	Méd.	Máx.	
1	3,0 x 0,5	0,0035	0,0338	0,0989	10,2	18,5	25,4	35
2	3,0 x 1,0	0,0133	0,0562	0,1401	13,9	21,5	27,3	36
3	3,0 x 1,5	0,0203	0,1107	0,2678	15,4	24,5	29,0	40
4	3,0 x 2,0	0,0159	0,1179	0,2463	15,6	24,8	28,8	36
5	3,0 x 3,0	0,0697	0,1834	0,3801	21,2	27,7	30,5	38
Geral	-	0,0035	0,1019	0,3801	10,2	23,5	30,5	185

O banco de dados final consiste em cinco tratamentos distintos com 35 a 40 árvores contendo informações de Altura total, DAP e Volume com e sem casca, totalizando 185 árvores.

2.2- Cálculo e ajuste do volume total por regressão

Para determinar os valores de volume dos fustes com e sem casca foi empregada à expressão de *Smalian* (HUSCH et al, 1972) (eq. I), através dela é possível se obter o volume de cada seção medida. O somatório de todos estes volumes é o volume inteiro da árvore.

$$V = \frac{AS_1 + AS_2}{2} \times L \quad (I)$$

Em que:

V = volume (com ou sem casca) da seção, em m³;

AS_1 e AS_2 = áreas seccionais (com ou sem casca), obtidas nas extremidades da seção, em m²;

L = comprimento da seção, em m.

Com posse dos dados de cubagem e os volumes calculados, foram ajustadas as equações de *Husch* (II), *Hohenald e Kreen* (III) e *Schumacher e Hall* (IV) para estimar o volume dos fustes,

$$V = \beta_0 \times DAP^{\beta_1} + \varepsilon_i \quad (\text{II})$$

$$V = \beta_0 + \beta_1 \times DAP + \beta_2 \times DAP^2 + \varepsilon_i \quad (\text{III})$$

$$V = \beta_0 \times DAP^{\beta_1} \times Ht^{\beta_2} + \varepsilon_i \quad (\text{IV})$$

Em que:

V = volume (com ou sem casca) do fuste, em m³;

β_i = parâmetro ($i = 0, 1, 2$);

DAP = diâmetro (com ou sem casca) a altura de 1,3m;

ε_i = erro aleatório, sendo $\varepsilon \sim NID(0, \sigma^2)$.

2.3- Ajustes de equações para estimar a altura

Também serão ajustadas as equações (V) e (VI) com a finalidade de estimar as alturas total das árvores.

$$\ln H = \beta_0 + \beta_1 \times \ln DAP + \varepsilon_i \quad (\text{V})$$

$$\ln H = \beta_0 + \beta_1 \times DAP^{-1} + \varepsilon_i \quad (\text{VI})$$

Em que:

Ht = altura total da árvore;

\ln = logaritmo neperiano;

β_i = parâmetro ($i = 0, 1, 2$);

DAP = diâmetro a altura de 1,3m;

ε_i = erro aleatório, sendo $\varepsilon \sim NID(0, \sigma^2)$.

Todos os modelos foram ajustados utilizando o *software* Statistica 12.0 (STATSOFT, INC, 2012), empregando o procedimento Gauss-Newton, pelo método dos mínimos quadrados.

Foi feita a estimativa geral, de modo a ajustar as equações para todo o banco de dados. Em seguida, o modelo de que apresentou o melhor resultado foi selecionado para fazer a regressão para cada tratamento.

2.4- Redes Neurais Artificiais

Para o emprego das RNAs, o banco de dados foi dividido aleatoriamente em três conjuntos, um para o treinamento (60%), um para teste (20%) e um para validação das redes (20%). As redes foram criadas utilizando o software gratuito *NeuroForest* 3.0 (Projeto NeuroForest).

2.4.1- Treinamento das redes neurais artificiais

Durante o treinamento de uma RNAs os pesos sinápticos são calibrados, com base nas características obtidas do banco de dados fornecido para o algoritmo de aprendizagem, de forma a gerar uma rede com a capacidade de prever o comportamento das informações, neste caso as redes deveriam projetar o volume (com e sem casca) e a altura dos fustes.

Na camada de entrada das redes para estimativa da altura do fuste foram utilizadas as informações dos tratamentos, blocos e DAP, enquanto nas redes para estimativa de volume, além destas informações, a altura total do fuste e diâmetros sem casca também foi utilizadas.

Após a seleção dos dados para o treinamento das RNAs o software faz a normalização dos dados. Esta etapa consiste na transformação de cada variável numérica em valores entre 0 e 1, impedindo que variáveis com valores muito altos influencie as estimativas.

As redes treinadas foram do tipo *perceptrons* de múltiplas camadas (MLP), onde duas camadas (intermediária e de saída) processam os dados enquanto a camada de entrada apenas os recebe (HAYKIN, 2001). O número de neurônios na camada oculta variou entre 3 e 11, caso a rede com 11 neurônios apresentasse o melhor erro quadrático médio (RMSE (%)) seria realizado o treinamento com mais neurônios até o ponto que o número de neurônios não fosse o limitador da qualidade do treinamento.

As RNAs treinadas são do tipo ântero-alimentadas utilizando o algoritmo *Resilient Propagation* (RPROP+), que realiza uma adaptação das atualizações de peso de acordo com o comportamento da função de erro (RIEDMILLER E BRAUN, 1993). A função de ativação empregada nas camadas de entrada, oculta e de saída do tipo sigmoidal.

O critério de parada foi erro médio ou número de ciclos, com os parâmetros variando entre 0,001 e 0,003 no erro médio e entre 1000 e 3000 no número de ciclos.

No total foram treinadas 20 redes para cada número de neurônios, para valores com casca e sem casca, resultando em 360 RNAs para a projeção de volume e 360 para a projeção de altura. Em seguida, com base no RSME (%) e correlação entre observado e estimado, foram pré-selecionadas 360 RNAs (10 melhores para cada número de neurônios na camada oculta para volume e altura com e sem casca) para serem testadas e validadas.

2.4.2- Teste e validação das redes neurais artificiais

A validação das RNAs visa avaliar a capacidade das redes treinadas em produzir saídas adequadas para entradas que não estavam presentes na etapa de treinamento. Nesta etapa foi utilizado 20% do banco de dados original. Após a validação, foi realizado o teste das RNAs com os 20% dos dados restantes de forma a confirmar a validação cruzada.

As 3 RNAs com menores valores de RMSE (%) e maior correlação entre os valores observados e estimados de cada análise foram selecionadas para comparação com os valores estimados através da regressão.

2.4.3- Avaliação da qualidade das redes neurais artificiais

Após o treinamento, teste e validação, todas as RNAs foram avaliadas através da análise dos erros quadráticos médios (RMSE (%)) e das correlações entre valores observados e estimados ($r_{Y\hat{Y}}$) (eq. VII e VIII).

$$RMSE (\%) = \frac{100}{\bar{Y}} \times \sqrt{\frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n}} \quad (\text{VII})$$

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

Em que:

\bar{Y} = média dos valores observados;

Y_i = valores observados;

\hat{Y}_i = valores estimados;

n = número total de observações

s^2 = variância;

cov = covariância.

A correlação indica a força e direção da relação entre o valor observado e estimado de determinada variável. Embora não seja possível concluir sobre a qualidade de uma rede apenas com esta informação, ela é útil para se saber o grau de associação entre os valores. O erro quadrático médio indica a precisão das estimativas através da avaliação da diferença quadrática média dos valores observados e estimados.

Para a análise gráfica foram avaliados os erros percentuais dos valores estimados em relação aos observados, seguindo a seguinte equação (IX):

$$erro_{\%} = \frac{(\hat{Y} - Y)}{Y} \times 100 \quad (\text{IX})$$

Em cada arquitetura de cada tratamento foram selecionadas as três redes que tiveram os melhores resultados. Na etapa seguinte as melhores RNAs foram comparadas com os dados estimados através da regressão, tanto para os modelos de volume quanto para os hipsométricos.

3- RESULTADOS E DISCUSSÕES

3.1- Estimativa volumétrica

Dentre as 360 arquiteturas treinadas, foram selecionadas as 6 com melhores RMSE (%) e $r_{Y\hat{Y}}$ do conjunto de validação, sendo 3 arquiteturas para as projeção de volume com casca e 3 para projeção de volume sem casca (Tabela 2).

Tabela 2: Características e precisão das RNAs selecionadas para projetar o volume.

Tipo	RNA	Arqui- tutura	Treinamento		Teste		Validação	
			RMSE (%)	$r_{Y\hat{Y}}$	RMSE (%)	$r_{Y\hat{Y}}$	RMSE (%)	$r_{Y\hat{Y}}$
Com Casca	1	5-5-1	16,53	0,9762	14,56	0,9812	12,82	0,9819
	2	5-10-1	15,28	0,9797	13,85	0,9831	12,86	0,9819
	3	5-11-1	15,01	0,9804	15,18	0,9797	13,00	0,9816
Sem Casca	4	5-6-1	18,65	0,9720	16,80	0,9770	15,47	0,9754
	5	5-9-1	18,82	0,9714	16,49	0,9781	15,87	0,9739
	6	5-10-1	18,52	0,9723	16,15	0,9785	16,84	0,9710

Onde: Arq. = número de neurônios em cada camada; RMSE (%) = erro quadrático médio; $r_{Y\hat{Y}}$ = correlação entre observado e calculado; Treinamento, Teste e Validação = conjunto de dados utilizado.

A partir dos valores de correlação obtidos é possível observar que apenas 2 RNAs treinadas (RNA 3 e 6) resultaram em valores menores de teste ou validação em relação ao treinamento, o que poderia indicar a presença de supertreinamento destas redes, ou seja, elas não seriam eficientes quando utilizadas em outros bancos de dados além do qual foram treinadas. Apesar de apresentar um valor de correlação na etapa de validação menor que o de treinamento, a RNA 6 apresentou um erro quadrático médio menor na validação em relação ao encontrado no treinamento.

As RNAs que obtiveram melhor desempenho para a projeção de volume foram as RNAs 2 (com médias de RMSE (%) = 14.00 e de $r_{Y\hat{Y}} = 0.9816$) e 4 (com médias de RMSE (%) = 16.98 e de $r_{Y\hat{Y}} = 0,9748$), na estimativa de volume com e sem casca respectivamente. É possível observar que além de mais precisas, conforme as estatísticas, estas redes apresentaram uma distribuição de resíduos mais homogênea em relação as demais (Figuras 1 e 2), de tal forma que as RNAs 2 e 4 serão as utilizadas para estimar o volume para cada tratamento.

A análise comparativa dos erros quadráticos médios e correlação entre valores observados e estimados obtidos com as RNAs (Tabela 2) e os calculados através das regressões ajustadas a partir do banco de dados total das 185 árvores (Tabela 3) possibilita a inferência sobre a qualidade das RNAs treinadas.

Tabela 3: Parâmetros dos modelos de *Husch*, *Hohenald e Kreen* e *Schumacher e Hall* para estimativa de volume com e sem casca.

		Husch	Hohenald e Kreen	Schumacher e Hall
Volumes c/ casca	β_0	0,00006433	0,04539224	0,00000511
	β_1	2,87225944	-0,01475659	2,32264243
	β_2		0,00147519	1,21887189
	$r_{Y\hat{Y}}$	0,9728	0,9736	0,9752
	RMSE (%)	17,61	17,35	16,84
Volumes s/ casca	β_0	0,00004506	0,04334767	0,00000383
	β_1	2,97290930	-0,01413301	2,46664485
	β_2		0,00138577	1,15389394
	$r_{Y\hat{Y}}$	0,9679	0,9686	0,9698
	RMSE (%)	19,80	19,60	19,20

Onde: *Husch*, *Hohenald e Kreen* e *Schumacher e Hall* = modelos ajustados; β_k = parâmetros do referido modelo; $r_{Y\hat{Y}}$ = coeficiente de correlação; RMSE (%) = erro quadrático médio.

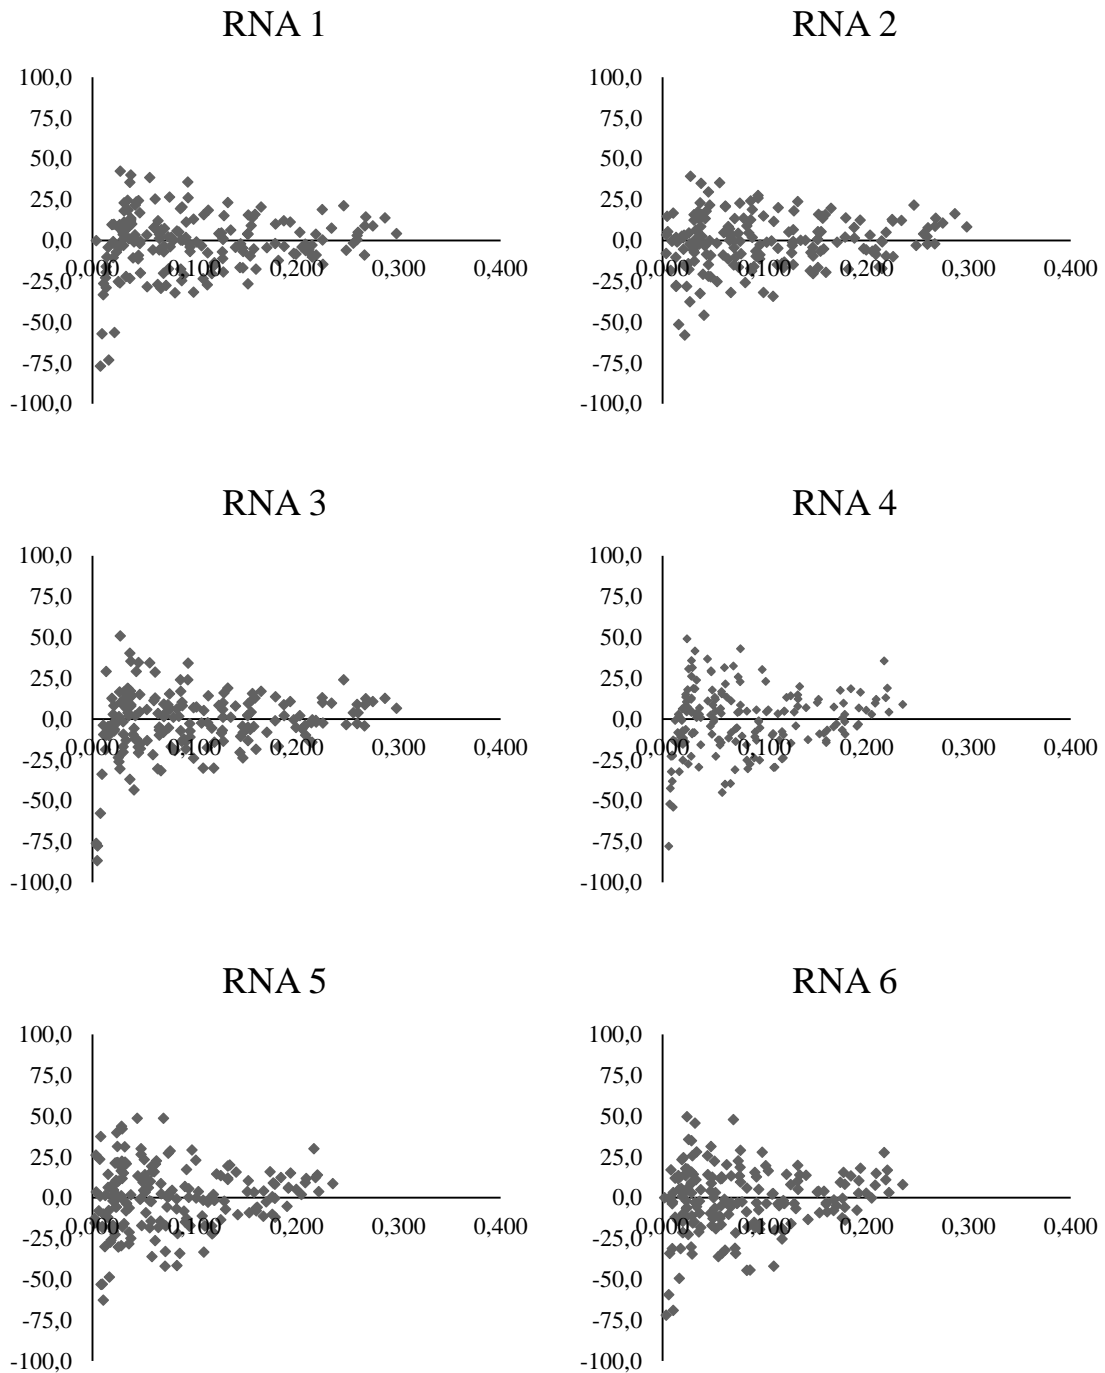


Figura 1: Dispersão dos erros percentuais (eixo y) em relação aos valores observados de volume (em m³, no eixo x) no treinamento, teste e validação das RNA 1 a 6, respectivamente.

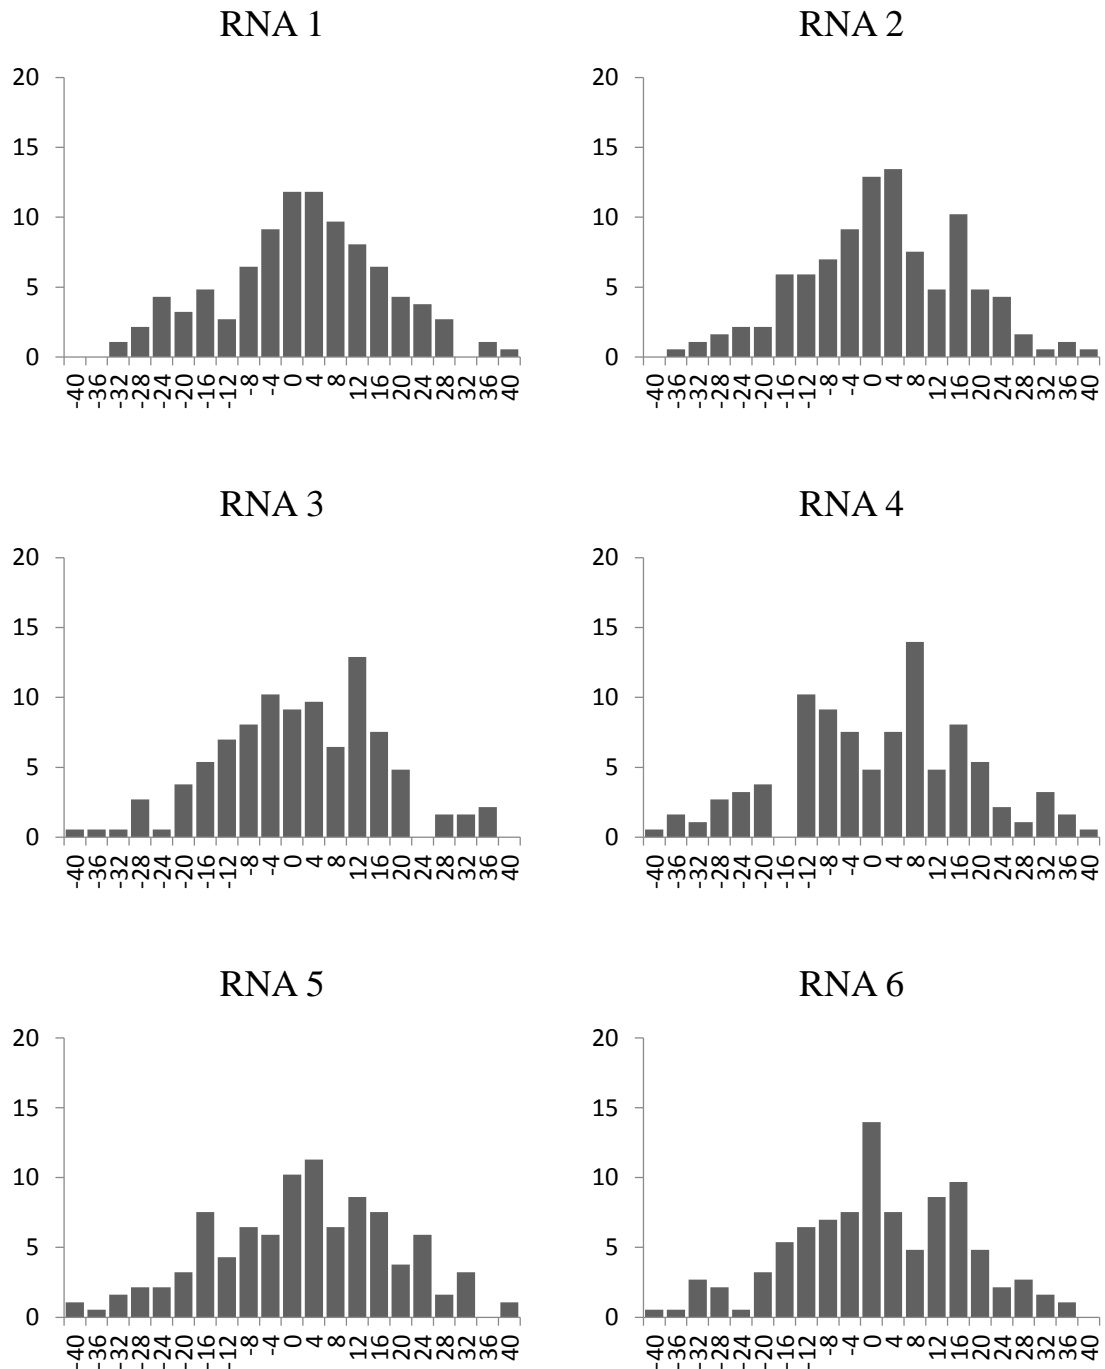


Figura 2: Frequência percentual (eixo y) dos erros percentuais (eixo x) das estimativas de RNA para estimação dos volumes totais, no treinamento, teste e validação das redes 1 a 6, respectivamente

Dentre os modelos de regressão ajustados, *Schumacher e Hall* apresentou os maiores coeficientes de correlação entre os valores observados e estimados (0,9752 e 0,9698 para projeções de volumes com e sem casca respectivamente), bem como os menores erros quadráticos médio (16,84 e 19,20 para projeções volumes com e sem casca respectivamente). Entretanto, nem mesmo os valores dos melhores ajustes de regressão foi superior que a média dos valores obtidos com as RNAs de pior desempenho entre as escolhidas para o estudo (RNA 1 e 6).

Quando se analisa os valores do erro quadrático médio e correlação do modelo de *Schumacher e Hall* em relação valores das RNAs 2 e 4 é possível observar que o erro quadrático médio da regressão para estimação do volume com e sem casca é respectivamente 20 e 13% maior que os resultantes do uso das RNAs, explicitando como estas foram mais eficientes. Eficiência esta, que pode ser comprovada pelos gráficos de dispersão residual das RNAs (Figuras 1 e 2) e das regressões (Figura 3).

Os histogramas de frequência (%) dos erros percentuais das estimativas gerada pelas RNAs (Figura 2) indicam que a maior parte dos erros ficou concentrada no intervalo de $\pm 12\%$.

As RNAs que estimaram o volume sem casca obtiveram maior concentração dos erros percentuais nesta faixa na etapa de treinamento, quando cerca de 60% dos dados estavam no intervalo, enquanto o teste e validação ficaram com média próxima a 58% dos erros percentuais no intervalo. As RNAs que estimaram o volume com casca tiveram uma resposta melhor, com aproximadamente 67, 55 e 68% dos erros percentuais entre $\pm 12\%$, para os erros gerados a partir do treinamento, teste e validação respectivamente.

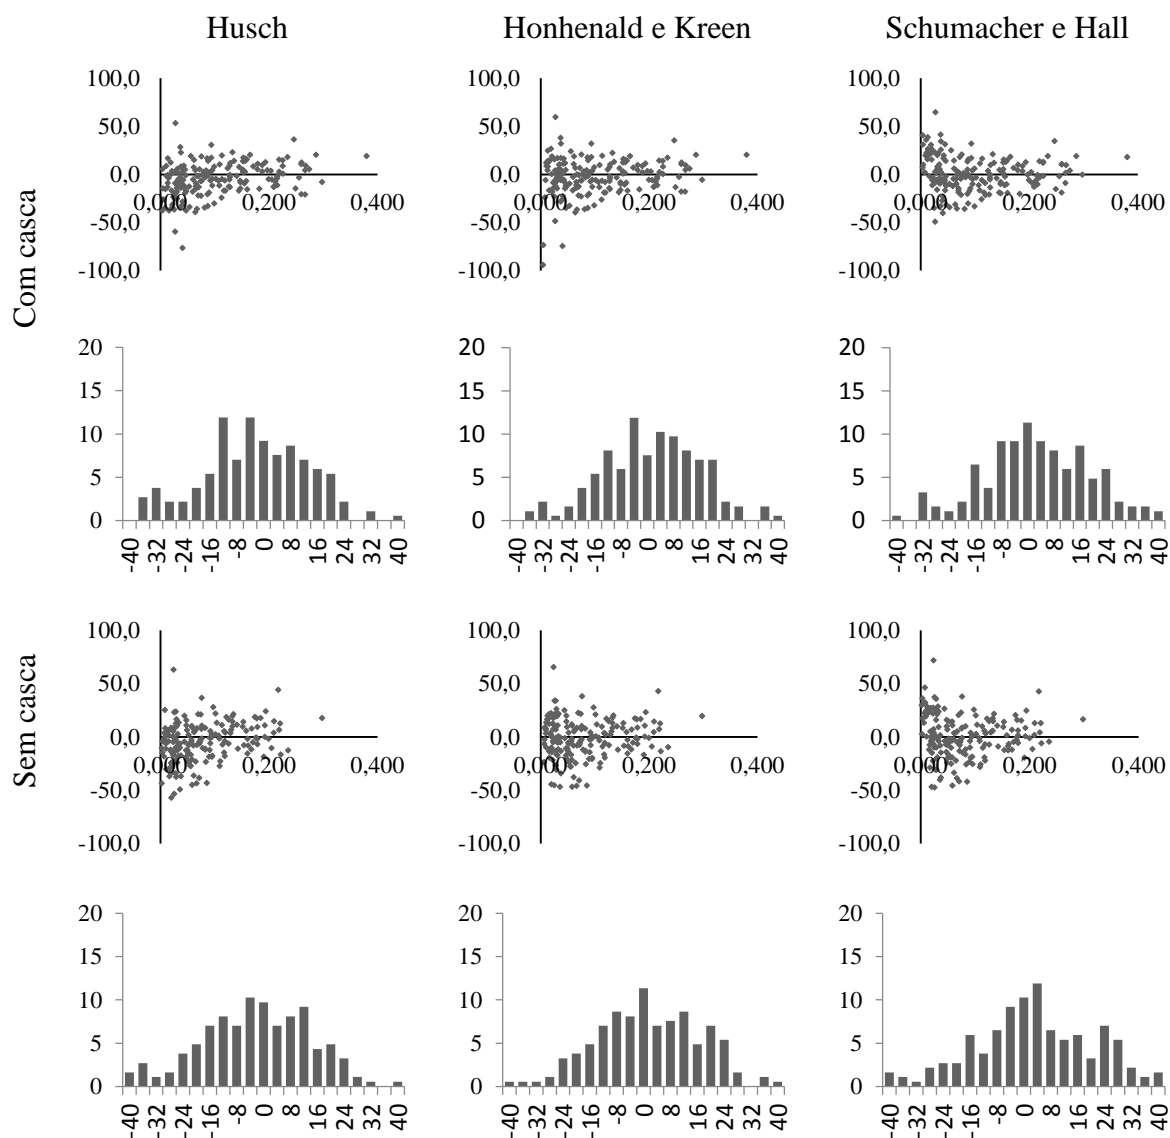


Figura 3: Dispersão dos erros percentuais (eixo y) em relação aos valores observados de volume (em m^3 , no eixo x) e a frequência percentual (eixo y) dos erros percentuais (eixo x) das estimativas obtidas com as regressões para projeção do volume com e sem casca.

A dispersão do resíduo percentual gerado pelas regressões ajustadas se apresentou de maneira mais homogênea do que as RNAs, porém a precisão geral dos dados não foi tão boa, além de que praticamente todas as regressões (exceto do modelo de *Hohenald e Kreen* para volume sem casca) tenderam à superestimação, fato que não ocorreu de maneira significativa com as RNAs.

O modelo ajustado para estimar o volume que teve a maior porcentagem dos erros percentuais no intervalo de $\pm 12\%$ foi o de *Husch* com aproximadamente 63 e 59% para

estimação de volume com e sem casca respectivamente. Porém, o modelo *Schumacher e Hall* foi escolhido para a comparação da sua eficiência na estimação de volume em cada tratamento em relação às RNAs 2 e 4, por ter apresentado uma porcentagem próxima de estimativas com o erro dentro deste intervalo (61 e 55% para projeção de volume com e sem casca, respectivamente), além de melhores níveis de correlação e erro quadrático médio.

No total foram realizados 10 ajustes de regressão do modelo de *Schumacher e Hall*, referentes aos 5 tratamentos para a projeção de volume com e sem casca (Tabela 4). Os valores de erro quadrático médio variaram entre 13,26 e 17,91 (tratamentos 5 e 3) para projeção de volume com casca e entre 13,27 e 21,11 (tratamentos 5 e 4) na estimativa de volumes sem casca.

Tabela 4: Parâmetros estimados, coeficientes de correlação e erro quadrático médio referentes aos ajustes da equação de volume para cada tratamento.

		Tratamentos				
Parâmetro		Trat1	Trat2	Trat3	Trat4	Trat5
Volume com casca	β_0	0,00000527	0,00002969	0,00001676	0,00001542	0,00000200
	β_1	1,75304777	2,26444290	2,58167295	2,20314603	2,24534856
	β_2	1,63493017	0,68086837	0,64929574	0,99497160	1,56113754
	$r_{Y\hat{Y}}$	0,9705	0,9580	0,9730	0,9507	0,9517
	RMSE (%)	16,96	17,62	17,91	17,15	13,26
Volume sem casca	β_0	0,00000359	0,00003786	0,00003171	0,00001010	0,00000058
	β_1	1,85377033	2,33597256	3,02423781	2,26887496	2,42844074
	β_2	1,62791736	0,49704250	0,07178144	1,03972084	1,74041183
	$r_{Y\hat{Y}}$	0,9695	0,9483	0,9659	0,9320	0,9583
	RMSE (%)	18,21	18,91	18,04	21,11	13,27

A correlação dos valores observados e estimados através do modelo de Schumacher e Hall variou entre 0,9507 e 0,9705 (tratamentos 4 e 1) para projeção de volume com casca e entre 0,9320 e 0,9695 (tratamentos 4 e 1) para volumes sem casca.

O desempenho das RNAs 2 e 4 se mostraram altamente satisfatórios (tabela 5), atingindo valores de erro quadrático médio menores que os obtidos com regressão em todos os tratamentos, além de ter um grau de correlação maior quem quase todos os tratamentos (exceto tratamento 3 para volume com casca e 5 sem casca).

Tabela 5: Coeficientes de correlação e erro quadrático médio obtidos pelas RNAs 2 e 4 para cada tratamento.

		Trat. 1	Trat. 2	Trat. 3	Trat. 4	Trat. 5
Volumes	$r_{Y\hat{Y}}$	0,9767	0,9781	0,9727	0,9575	0,9561
c/ casca	RMSE (%)	16,65	15,57	17,00	16,19	12,58
Volumes	$r_{Y\hat{Y}}$	0,9781	0,9697	0,9666	0,9649	0,9577
s/ casca	RMSE (%)	15,22	17,06	16,50	15,50	12,51

A análise dos gráficos de dispersão do erro percentual (Figuras 4 e 5) possibilita visualizar como as RNAs apresentaram uma distribuição mais concentrada em uma porcentagem mais baixa. Mesmo tendo uma distribuição aparentemente mais homogênea, o resíduo gerado pela regressão é mais estratificado e chega a porcentagens mais altas.

As RNAs tiveram uma média de aproximadamente 63% do resíduo percentual gerado ficou dentro do intervalo de $\pm 12\%$ de erro, valor próximo ao obtido com o erro percentual resultante de 62% para a estimação do volume com casca por regressão. Quando se estimou o volume sem casca esta diferença foi maior, sendo 63% para o resíduo gerado pela RNA e 58% pela regressão. Possivelmente esta diferença surgiu por algum ruído no banco de dados do tratamento 4, como pode se observar por seus valores de erro quadrático médio e correlação consideravelmente piores que a média. Fato este aliado com a característica de tolerância a ruídos das RNAs fez com que o seu uso fosse mais eficiente.

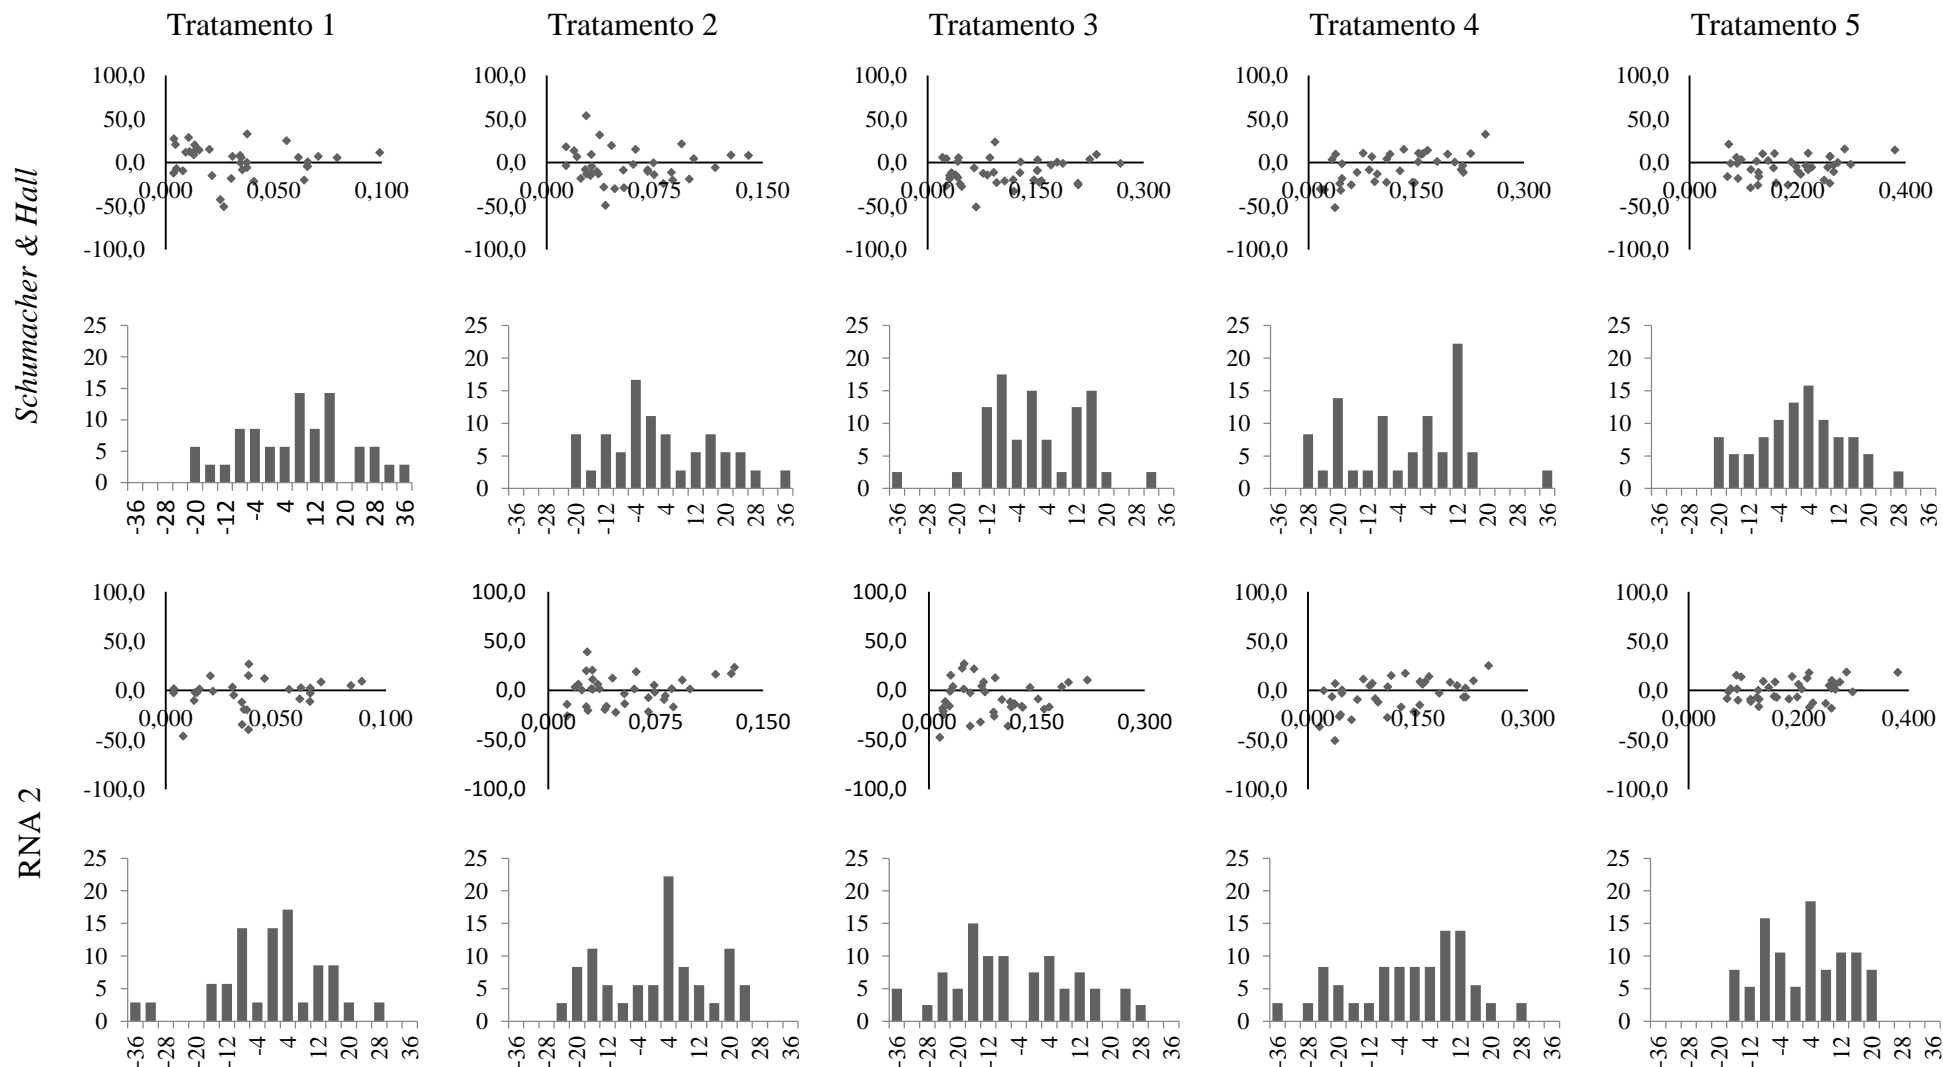


Figura 4: Dispersão dos erros percentuais (eixo y) em relação aos valores observados de volume (em m³, no eixo x) e frequência percentual (eixo y) dos erros percentuais (eixo x) das estimativas geradas pela regressão e pela RNA 2 para estimação de volumes obtidas a partir do valor de DAP com casca.

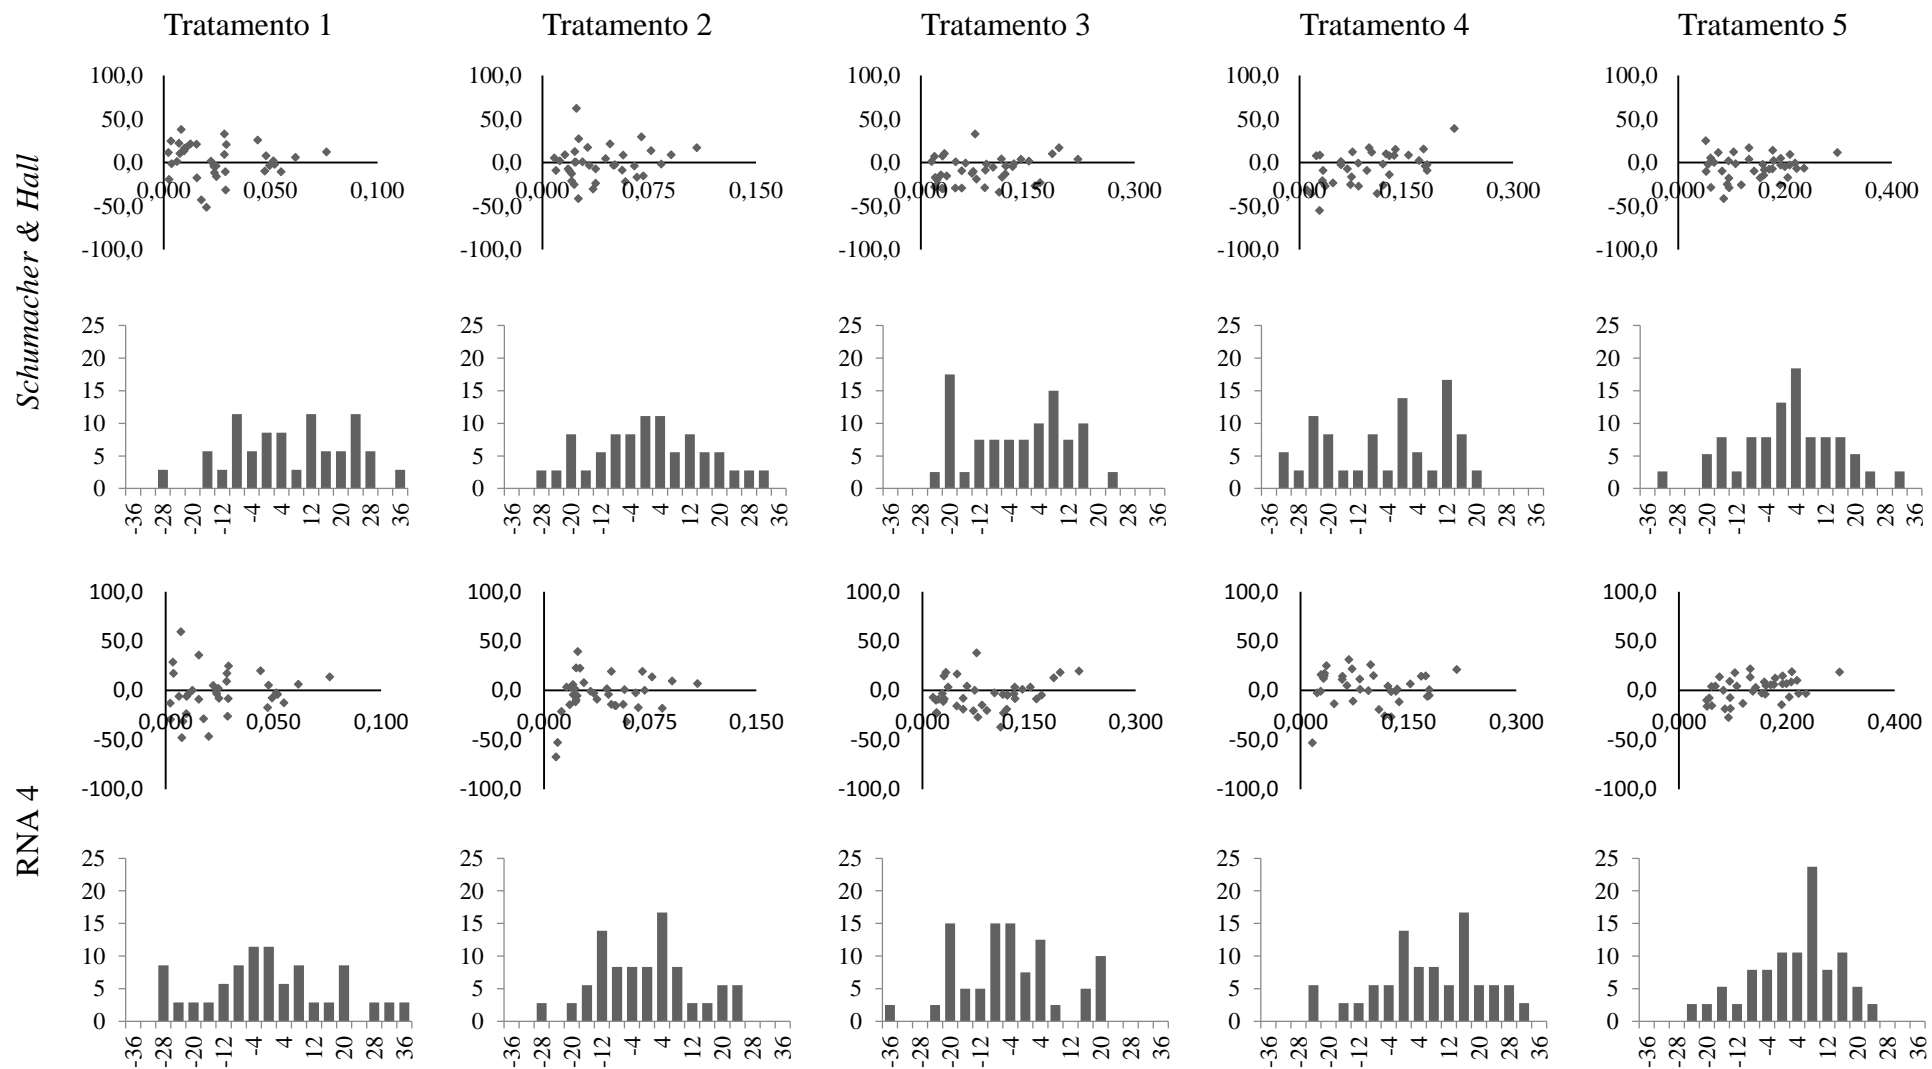


Figura 5: Dispersão dos erros percentuais (eixo y) em relação aos valores observados de volume (em m³, no eixo x) e frequência percentual (eixo y) dos erros percentuais (eixo x) das estimativas geradas pela regressão e pela RNA 4 para estimação de volumes obtidas a partir do valor de DAP sem casca.

3.2- Altura de árvores

A tabela 6 detalha as características das 3 arquiteturas, dentre as 180 treinadas, para estimar a altura das árvores, que obtiveram com os melhores valores de RMSE (%) e $r_{Y\hat{Y}}$, partir de medições do DAP.

Tabela 6: Características e precisão das RNAs selecionadas para estimar a altura.

RNA	Arquitetura	Treinamento		Teste		Validação	
		RMSE (%)	$r_{Y\hat{Y}}$	RMSE (%)	$r_{Y\hat{Y}}$	RMSE (%)	$r_{Y\hat{Y}}$
7	4-4-1	3,26	0,9882	3,09	0,9875	3,20	0,9843
8	4-7-1	3,97	0,9826	3,95	0,9807	3,32	0,9815
9	4-11-1	3,89	0,9833	3,87	0,9813	3,29	0,9820

Onde: RNA = número da arquitetura selecionada; Arq. = número de neurônios em cada camada; RMSE (%) = erro quadrático médio; $r_{Y\hat{Y}}$ = correlação entre observado e calculado; Treinamento, Teste e Validação = conjunto de dados utilizado.

A RNA 7, com 4 neurônios na camada oculta, foi a que apresentou o melhor desempenho (com médias de RMSE (%) = 3.18 e de $r_{Y\hat{Y}}$ = 0,9867), seguida pela RNA 9 e 8 em ordem decrescente de desempenho. Sendo assim, ela foi selecionadas para a projeção das alturas para cada tratamento.

Quando comparados os erros quadráticos médios e correlação entre valores observados e estimados obtidos com as RNAs e os obtidos pela regressão ajustados com as medições das 185 árvores do banco de dados (Tabela 7) é possível inferir sobre a eficiência das RNAs.

Dentre os modelos de regressão estudados, o $\ln H = \beta_0 + \beta_1 \times DAP^{-1} + \varepsilon_i$ foi o que melhor descreveu o banco de dados, pois apesar de ter um grau de correlação próximo ao outro modelo, este obteve menores valores de erro quadrático. Porém os valores encontrados com as regressões foram consideravelmente piores que os encontrados com as RNAs. Comparando os valores de erro quadrático médio do modelo com os da RNA 7 se chega a um valor aproximadamente 33,5% maior.

Tabela 7: Estimativas dos parâmetros dos modelos de estimativas de altura.

Modelo	Parâmetro	
$\ln H = \beta_0 + \beta_1 \times \ln DAP + \varepsilon_i$	β_0	1,40359206
	β_1	0,70578355
	$r_{Y\hat{Y}}$	0,9742
	RMSE (%)	5,2006
$\ln H = \beta_0 + \beta_1 \times DAP^{-1} + \varepsilon_i$	β_0	3,74336445
	β_1	-6,69399199
	$r_{Y\hat{Y}}$	0,9743
	RMSE (%)	4,2522

Onde: \ln = logaritmo neperiano; H = altura estimada; β_k = parâmetros do referido modelo; DAP = Diâmetro a 1,3m de altura; ε_i = erro aleatório, sendo $\varepsilon \sim NID(0, \sigma^2)$; $r_{Y\hat{Y}}$ = coeficiente de correlação; RMSE (%) = erro quadrático médio.

Através da comparação dos gráficos de resíduos das redes neurais (Figuras 6) com os gráficos dos resíduos das estimativas obtidas através da regressão (Figura 7) é possível observar que além de menores, a distribuição dos resíduos se mostrou mais homogênea nas RNAs.

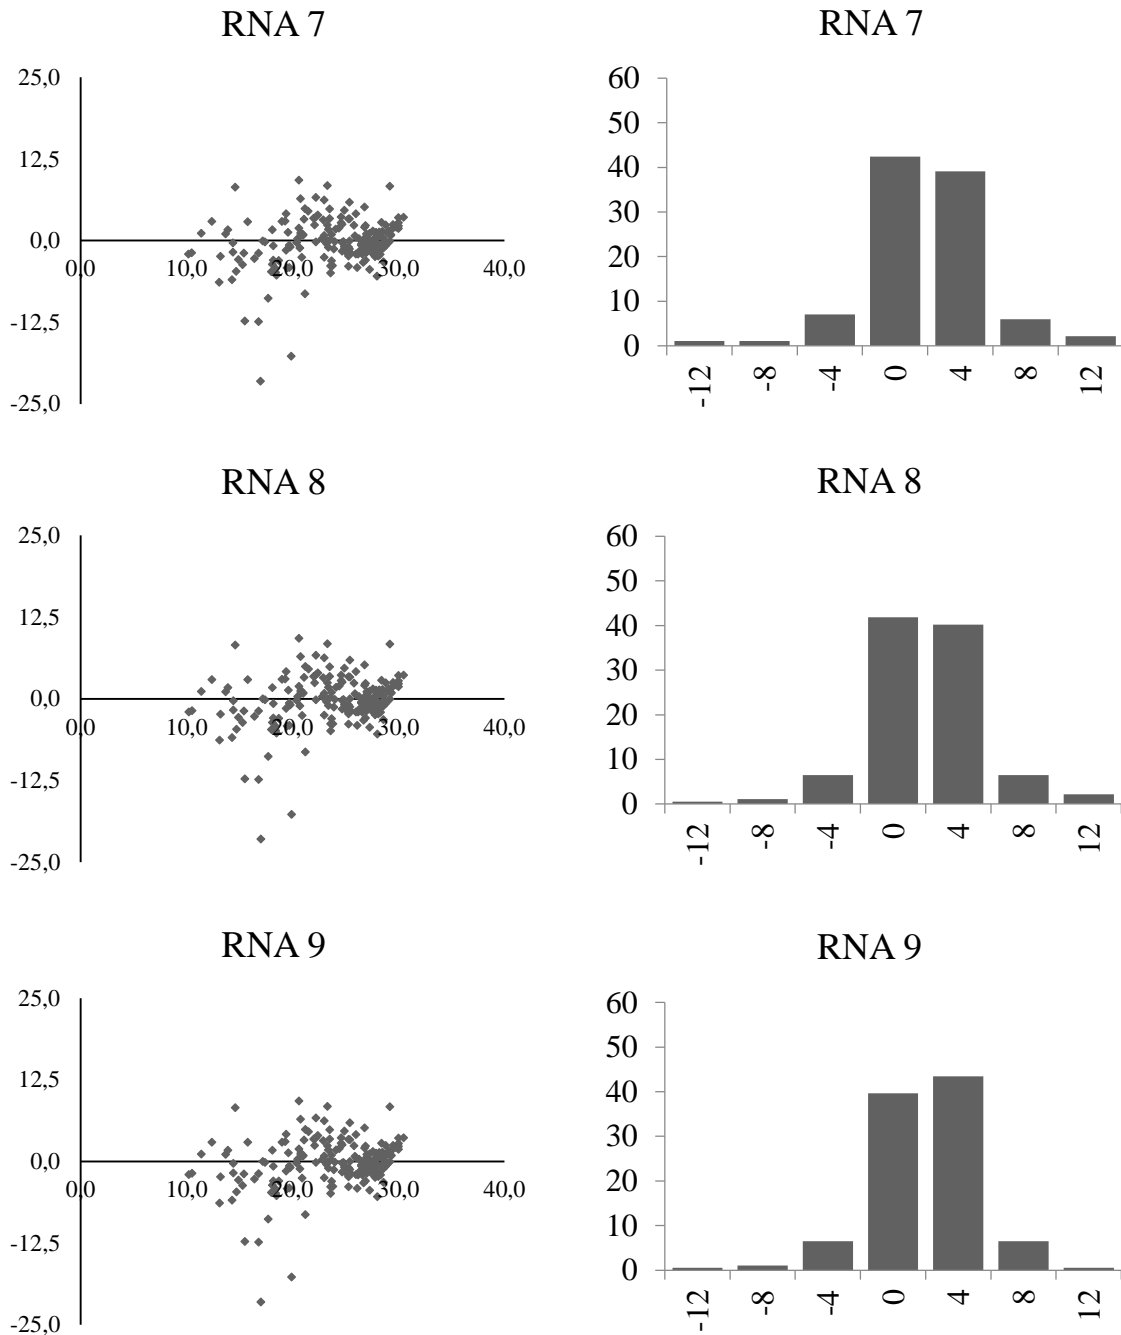


Figura 6: Dispersão dos erros percentuais (eixo y) em relação aos valores observados de altura (em m, no eixo x) e frequência percentual (eixo y) dos erros percentuais (eixo x) no treinamento, teste e validação das RNA 7 a 9, respectivamente.

Conforme os histogramas de frequência percentuais dos erros das estimativas (Figura 7) indica, a maioria dos erros ficou concentrada em $\pm 4\%$, com uma leve tendência a superestimação dos valores.

Na etapa de treinamento das redes se chegou a média próxima de 85% dos erros neste intervalo. Na fase de teste estes valores foram menores, sendo suas médias próximas a 79%. Por fim, a etapa de validação foi onde se obteve as melhores médias, com 92 % dos erros dos valores estimados no intervalo de $\pm 4\%$.

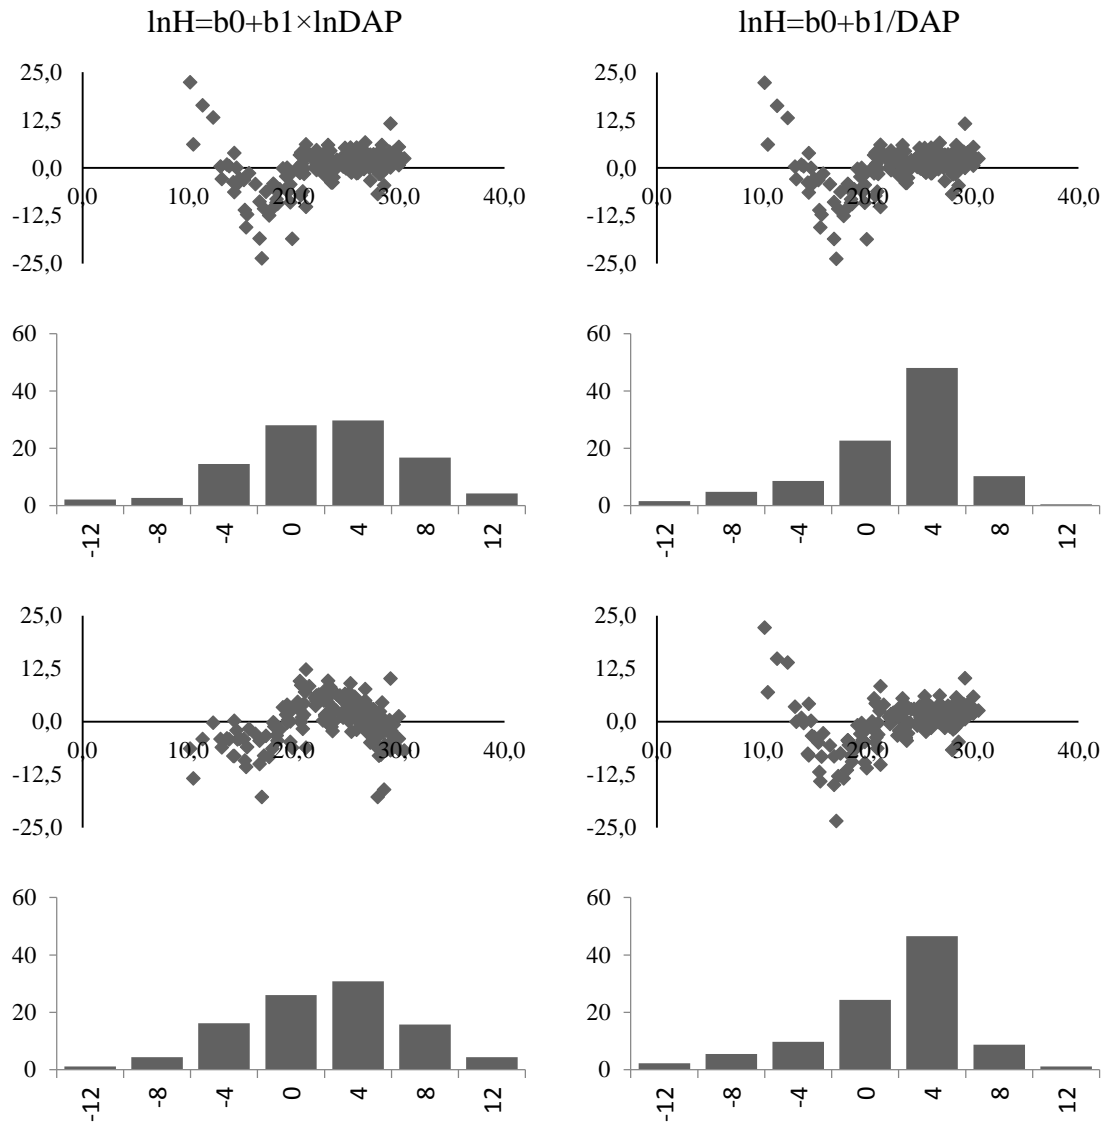


Figura 7: Dispersão dos erros percentuais (eixo y) em relação aos valores observados de altura (em m, no eixo x) e a frequência percentual (eixo y) dos erros percentuais (eixo x) das estimativas obtidas com as regressões para projeção da altura total.

Com as regressões se obteve uma resposta semelhante, porém com uma precisão menor que com as RNAs, com elas a maioria dos erros também ficaram entre $\pm 4\%$ com a uma tendência (maior que das RNAs) de superestimação dos valores, em especial o

modelo $\ln H = \beta_0 + \beta_1 \times DAP^{-1}$. Aproximadamente 76% dos erros para estimativas geradas ficaram entre $\pm 4\%$.

Devido à alta tendência a superestimação de valores do modelo $\ln H = \beta_0 + \beta_1 \times DAP^{-1}$ observada na análise gráfica, o modelo $\ln H = \beta_0 + \beta_1 \times \ln DAP + \varepsilon_i$ foi utilizado na comparação com as RNAs 7 em relação ao desempenho em cada tratamento.

Foram realizados 5 ajustes de regressão do modelo $\ln H = \beta_0 + \beta_1 \times \ln DAP + \varepsilon_i$, referentes aos 5 tratamentos e ao DAP (Tabela 8). Nas regressões realizadas a correlação variou entre 0,8778 e 0,9877, representando respectivamente os valores dos tratamentos 5 e 1.

Tabela 8: Parâmetros estimados, coeficientes de correlação e erro quadrático médio referentes aos ajustes da equação de altura para cada tratamento.

Parâmetro	Tratamentos				
	Trat.1	Trat.2	Trat.3	Trat.4	Trat.5
β_0	1,15933215	1,285998054	1,45544453	1,424376752	2,00127609
β_1	0,82386143	0,760701154	0,68693241	0,697814781	0,48115345
$r_{Y\hat{Y}}$	0,9877	0,9611	0,9681	0,9438	0,8778
RMSE	4,0614	5,1155	3,9929	4,9404	3,8419

Em relação ao erro quadrático médio também teve uma grande diferença, com os valores variando entre 3,8419 e 5,1155, referentes aos tratamentos 5 e 2 respectivamente. Quando analisadas as RNAs, observa-se que a RNA 7 apresentou um ótimo desempenho quando usadas para estimação da altura (Tabela 9).

Tabela 9: Coeficientes de correlação e erro quadrático médio obtido pela RNA 7 para cada tratamento.

	Parâmetro	Trat. 1	Trat. 2	Trat. 3	Trat. 4	Trat. 5
Alturas c/ casca	$r_{Y\hat{Y}}$	0,9906	0,9841	0,9838	0,9783	0,9360
	RMSE (%)	3,2926	3,4652	3,0023	3,0211	2,9816

Os resultados das estimativas de alturas são apresentados na figura 8, onde pode-se observar que além de obter melhores indicadores estatísticos, a dispersão dos resíduos gerados pela RNA foi mais homogênea do que os obtidos pela regressão, podendo novamente ressaltar a tendência de superestimação de ambos. Com o uso da RNA aproximadamente uma média geral de 87% das alturas foram estimadas dentro de um intervalo de erro de $\pm 4\%$, com a regressão estes números caem para 80%. Com isto pode-se inferir que os resultados de estimação gerados com o uso das RNAs foram altamente satisfatórios.

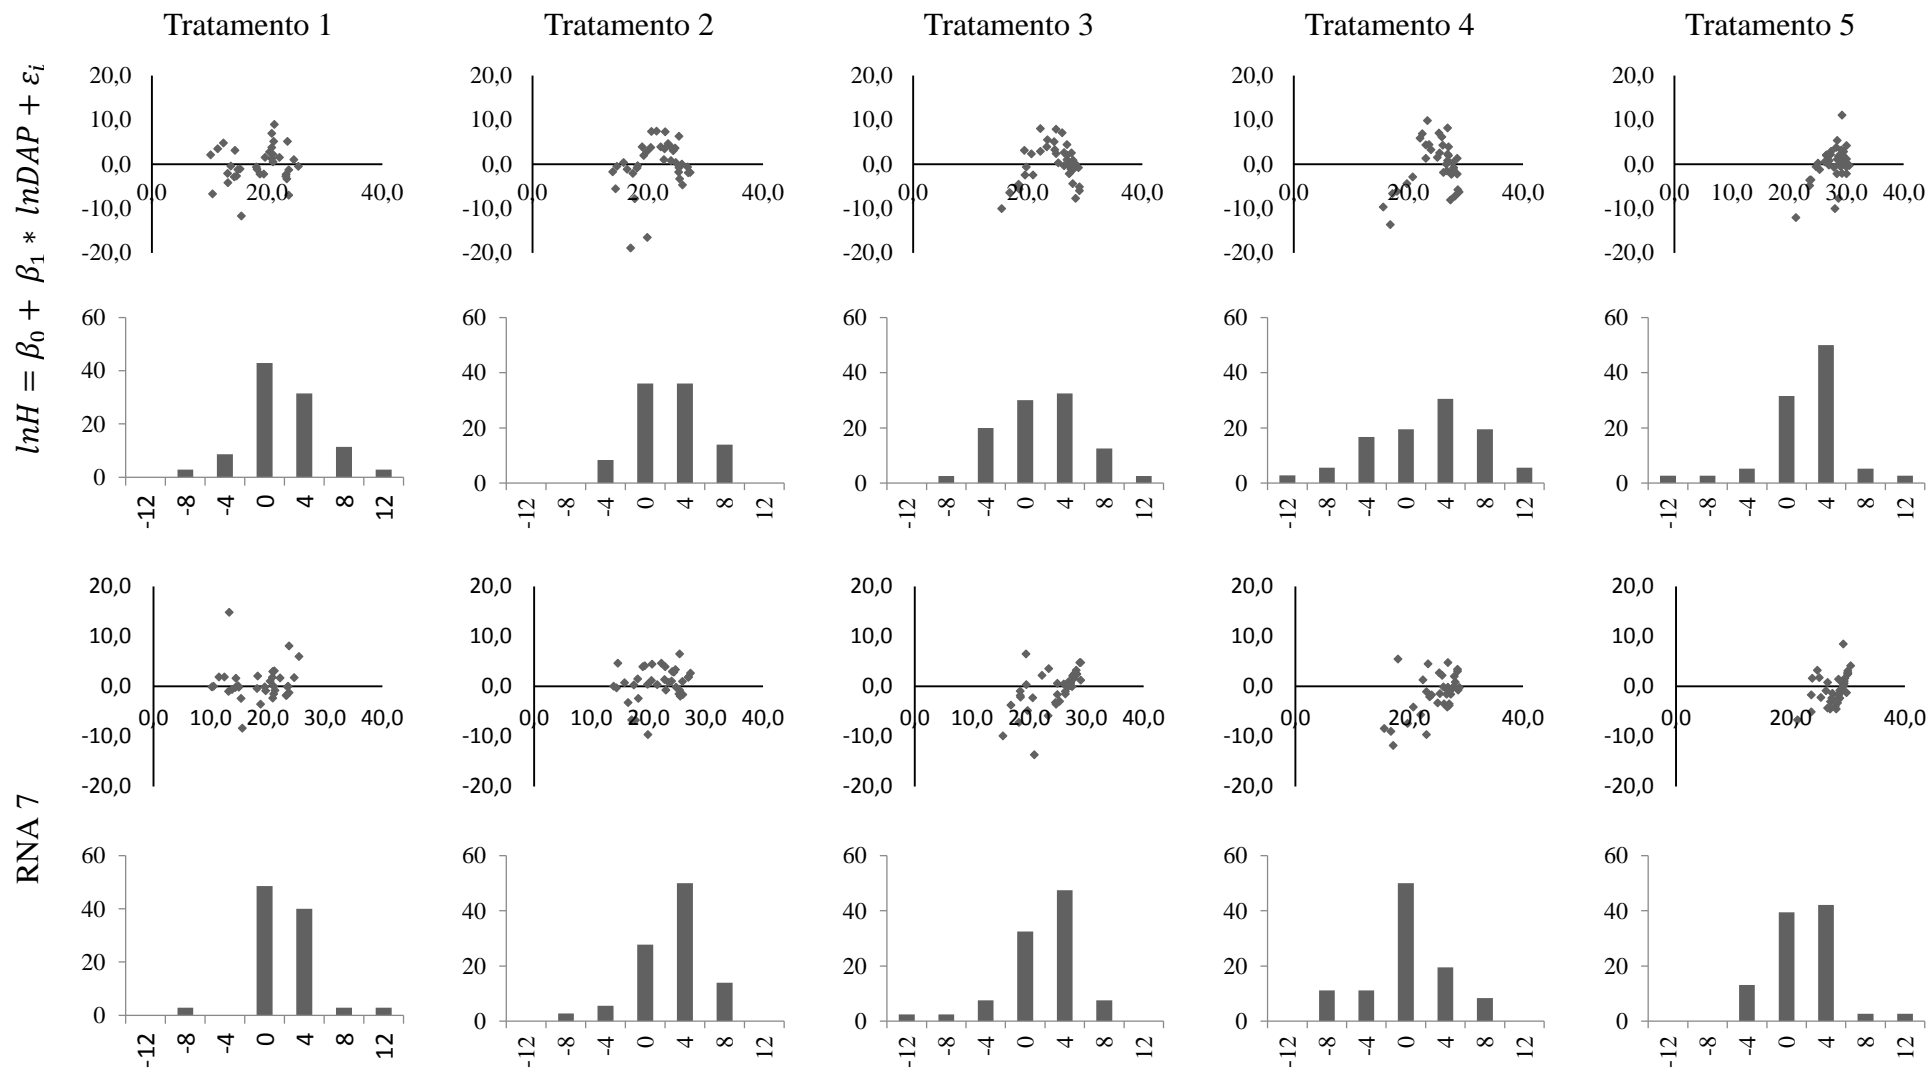


Figura 8: Dispersão dos erros percentuais (eixo y) em relação aos valores observados de altura (em m, no eixo x) e frequência percentual (eixo y) dos erros percentuais (eixo x) das estimativas geradas pela regressão e pela RNA 7 para projeção das alturas obtidas a partir do valor de DAP.

4- CONCLUSÕES

Tanto as equações hipsométricas e volumétricas, quanto as Redes Neurais Artificiais avaliadas foram eficientes para estimar altura e volume de um povoamento adensado de eucalipto.

Mesmo com o bom resultado encontrado com o uso de regressões, as RNAs tiveram respostas sensivelmente melhores, o que refletiria diretamente na redução dos custos de inventário, uma vez que seria necessária a cubagem de um menor número de árvores.

5- REFERÊNCIAS BIBLIOGRÁFICAS

Associação Brasileira de Produtores de Florestas Plantadas – ABRAF. **Anuário estatístico da ABRAF 2013: ano base 2012.** Disponível em: <http://www.abraflor.org.br/estatisticas.asp> Acesso em: 06 de julho de 2013.

BINOTI, M. L. M. 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, 2010.

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

BULLINARIA, J. A. **Introduction to Neural Computation.** Notas de aula. Disponível em: <http://www.cs.bham.ac.uk/~jxb/inc.html> Acesso em: 04 de julho de 2013.

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

COUTO, L.; BETTERS, D.R. **Short-rotation Eucalypt Plantations in Brazil: Social and Enviromental Issues.** ORNL/TM-12846, 34p.

DIAMANTOPOULOU, M. J. **Artificial neural networks as an alternative tool in pine bark volume estimation.** Computers and Electronics in Agriculture, v. 48, n.3, p. 235-244, 2005.

FERRAZ, A. S. **Estimação dos estoques de biomassa e carbono na parte aérea de um fragment de floresta estacional semidecidual por meio de imagens de satélite Ikonos II.** 2012. 88f. Tese (Doutorado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa, 2012.

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

KER, J.; SMITH, J. **Sampling for height-diameter relationships.** Journal of forestry, v.55, n.3, p.205-207, 1957.

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, 2011.

LEITE, H. G.; BINOTI, D. H. B; BINOTI, M. L. M. S. **NeuroForest** versão 3.0 <<http://neuroforest.ucoz.com/>>

MÜLLER, M. D. **Produção de Madeira para geração de energia elétrica numa plantação clonal de eucalipto em Itamarandiba, MG.** 2005, 108 p. Tese (Doutorado em Ciência Florestal). Universidade Federal de Viçosa, Viçosa – Minas Gerais, 2005.

OLIVEIRA, A.; GUITIERREZ, M.; LOSEKANN, L.D. **Energia e Desenvolvimento Sustentável.** Rio de Janeiro: Instituto de Economia UFRJ/ Min. das Minas e Energia (Relatório Final), 1998, 160p.

OLIVEIRA, A.S. **Análise das modalidades e procedimentos simplificados do Mecanismo de Desenvolvimento Limpo – os projetos de pequena escala e a geração de energia renovável para o atendimento de residências rurais e isoladas.** Rio de

Janeiro: UFRJ, 2003, 236p. Dissertação (Mestrado em Ciências em Planejamento Energético) – Universidade Federal do Rio d Janeiro, 2003.

RIEDMILLER, M. AND BRAUN, H. **A direct adaptive method for faster backpropation learning: the RPROP algorithm.** Proceedings of IEEE International Conference on Neural Networks (San Francisco), Vol. 1, pp. 586-591. 1993.

STATSOFT, INC. **Statistica: Data Analysis Software System**, Version 12.0. 2012.