



UNIVERSIDADE FEDERAL DO ESPÍRITO SANTO
CENTRO DE CIÊNCIAS AGRÁRIAS E ENGENHARIAS
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS FLORESTAIS

ANA CAROLINA BOA

**MODELAGEM DA DENSIDADE BÁSICA DA MADEIRA DE EUCALIPTO
UTILIZANDO REDES NEURAS ARTIFICIAIS**

JERÔNIMO MONTEIRO – ES

2018

ANA CAROLINA BOA

**MODELAGEM DA DENSIDADE BÁSICA DA MADEIRA DE EUCALIPTO
UTILIZANDO REDES NEURAS ARTIFICIAIS**

Tese apresentada ao Programa de Pós-Graduação em Ciências Florestais do Centro de Ciências Agrárias e Engenharias da Universidade Federal do Espírito Santo, como parte das exigências para obtenção do Título de Doutor em Ciências Florestais na Área de Concentração Ciências Florestais.
Orientador: Prof. Dr. José Tarcisio da Silva Oliveira
Coorientadores: Prof. Dr^a. Graziela Baptista Vidaurre e Prof. Dr. Humberto Fantuzzi Neto

JERÔNIMO MONTEIRO – ES

2018

Dados Internacionais de Catalogação-na-publicação (CIP)
(Biblioteca Setorial Sul, Universidade Federal do Espírito Santo, ES, Brasil)

B662m Boa, Ana Carolina, 1989
Modelagem da densidade básica da madeira de eucalipto
utilizando redes neurais artificiais / Ana Carolina Boa. – 2018.
89 f. : il.

Orientador: José Tarcísio da Silva Oliveira.

Coorientador: Graziela Baptista Vidaurre ; Humberto Fantuzzi

Neto.

Tese (Doutorado em Ciências Florestais) – Universidade Federal
do Espírito Santo, Centro de Ciências Agrárias e Engenharias.

1. Madeira. 2. Qualidade. 3. Eucalipto. 4. Redes neurais
(Computação). I. Oliveira, José Tarcísio da Silva. II. Vidaurre, Graziela
Baptista. III. Fantuzzi Neto, Humberto. IV. Universidade Federal do
Espírito Santo. Centro de Ciências Agrárias e Engenharias. V. Título.

CDU: 630

**MODELAGEM PARA ESTIMATIVA DA DENSIDADE BÁSICA DA MADEIRA DE
EUCALIPTO DESTINADA À PRODUÇÃO DE CELULOSE**

ANA CAROLINA BOA

Tese apresentada ao Programa de Pós-Graduação em Ciências Florestais do Centro de Ciências Agrárias e Engenharias da Universidade Federal do Espírito Santo, como parte das exigências para obtenção do Título de Doutor em Ciências Florestais na Área de Concentração Ciências Florestais.

Aprovada em XX de XXXXXXXXXXXXXXX de 2018.

Prof. Dr. José Tarcisio da Silva Oliveira (orientador)
Universidade Federal do Espírito Santo

Prof. Dr^a. Graziela Baptista Vidaurre
(coorientadora)
Universidade Federal do Espírito Santo

Prof. Dr^a. Mayra Luiza Marques da Silva
Universidade Federal de São João Del-
Rei

Prof. Dr. Adair José Regazzi
Pesquisador
Universidade Federal do Espírito Santo

Dr. Jose Luis Lima
Pesquisador
Fibria Celulose S.A.

AGRADECIMENTOS

A gratidão é a forma mais fiel de reconhecimento. É entender que nós devemos acreditar em nossos sonhos e reconhecer a importância de todos aqueles que o tornaram realidade. Devemos nos orgulhar de nossas vitórias e ser gratos a todos que estiveram ao nosso lado.

Acima de tudo, agradeço a Deus por ser sustento e luz. Não foi fácil, mas Ele me deu forças para chegar até aqui.

A minha mãe, Maria, ao meu pai, Gilson, e ao meu irmão, Pedro, agradeço pelo apoio, amor e dedicação, e por tudo que representam para mim.

Agradeço também, a Universidade Federal do Espírito Santo e ao Programa de Pós-Graduação em Ciências Florestais pela oportunidade de realizar o curso de doutorado, e a CAPES pela concessão da bolsa.

Ao Prof. Dr. José Tarcísio da Silva Oliveira, pela amizade, dedicação e competência na orientação durante todos esses anos.

Aos professores coorientadores, Prof. Dr. Humberto Fantuzzi Neto e Prof. Dr^a. Graziela Baptista Vidaurre, pela troca de informações e pela colaboração para que este estudo pudesse ser realizado.

Aos membros da comissão examinadora, Prof. Dr^a. Mayra Luiza Marques da Silva, Prof. Dr. Adair José Regazzi e o Pesquisador Dr. José Luis Lima, por aceitarem participar da banca e pelas valiosas contribuições com este trabalho.

A empresa Fibria Celulose S.A. pelo auxílio desde o início do desenvolvimento do trabalho, pela doação do material de estudo e recursos para a realização das análises.

Aos professores, funcionários e colegas do Departamento de Ciências Florestais e da Madeira pela boa convivência e pela troca de informações. Em especial, aos colegas do LaMFlor, Jeangelis, Jeferson e Evandro pelas discussões e todo o auxílio no processamento dos dados.

A Thaís Marcchiori, por fazer parte da minha vida, por sempre estar ao meu lado e por me fazer enxergar que não existem limites para quem é perseverante.

Ao Dioener, por cuidar de mim, pelo carinho e companheirismo. Por trazer alegria ao compartilhar sua família e amigos comigo.

A Elisângela, por sempre me incentivar e cuidar de mim nos momentos difíceis durante essa caminhada.

A todos aqueles que, mesmo não mencionados aqui, fizeram parte desta história e compartilharam momentos inesquecíveis comigo.

Muito obrigada!

"O único homem que jamais erra é aquele que nunca faz nada."

"Você precisa fazer aquilo que pensa que não é capaz de fazer."

— **Eleanor Roosevelt**

RESUMO

BOA, Ana Carolina. **Modelagem para estimativa da densidade básica da madeira de eucalipto utilizando redes neurais artificiais**. 2018. Tese (Doutorado em Ciências Florestais) – Universidade Federal do Espírito Santo, Jerônimo Monteiro, ES. Orientador: José Tarcisio da Silva Oliveira. Coorientadores: Graziela Baptista Vidaurre e Humberto Fantuzzi Neto.

As indústrias brasileiras do setor florestal são destaques mundiais em produtividade e qualidade, e empregam um grande volume de matéria-prima para atender a demanda de seus processos. Além da quantidade, o setor exige materiais que atendam com qualidade seus processos e correspondam com a qualidade requerida de seus produtos finais. Entre as propriedades que caracterizam a madeira, a densidade básica é destacada como um importante parâmetro de qualidade, uma vez que está relacionada a diversos aspectos tecnológicos e econômicos. Deste modo, o objetivo deste trabalho foi aplicar modelagem por redes neurais artificiais na estimativa da densidade básica da madeira de eucalipto destinada à produção de celulose. Foram avaliadas 352 árvores de 18 clones do híbrido *Eucalyptus grandis* x *Eucalyptus urophylla*, com idades entre dois e oito anos, originados de plantios nos estados do Espírito Santo e Bahia. As variáveis quantitativas empregadas nas estimativas da densidade foram idade, DAP, volume, precipitação acumulada, temperatura e umidade relativa, adicionadas das variáveis qualitativas clone e região. A densidade da madeira foi estimada por meio de redes neurais artificiais (RNAs) e, para melhor desempenho, estimativas foram realizadas a partir de sete diferentes combinações das variáveis empregadas, sendo elas: COMP (dados completos), REG-1 (Aracruz-ES), REG-2 (São Mateus-ES), REG-3 (Bahia), CLAS-1 (árvores com 2 a 4 anos), CLAS-2 (árvores com 4 a 6 anos) e CLAS-3 (árvores com 6 a 8 anos). Foram também testados os desempenhos das funções de ativação logarítmica hiperbólica e tangente hiperbólica e dos algoritmos de treinamento Levenberg-Marquardt e Resilient Propagation (RPROP+) da camada oculta das RNAs. Com base nas configurações da camada oculta, o algoritmo Levenberg-Marquardt apresentou melhor desempenho e tanto a função de ativação logarítmica quanto a hiperbólica apresentaram desempenho satisfatório. De modo geral, as redes neurais artificiais apresentaram bom desempenho na estimativa da densidade básica da madeira de eucalipto, e todas as combinações de variáveis empregadas na estimativa foram eficientes. Contudo, houve tendência de superestimação dos valores estimados. Especificar as regiões e as classes de idade permitiu que fossem alcançados melhores resultados, sendo observados resultados mais precisos na região Aracruz (REG-1) e para árvores com idade variando de quatro a seis anos (CLAS-2).

Palavras-chave: Qualidade, madeira, polpa, eucalipto, redes neurais artificiais.

ABSTRACT

BOA, Ana Carolina. **Modeling for estimation of the eucalypt wood basic density to pulpwood.** 2018. Thesis (Doctor of Forest Sciences) - Federal University of Espírito Santo, Jerônimo Monteiro, ES. Advisor: José Tarcisio da Silva Oliveira. Co-Advisors: Graziela Baptista Vidaurre and Humberto Fantuzzi Neto.

Brazilian forestry industries are world leaders in productivity and quality, and use a large volume of raw material to meet the demand of their processes. In addition to quantity, the industry requires materials that meet the quality of their processes and match the required quality of their final products. Among the properties that characterize wood, the basic density is highlighted as an important parameter of quality, since it is related to many different technological and economic aspects. Therefore, the objective of this study was to apply artificial neural network modeling to estimate the basic density of eucalyptus wood for pulpwood. A total of 352 trees from 18 clones of *Eucalyptus grandis* x *Eucalyptus urophylla* hybrid, aged between two and eight years old, originated from plantations in the states of Espírito Santo and Bahia. The quantitative variables used in the density estimates were age, diameter at breast height, volume, accumulated precipitation, temperature and relative humidity, added to qualitative variables clone and region. The density of the wood was estimated using artificial neural networks (ANNs) and, for better estimation performance, the estimates were made from seven different combinations of the variables: COMP (complete data), REG-1 (Aracruz-ES), REG-2 (São Mateus-ES), REG-3 (Bahia), CLAS-1 (trees from 2 to 4 years), CLAS-2 (trees from 4 to 6 years) e CLAS-3 (trees from 6 to 8 years). The performances of the hyperbolic logarithmic and hyperbolic tangent activation functions and the Levenberg-Marquardt and Resilient Propagation (RPROP +) training algorithms of the hidden layer of the RNAs were also tested. Based on the hidden layer configurations, the Levenberg-Marquardt algorithm presented better performance and both logarithmic and hyperbolic activation functions performed satisfactorily. In general, artificial neural networks performed well in estimating the basic density of eucalyptus wood, and all combinations of variables used in the estimation were efficient. However, there was a tendency to overestimate the estimated values. Specifying regions and age classes allowed better results to be achieved, with more accurate results being observed in the region Aracruz (REG-1) and trees from 6 to 8 years (CLAS-2).

Keywords: Quality, wood, pulp, eucalyptus, artificial neural networks.

SUMÁRIO

1. INTRODUÇÃO	08
1.1. O problema e sua importância	10
1.2. Objetivos	12
1.2.1. Objetivo geral	12
1.2.2. Objetivos específicos	12
2. REVISÃO DE LITERATURA.....	13
2.1. Madeira de eucalipto como fonte de matéria-prima	13
2.2. Qualidade da madeira de eucalipto para a produção de celulose	15
2.3. Redes neurais artificiais	20
2.4. Análise de regressão	28
3. MATERIAL E MÉTODOS	31
3.1. Descrição dos dados	31
3.2. Amostragem da madeira	32
3.3. Variáveis climáticas	33
3.4. Modelagem da densidade básica da madeira	34
3.4.1. Modelagem por redes neurais artificiais	36
3.4.2. Modelagem por regressão linear	38
3.5. Avaliação das estimativas geradas pelos métodos empregados	38
4. RESULTADOS E DISCUSSÕES	41
5. CONCLUSÕES	61
6. REFERÊNCIAS BIBLIOGRÁFICAS	62
APÊNDICES	68

1. INTRODUÇÃO

O setor florestal brasileiro destaca-se pela expressiva área de florestas plantadas e pelo elevado nível das pesquisas científicas desenvolvidas simultaneamente ao crescimento deste setor. É representado por empresas de diversos segmentos, que demandam madeira de alta qualidade a fim de obterem elevados rendimentos na transformação e produtos de elevado valor agregado, bem como com excelentes propriedades.

As espécies do gênero *Eucalyptus* são as que mais atendem a este setor e, também, se destacam em área plantada no Brasil. O uso de eucalipto está relacionado à boa adaptação do gênero encontrada no País, pelas mais diferentes espécies, em função das condições edafoclimáticas e em adição às tecnologias empregadas nestas formações florestais. A madeira das espécies deste gênero é largamente empregada como matéria-prima na produção de diversos produtos, se destacando a produção de celulose e papel, energia, painéis e produtos sólidos.

O Brasil é um dos maiores produtores de celulose em nível mundial, sendo este setor de grande importância no cenário econômico nacional. Porém, mesmo diante da importância e de todo nível tecnológico empregado neste setor, alguns obstáculos ainda precisam ser superados.

A busca por matéria-prima de qualidade, assim como a qualidade do produto final, vem sendo uma abordagem presente em diversas pesquisas e discussões no segmento florestal. Compreender a qualidade da madeira produzida em uma floresta é considerado importante pelas empresas, principalmente, porque esse fator está estreitamente ligado à estruturação e ao rendimento dos processos, assim como às características dos produtos finais (ANDRADE, 2006; FOELKEL, 2015a; 2015b).

Para a classificação de materiais de qualidade superior é necessário que sejam realizados estudos de caracterização da madeira para a produção de celulose quanto a sua constituição química, anatômica e sua densidade (GOMIDE; FANTUZZI NETO; LEITE, 2004). Porém, é necessário considerar as diferenças existentes na composição do lenho das árvores e até mesmo entre os tecidos que o constituem (TRUGILHO et. al, 2007).

Segundo Foelkel (2015a), a qualidade da madeira não é de fácil definição e controle, devido a associação da própria variabilidade natural da madeira e dos inúmeros produtos com os quais esta é empregada como matéria-prima. O autor

ainda destacou que cada segmento industrial do setor florestal tem buscado opções de mensuração da qualidade, para que seja possível assegurar indicações eficientes e seguras para as tomadas de decisões nos processos que utilizam a madeira.

Entre as propriedades e características que são empregadas na avaliação da qualidade da madeira, a densidade básica é a que se destaca pela ampla utilização; uma vez que está relacionada com muitos aspectos tecnológicos e econômicos. Na produção de celulose, por exemplo, a avaliação da densidade permite inferir no rendimento e qualidade da polpa, bem como em propriedades do papel (PEREIRA et al., 2000, SHMULSKY; JONES, 2011; FOELKEL, 2015a).

Associados à densidade, existem outros parâmetros de qualidade, mas a densidade é largamente empregada, principalmente, em função de sua fácil mensuração e de suas correlações com outras características importantes da madeira, tais como a quantidade de massa, estrutura e proporção celulares, outras propriedades físicas e propriedades mecânicas, térmicas, acústicas e elétricas (BATISTA, 2012; FOELKEL, 2015b).

Contudo, a densidade básica pode variar em função de diversos fatores. Foelkel (2015b) destacou como principais causas de variabilidade da densidade básica: (i) espécie de eucalipto; (ii) material genético; (iii) idade das árvores na colheita; (iv) posição de amostragem da madeira (variações ao longo do comprimento e na direção medula-casca); e (v) influências das condições ambientais.

Visto que a densidade básica da madeira possui importante influência no processamento desta e que diversos fatores podem ocasionar sua variabilidade, causando indiretamente variabilidade das propriedades da madeira, torna-se importante implementar ferramentas para a quantificação e estimação da densidade.

O uso das redes neurais artificiais (RNAs) se destaca como uma ferramenta importante em estudos de predição das propriedades da madeira, e a ciência florestal já vêm utilizando a computação neurobiológica em alguns estudos (DIAMONTOPOULOU, 2005; GÖRGENS, 2006; RIBEIRO, 2007; STEIN, 2010, BINOTI et al., 2015; ZANETTI et al., 2015a; 2015b; LEITE et al., 2016; REIS, 2017; LOPES, 2018).

As RNAs, por definição de Haykin (2001), são um processador distribuído, massivamente paralelo, com capacidade de armazenar o conhecimento e torná-lo disponível. E, a partir de sua aplicação, soluções podem ser obtidas para problemas de aproximação de função, classificação de padrões, agrupamento de dados,

predição (séries temporais), otimização, recuperação de conteúdo e controle (JAIN; MAO; MOHIUDDIN, 1996; HAYKIN, 2001; BINOTI, 2010).

Estudos relativos à aplicação de RNAs na avaliação tecnológica da madeira e de seus derivados ainda são pouco encontrados na literatura. A título de exemplo apontamos os realizados por Ribeiro (2007), Stein (2010), Nunes et al. (2011), Leite et al. (2016), Zanuncio et al. (2016), Zanuncio et al. (2017) e Reis (2017).

Estes estudos propuseram e demonstraram que o uso de RNAs na avaliação tecnológica da madeira pode apresentar resultados importantes, com obtenção de redução da variabilidade das propriedades da madeira, processo e polpa celulósica, assim como, auxiliando na predição de características destes. E indicam, que o uso desta ferramenta pode influir em importantes resultados.

1.1. O problema e sua importância

Por se tratar de um material de origem biológica a madeira está passível a variações em sua constituição, em função de características genéticas pertinentes à espécie originada, assim como às do ambiente no qual a árvore se desenvolveu. O fenótipo é o resultado da interação entre estes fatores, o qual irá expressar o quanto características genéticas estarão suscetíveis às variações relacionadas ao ambiente local dos plantios florestais.

As florestas clonais de eucalipto, do Brasil, são referências mundiais quanto a ganhos em produtividade e qualidade da madeira, e inúmeras pesquisas foram e vêm sendo desenvolvidas para que estes resultados possam ser obtidos. Entretanto, é importante destacar que as condições edafoclimáticas nacionais também compreenderam importantes influências na adaptabilidade de espécies do gênero *Eucalyptus* no País.

Com base na extensão territorial do Brasil e as diferentes condições edafoclimáticas nele observadas, o setor florestal está sujeito a diversos desafios setoriais referentes aos diferentes fenótipos que poderão ser expressos pelas florestas clonais de eucalipto plantadas ao longo de todo o território nacional.

Além de enfrentar os desafios decorrentes as expressões fenotípicas, o setor florestal compreende a produção e transformação da madeira para diversos produtos; os quais demandam propriedades específicas no processamento e respectivos produtos finais. De maneira que, cada produto requer uma combinação das

propriedades da madeira; sejam anatômicas, químicas e, ou físicas, que atendam as particularidades de seus processamentos e sua qualidade final requerida.

No seguimento de celulose e papel, o processamento químico Kraft da madeira para obtenção de polpa celulósica é mundialmente o mais empregado. Quando comparado a outros processos químicos, ou a processos mecânicos e às associações entre estes, o Kraft não se correlaciona à obtenção de maiores rendimentos. Contudo, sua versatilidade na aplicação a uma ampla variedade de espécies madeireiras, como fonte de matéria-prima, e na obtenção de polpas de alta qualidade o designam a tal posição.

Porém, é importante destacar que mesmo que a aplicação do processo Kraft possa ser destinada a diferentes espécies madeireiras, é preciso que sejam empregadas matérias primas homogêneas na polpação, permitindo que possíveis falhas no processo sejam minimizadas e atendendo a produção do papel, que demanda polpa celulósica com propriedades homogêneas para que a qualidade requerida dos papéis produzidos seja alcançada.

A utilização de matérias primas homogêneas não está somente relacionada a ganhos em qualidade do produto final, mas também às diferentes etapas que compreendem o processo para obtenção de celulose, de modo que estas possam ser ajustadas em função das características da madeira.

Variações na densidade e composição química deste material têm efeito, por exemplo, no aumento do consumo de químicos e do consumo específico (m^3 de madeira por tonelada de celulose) e na redução do rendimento, os quais, por consequência, acarretam em aumento dos custos de produção. Já variações na composição anatômica da madeira, principalmente, associadas às dimensões celulares, podem ocasionar variações nas propriedades do papel.

Com base nas informações apresentadas, é importante entender como as variações nas propriedades da madeira influenciam seu processamento e a qualidade do produto final, e a predição destas propriedades pode ser empregada como uma ferramenta de qualidade no processamento para obtenção de polpa celulósica. Deste modo, lança-se aqui como questão central e direcionadora desta pesquisa: como se pode prever variáveis associadas a seleção destes materiais?

Como hipóteses desta pesquisa, têm-se que a aplicação de modelagem matemática por RNAs, na estimação de propriedades da madeira, como alternativa para a predição da densidade básica da madeira destes materiais.

A relevância desta pesquisa está em fornecer informações aos integrantes do setor florestal, sejam produtores de madeira ou indústrias que utilizam a madeira como fonte de matéria-prima, auxiliando a obtenção de materiais adequados aos seus processos e à qualidade final requerida. A predição da densidade da madeira permitirá que os processos sejam ajustados com maior precisão à matéria-prima utilizada, de forma que sejam contempladas variações em função da idade e da localização dos plantios florestais

1.2. Objetivos

1.2.1. Objetivo geral

Objetiva-se nesse trabalho aplicar modelagem por redes neurais artificiais na estimativa da densidade básica da madeira de eucalipto destinada à produção de celulose.

1.2.2. Objetivos específicos

- i. Avaliar a aplicação de RNAs no estudo da qualidade da madeira de eucalipto para produção de celulose, mediante modelagem da densidade básica da madeira em função de dados de inventário das árvores e características dos locais de plantio das árvores;
- ii. Avaliar a aplicação de RNAs na modelagem da densidade básica da madeira de eucalipto para regiões: Aracruz (REG-1), São Mateus (REG-2) e Bahia (REG-3);
- iii. Avaliar a aplicação de RNAs na modelagem da densidade básica da madeira de eucalipto para classes de idade: dois a quatro anos (CLAS-1), quatro a seis anos (CLAS-2) e seis a oito anos (CLAS-3);
- iv. Empregar regressão linear múltipla como um parâmetro para avaliar o desempenho das técnicas RNAs na modelagem da densidade básica da madeira de eucalipto.

2. REVISÃO DE LITERATURA

2.1. Madeira de eucalipto como fonte de matéria-prima

A área de florestas plantadas no Brasil ocupou 7,84 milhões de hectares no ano de 2016, conforme reportado pela Indústria Brasileira de Árvores – IBÁ (2017), os quais compuseram mais de 90% de toda a madeira consumida como matéria-prima para fins industriais e corresponderam a mais de 6,2% do PIB Industrial no País.

De acordo com a mesma publicação, inúmeras empresas de diversos seguimentos compõe o setor de atividade florestal, e de forma acentuada os segmentos que demonstraram maior atuação em áreas de plantios florestais, respectivamente, foram: celulose e papel, produtores independentes e fomentados, siderurgia e carvão vegetal, painéis de madeira e pisos laminados e produtos sólidos de madeira.

Entre os anos de 1967 e 1988, foi verificada no Brasil uma expansão da oferta de madeira de florestas plantadas em decorrência ao programa de incentivos fiscais praticado, no qual foram investidos cerca de US\$10 bilhões e em que, até o ano de 1985, foram implementados 6 milhões de hectares de florestas plantadas, dos quais 65% eram representados por florestas de eucalipto (NAHUZ, 2007).

Hoje, a base florestal plantada brasileira consiste em intensa implementação de espécies de eucalipto e pinus. No ano de 2016, as florestas de eucalipto ocuparam 5,67 milhões de hectares da área de árvores plantadas, representando 72% deste total, enquanto os plantios de pinus compreenderam 1,58 milhão de hectares (IBÁ, 2017).

Os plantios de eucalipto ocupam diversos estados do país e estão localizados principalmente nos Estados de Minas Gerais (24%), São Paulo (17%) e Mato Grosso do Sul (15%). Como maior segmento consumidor de madeira nacional também observamos que a distribuição geográfica das empresas produtoras de celulose e papel nacionais acompanha a dispersão destes plantios florestais e, assim como os plantios, se encontram em maior concentração nas regiões Sul e Sudeste, e em partes das regiões Centro-Oeste e Nordeste (IBÁ, 2017).

O gênero *Eucalyptus* foi introduzido comercialmente no Brasil a pouco mais de um século, onde foram testadas suas espécies mais promissoras; como fonte de matéria-prima para suprir a necessidade de lenha, postes e dormentes. Posteriormente, foi empregado na indústria de celulose e papel e na produção de carvão vegetal (QUEIROZ e BARRICHELO, 2007; DOSSA et al., 2010).

Edmundo Navarro de Andrade foi o precursor da introdução comercial do eucalipto no Brasil. O engenheiro agrônomo confiante nas observações feitas em campo nas árvores das diferentes espécies do gênero, buscou desenvolver pesquisas técnicas que comprovassem a aplicação deste material como fonte de matéria-prima em diversos seguimentos. Foi então, que em 1925 viajou aos Estados Unidos para testar o uso do eucalipto na produção de papel, contudo, o pesquisador obteve resultados que não satisfizeram aos consumidores brasileiros, pois a folha não era suficientemente resistente para a impressão de jornal (QUEIROZ e BARRICHELO, 2007).

O primeiro relato de fabricação de celulose e papel a partir da madeira de eucalipto no Brasil foi em Jundiaí pela empresa Gordinho Braune & Cia, por volta de 1927, com produção de 10 toneladas diárias e composição do papel com 75% de fibras de eucalipto e o demais fibras de *Araucaria angustifolia*. Somente 30 anos depois, a empresa Suzano foi quem produziu papel branco com 100% de fibras de eucalipto (FOELKEL, 2013).

Diante da excelência verificada na introdução de espécies deste gênero, em 1939 foi publicado o primeiro 'handbook' sobre produção de mudas, cultivo e manejo do eucalipto, que também incluía detalhes sobre os períodos de corte e suas indicações (QUEIROZ e BARRICHELO, 2007). Desde então, diversos estudos sobre sua implantação, desenvolvimento e qualidade da madeira foram desenvolvidos, evidenciando a superioridade do cultivo de eucalipto no Brasil.

A implementação das florestas de eucalipto foi marcada pelo rápido crescimento das árvores, por terem se adaptado bem às condições edafoclimáticas nacionais e devido a sua grande diversidade de espécies, que possibilitaram esta adaptação a diferentes tipos de clima e solo, além de sua utilização para diversos fins (PONCE, 1995; AMPARADO et al., 2008; DOSSA et al., 2010).

Nas últimas décadas, a produtividade por hectare por ano destas florestas progrediram de $15 \text{ m}^3.(\text{ha.ano})^{-1}$, nos anos 70, para cerca de $35,7 \text{ m}^3.(\text{ha.ano})^{-1}$ em

média no ano de 2016, podendo ser observadas máximas de até 60 m³.(ha.ano)⁻¹ (QUEIROZ e BARRICHELO, 2007; FOELKEL, 2013; IBÁ, 2017).

Antônio Joaquim de Oliveira, mencionado por Queiroz e Barrichelo (2007), ressaltou que para o cultivo de eucalipto no Brasil alcançar níveis tão produtivos, foi necessário que pesquisadores de todo o país investissem primeiro na seleção de espécies, depois em árvores com as características mais desejadas e a partir de então na clonagem, que é atualmente a base da cultura de eucalipto.

O gênero eucalipto possui mais de 700 espécies, e é considerado muito importante para a economia de mais de 100 países. No Brasil, o híbrido “urograndis” (*Eucalyptus grandis* x *Eucalyptus urophylla*) compreende a maior área plantada, destacando-se também os plantios das espécies *Eucalyptus grandis*, *Eucalyptus camaldulensis*, *Eucalyptus cloeziana*, *Eucalyptus dunnii* e *Eucalyptus citriodora* (SILVA e CASTRO, 2014).

O Brasil é hoje o maior produtor de celulose branqueada de fibra curta do mundo e o segundo principal produtor mundial do segmento de celulose, considerando-se o processo químico de fibra curta (eucalipto) e longa (pinus) e a pasta de alto rendimento. Títulos aos quais foram alcançados em virtude do emprego do eucalipto como matéria-prima, devido a associação da alta produtividade a curtos ciclos silviculturais e a qualidade apresentada pela madeira (SILVA e CASTRO, 2014; IBÁ, 2017).

2.2. Qualidade da madeira de eucalipto para a produção de celulose

A produção mundial de polpa celulósica no ano de 2015 atingiu 175,2 milhões de toneladas, de modo que, em 2016, Estados Unidos e Brasil foram os maiores produtores mundiais. Já a produção mundial de papel, que alcançou 400,1 milhões de toneladas em 2015, apresentou em 2016 a China como maior produtora e o Brasil ocupando a oitava posição neste *ranking* (Tabela 1) (FAO – Food and Agriculture Organization of the United Nations, 2017; IBÁ, 2017).

O processamento químico para obtenção de polpas celulósica foi o mais empregado nos últimos anos, a qual foi empregada como fonte de matéria-prima para produção de diversos tipos de papel, dentre os quais se destacam: papéis para embalagens, papéis para imprimir e escrever, papéis domésticos e sanitários (tissue) e papel jornal (FAO, 2017).

Tabela 1: Principais países produtores de celulose e papel no ano de 2016.

Celulose			Papel		
País	Produção*		País	Produção*	
1º EUA	48,5		1º China	111,2	
2º Brasil	18,8		2º EUA	72,4	
3º Canadá	17,0		3º Japão	26,4	
4º China	16,8		4º Alemanha	22,6	
5º Suécia	11,5		8º Brasil	10,3	

*Milhões de toneladas.

Fonte: Adaptado de IBÁ (2017).

As características dos diversos tipos de papel se diferenciam devido a particularidades de suas aplicações finais. Para impressão e escrita, é preciso que os papéis sejam provenientes de polpas branqueadas e apresentem altos teores de alvura, sejam resistentes à tração e ao rasgo, apresentem bom acabamento superficial e sejam estáveis dimensionalmente. Já papéis para embalagem necessitam também de resistência à tração e ao rasgo e estabilidade dimensional, contudo, geralmente não são branqueados (SANTOS, 2005; SHMULSKY e JONES, 2011).

Papéis domésticos e sanitários (*tissue*) precisam apresentar parâmetros de maciez, resistência à tração, absorvência e também é preciso que sejam procedentes de polpas branqueadas. Já o papel jornal precisa ser resistente, para ser empregado em prensas de impressão rápida, possuir boa superfície de impressão e ser de baixo custo (SANTOS, 2005; SHMULSKY e JONES, 2011).

No Brasil, as polpas celulósicas empregadas na produção de papel utilizam a madeira como fonte de matéria-prima, especialmente as provenientes de eucalipto e pinus (ANDRIONI, 2006). Gouvêa et al. (2009), destacaram que a qualidade da madeira é importante quando o objetivo é a produção de polpa celulósica e as variáveis relacionadas a este processo, assim como suas propriedades, são alteradas em função desta matéria-prima. Os autores ainda destacaram que o desafio da indústria de celulose e papel é a seleção de material adequado ao seu produto.

Diferenças são verificadas nas espécies utilizadas para produção de polpas celulósicas, desde os aspectos silviculturais, até as propriedades que determinam a qualidade de suas madeiras. Estas diferenças conferem às respectivas polpas

celulósicas variações em suas propriedades, que podem ser exploradas para produção de papéis com características específicas, de forma a atingir mercados mais exigentes e proporcionar maiores retornos sobre os investimentos realizados pelas indústrias de celulose e papel (DUARTE, 2007).

Para a classificação de materiais de qualidade superior é necessário que sejam realizados estudos de caracterização da madeira para a produção de celulose quanto a sua constituição química, anatômica e sua densidade (GOMIDE; FANTUZZI NETO; LEITE, 2004). Porém, é necessário considerar as diferenças existentes na composição do lenho das árvores e até mesmo entre os tecidos que o constituem (TRUGILHO et al., 2007).

Foelkel (2013) afirmou que a propriedade mais desejada em indústrias de celulose é a uniformidade da matéria-prima, seja ela proveniente de qualquer essência florestal e, nesta mesma publicação, enumerou e elucidou as onze características vitais das madeiras dos eucaliptos relacionadas à fabricação de celulose Kraft branqueada, dentre as quais destaca-se a densidade básica da madeira.

O autor também destacou que, variações na densidade da madeira influenciam no custo e no rendimento de processo industrial, sobretudo na qualidade da polpa e dos papéis, e sua uniformidade permite melhor controle na gestão dos fluxos de massa e da variabilidade do processo.

Ainda na mesma publicação, o autor pontua critérios de qualidade da madeira de eucalipto comparados aos de madeiras de fibras longas, para a espécie de *Pinus taeda* e o híbrido *Eucalyptus grandis* x *Eucalyptus urophylla* (Tabela 2). Quando comparadas características das madeiras de eucalipto a das coníferas, maiores valores de densidades resultam em menores consumos específicos, os quais associados a menores percentuais de lignina impactaram diretamente em maiores rendimentos.

A densidade básica da madeira é destacada como uma das principais características quando se pretende avaliar a qualidade da madeira, pois está relacionada com muitos aspectos tecnológicos e econômicos. Na produção de celulose, a avaliação da densidade permite inferir em características do processo, bem como uma série de propriedades do papel (PEREIRA et al, 2000, SHMULSKY; JONES, 2011).

Tabela 2: Exemplos de propriedades e comportamentos de polpação Kraft para diferentes tipos de madeiras, para a espécie de *Pinus taeda* e o híbrido *Eucalyptus grandis x Eucalyptus urophylla*.

Propriedade	Madeira	
	<i>E. grandis x E. urophylla</i>	<i>Pinus taeda</i>
Densidade básica da madeira (g.cm ⁻³)	0,50	0,38
Teor Lignina Klason total (% base madeira)	28	32
Número kappa na polpa (digestor)	16 - 18	23 - 25
Rendimento do cozimento kraft (%)	51 - 54	43 - 45
Fator H	400 - 600	1000 - 1500
Carga de Álcali Efetivo (% como NaOH)	17 - 20	23 - 24
Consumo específico madeira* m ³ .(ton polpa) ⁻¹	3,6 – 3.8	~ 6

*Polpa não branqueada.

Fonte: Adaptado de Foelkel (2013).

Relativo ao processo de obtenção da polpa celulósica, verifica-se influência direta da densidade na madeira em diversas etapas do processamento, desde a formação dos cavacos (dimensionamento e densidade a granel dos cavacos), durante o processamento (teor de rejeitos, consumo específico de madeira [m³.tonelada polpa⁻¹], consumo de álcali efetivo e rendimento depurado) e em propriedades da polpa (viscosidade e consumo de energia no refino) (QUEIROZ, 2004; RIBEIRO, 2007; STEIN, 2010).

Fantuzzi Neto (2012) destacou que as maiores espessuras dos cavacos, formados das madeiras mais densas, resultam em maior dificuldade de impregnação dos mesmos, o que conseqüentemente é compensado por uma maior carga alcalina, sendo prejudicial para o rendimento do processo. Como conclusão às análises de correlação realizadas em seu estudo, o autor identificou correlações significativas positivas entre a densidade e os consumos de álcali e específico.

Segundo Panshin e De Zeeuw (1980), a densidade resulta da interação entre as propriedades químicas e anatômicas da madeira, variando em função de

diferenças nas dimensões celulares, interações entre estes fatores e pelo teor de extrativos por unidade de volume no lenho.

As principais causas de variabilidade da qualidade da madeira, por extensão de sua densidade básica, como sendo relacionadas a: (i) espécie, (ii) material genético, (iii) idade da árvore, (iv) posição de amostragem (base-topo e medula-casca) e (v) condições ambientais (FOELKEL, 2015b).

A densidade da madeira possui grande influência do genótipo e está intimamente relacionada ao complexo processo de formação da madeira, incluindo a diferenciação das iniciais cambiais em vários tecidos do xilema, alongamento das células e a síntese da parede celular secundária. E por isso, relaciona-se também às condições de crescimento das árvores, onde verifica-se significativa correlação entre as variações climáticas, a exemplo da temperatura, precipitação e solo, e a densidade da madeira (SWENSON e ENQUIST, 2007; MA et al., 2015).

É importante destacar que as variações nas dimensões das fibras, além de afetarem diretamente a densidade básica da madeira, influenciam as propriedades do papel. Fibras com paredes finas resultam em papéis com menor resistência ao estouro e a tração, mas com alta resistência ao rasgo, porém, papéis produzidos com fibras de paredes espessas, possuem alta resistência à dobra. O comprimento das fibras é outra característica que afeta as propriedades do papel, com a resistência ao rasgo sendo a propriedade mais afetada, em que geralmente, quanto maior o comprimento das fibras, maior será a resistência ao rasgo (SHMULSKY; JONES, 2011).

Ainda sobre o impacto das fibras na qualidade dos papéis, ressalta-se que variações nas dimensões celulares resultam em variações do volume específico aparente (bulk), porosidade, absorção de líquidos, acabamento superficial e maciez dos papéis formados (FOELKEL, 2009).

O coarseness também é uma propriedade utilizada na avaliação da qualidade na produção de celulose, sendo expresso como massa em miligramas de polpa por 100m de comprimento de fibras, estando relacionados com as propriedades físico-mecânicas e com as características superficiais do produto final (PEDRAZZI et al., 2013).

Segundo Carpim et al. (1987), citado por PEDRAZZI et al. (2013), o coarseness depende do teor de carboidratos das polpas celulósicas, e principalmente da

densidade da madeira, isto é, para um mesmo comprimento de fibra, madeiras mais densas terão maior coarseness.

2.3. Redes neurais artificiais

Uma rede neural artificial (RNA) é um conjunto interligado de neurônios de processamento simples, cujo funcionamento é inspirado no sistema nervoso dos seres vivos. Possui a capacidade de aprender através de exemplos e generalizar a informação, por meio de um conjunto de unidades de processamento, caracterizadas como unidades de neurônios artificiais (GURNEY, 1997; BRAGA; CARVALHO; LUDERMIR, 2000; SILVA; SPATTI; FLAUZINO, 2010).

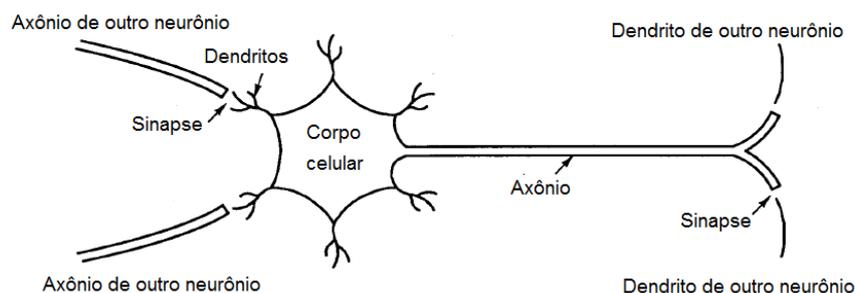
Segundo Haykin (2001), uma rede neural, em sua forma mais geral, “[...] é uma máquina que é projetada para modelar a maneira como o cérebro realiza uma tarefa particular ou função de interesse [...]”, com propensão natural em armazenar conhecimento e torna-lo disponível para uso.

A teoria e projeto de RNA têm avançado significativamente nos últimos anos, porém, foi em 1943 que o trabalho inicial foi publicado por McCulloch e Pitts, respectivamente um neurobiólogo e um estatístico, sendo um artigo seminal intitulado "Um cálculo lógico das ideias iminentes na atividade do sistema nervoso" no Boletim de Matemática Biofísica (HU e HWANG, 2001).

Os neurônios que compõe as RNA são biologicamente inspirados, ou seja, eles são compostos por elementos de uma maneira análoga à das funções mais elementares dos neurónios biológicos (KHARE e NAGENDRA, 2007). Portanto, a estrutura individual de cada neurônio, os tipos de suas conexões e o comportamento do conjunto dos neurônios naturais formam a base para o estudo de RNAs (BRAGA; CARVALHO; LUDERMIR, 2000).

O neurônio é a unidade fundamental do sistema nervoso biológico e apresenta como principal papel a condução de impulsos. Tal elemento biológico pode ser dividido em três partes principais (Figura 2): dendritos, corpo celular e axônio (SILVA; SPATTI; FLAUZINO, 2010; KHARE e NAGENDRA, 2007).

Figura 2 – Neurônio biológico.



Fonte: Adaptado de Fausett (1997).

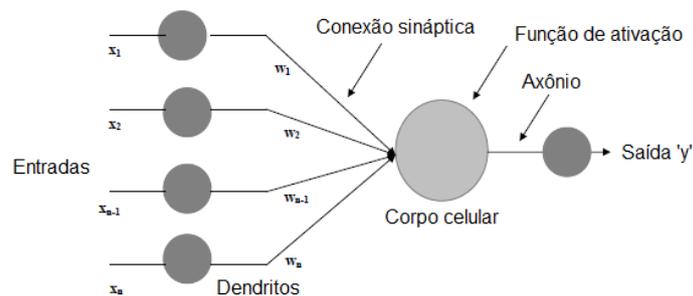
Os dendritos são vários prolongamentos que associados formam a árvore dendrital. Eles captam os estímulos de outros neurônios (neurônios conectores) ou do meio externo (neurônios sensitivos), por meio de sinais em forma de impulsos elétricos, e os conduzem até o corpo celular (SILVA; SPATTI; FLAUZINO, 2010; KHARE e NAGENDRA, 2007; FAUSETT, 1994).

No corpo celular, as informações recebidas por meio dos dendritos são processadas e novos impulsos são gerados, os quais são transmitidos a outros neurônios, através do axônio. O axônio é constituído por um único prolongamento, e o ponto de contato entre a terminação axônica de um neurônio e o dendrito de outro neurônio é denominada sinapse. Portanto, por meio das sinapses ocorre a conexão que viabiliza a transferência de impulsos elétricos de um neurônio a outro (SILVA; SPATTI; FLAUZINO, 2010; BRAGA; CARVALHO; LUDERMIR, 2000).

Nas RNA os neurônios artificiais são a unidade processadora de informação, e seu modelo mais simples (Figura 3), que engloba as principais características de uma rede neural biológica, envolvendo paralelismo e conectividade, foi proposto por McCulloch e Pitts (MCP) em 1943 (SILVA; SPATTI; FLAUZINO, 2010).

Este modelo é constituído de n entradas x_1, x_2, \dots, x_n (dendritos) e uma saída y (axônio). Cada entrada está associada a um peso w_1, w_2, \dots, w_n que representam as sinapses, os quais podem ser positivos ou negativos. São calculadas as somas ponderadas $x_i w_i$ dos valores recebidos, e quando este valor ultrapassa o limiar do neurônio, este “dispara” ativando a função de ativação e gerando saída (BINOTI, 2010).

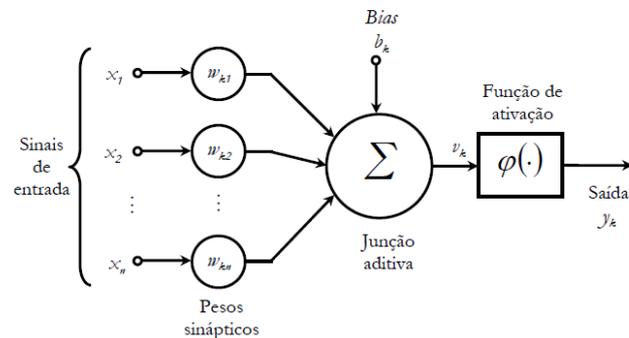
Figura 3 – Neurônio de McCulloch e Pitts.



Fonte: Adaptado de Khare e Nagendra (2007).

Porém, algumas limitações do modelo MCP original foram levantadas, e atualmente um modelo básico de neurônio artificial pode ser representado pela Figura 4.

Figura 4 – Estrutura do neurônio artificial.



Fonte: Haykin (2001).

Haykin (2001) apresentou três elementos básicos que podem ser destacados da estrutura deste neurônio:

- i. Sinapses: também denominadas elos de entrada, são caracterizadas por pesos. Um sinal x_j na entrada da sinapse j conectada ao neurônio k é multiplicado pelo peso sináptico w_{kj} que pode compreender valores negativos e positivos.
- ii. Junção aditiva: soma os sinais de entrada, ponderados pelas respectivas sinapses (pesos) dos neurônios.
- iii. Função de ativação: também referida como função restritiva, pois restringe a amplitude da saída de um neurônio, a qual tipicamente é

escrita como o intervalo unitário fechado $[0,1]$ ou alternativamente $[1,1]$, e responsável pela geração das saídas y do neurônio.

Além dos elementos destacados, Haykin (2001) descreve também o bias (b_k), que apresenta efeito de aumentar ou diminuir a entrada líquida da função de ativação, quando positivo ou negativo, respectivamente.

A forma como os neurônios estão organizados ou dispostos, uns em relação aos outros, define a arquitetura da RNA. Sua definição é importante durante a construção da RNA, pois restringe o tipo de problema que pode ser tratado pela rede (SILVA; SPATTI; FLAUZINO, 2010; BRAGA; CARVALHO; LUDERMIR, 2000).

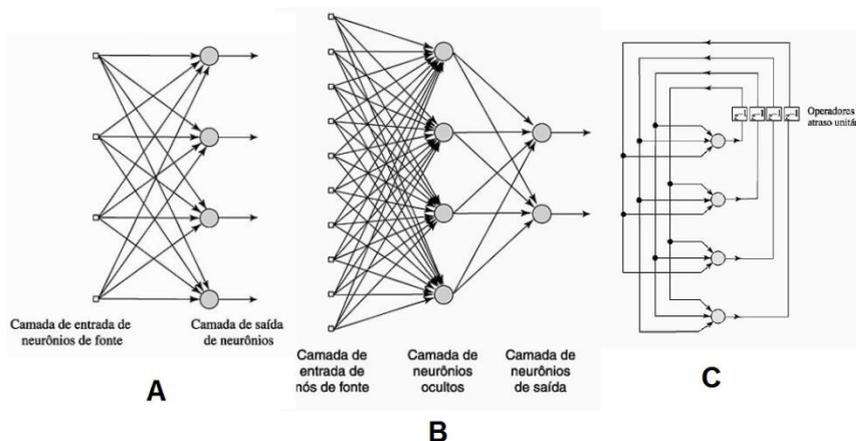
Segundo Braga, Carvalho e Ludermir (2000), fazem parte da definição da arquitetura de uma RNA os seguintes parâmetros: número de camadas da rede, número de neurônios em cada camada, tipo de conexão e topologia da rede.

Entre as principais arquiteturas de redes neurais artificiais, considerando a disposição de seus neurônios, suas conexões e a constituição de suas camadas, podemos dividi-las em: redes *feedforward* (alimentação à frente) de camada simples, redes *feedforward* de camadas múltiplas, redes recorrentes e redes reticuladas (SILVA; SPATTI; FLAUZINO, 2010).

Na arquitetura *feedforward* de camada simples (Figura 5a), observamos apenas uma camada de entrada e uma única camada de neurônios, que já configuram a própria camada de saída. Entre os principais tipos de redes com essa arquitetura estão o *Perceptron* e o *Adaline*, as quais são tipicamente empregadas em problemas envolvendo classificação de padrões e filtragem linear (SILVA; SPATTI; FLAUZINO, 2010).

Já a arquitetura *feedforward* de camadas múltiplas (Figura 5b), se distingue da anterior devido a presença de uma ou mais camadas ocultas, cujos neurônios que as compõe são chamados de neurônios ocultos ou unidades ocultas. Estes neurônios ocultos apresentam como função a intervenção entre a entrada externa e a saída da rede de maneira útil, de forma a tornar a rede capaz de extrair estatísticas de ordem elevada (HAYKIN, 2001). As RNAs com estas arquiteturas são utilizadas na solução de problemas tais como aproximação de função, classificação de padrões, identificação de sistemas, otimização, robótica e controle de processos, sendo os principais tipos *Perceptron* multicamadas (MLP) e as redes de base radial (RBF) (SILVA; SPATTI; FLAUZINO, 2010).

Figura 5 – Arquiteturas de redes: (a) rede alimentada *feedforward* de camada simples, (b) redes *feedforward* de camadas múltiplas e (c) redes recorrentes.



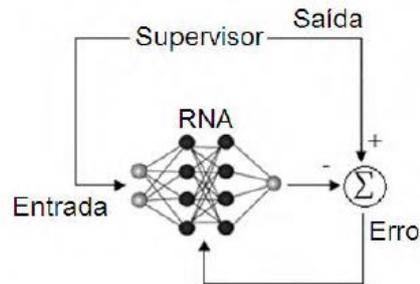
Fonte: Adaptado de Haykin (2001).

Redes neurais recorrentes (Figura 5c) são diferenciadas das redes *feedforward* por possuírem um laço de realimentação, pois as saídas dos neurônios são realimentadas como sinais de entrada para outros neurônios, o que impacta na capacidade de aprendizagem da rede e no seu desempenho. Entre os principais tipos de redes que possuem realimentação, destacam-se a rede de Hopfield e a rede *Perceptron* multicamadas com realimentação entre neurônios situados em camadas distintas (SILVA; SPATTI; FLAUZINO, 2010; HAYKIN, 2001).

Uma característica relevante das RNAs é a capacidade destas de aprender por meio da apresentação de amostras (padrões) que demonstram um comportamento, sendo em seguida, após a aprendizagem da relação entre entradas e saídas, capazes de generalizar soluções. A etapa de aprendizagem consiste na aplicação de um conjunto de procedimentos para que a RNA possa aprender determinada função, sendo este conjunto denominado algoritmos de aprendizado (SILVA; SPATTI; FLAUZINO, 2010; BRAGA; CARVALHO; LUDERMIR, 2000).

O aprendizado supervisionado é o mais comum em RNAs, sendo chamado de supervisionado porque as entradas e saídas desejadas são fornecidas por um supervisor externo (Figura 6). Desta maneira, cada entrada submetida à rede gera uma saída calculada, que é comparada à resposta desejada, para que os pesos possam ser ajustados e o erro seja minimizado (BINOTI, 2010; BRAGA; CARVALHO; LUDERMIR, 2000).

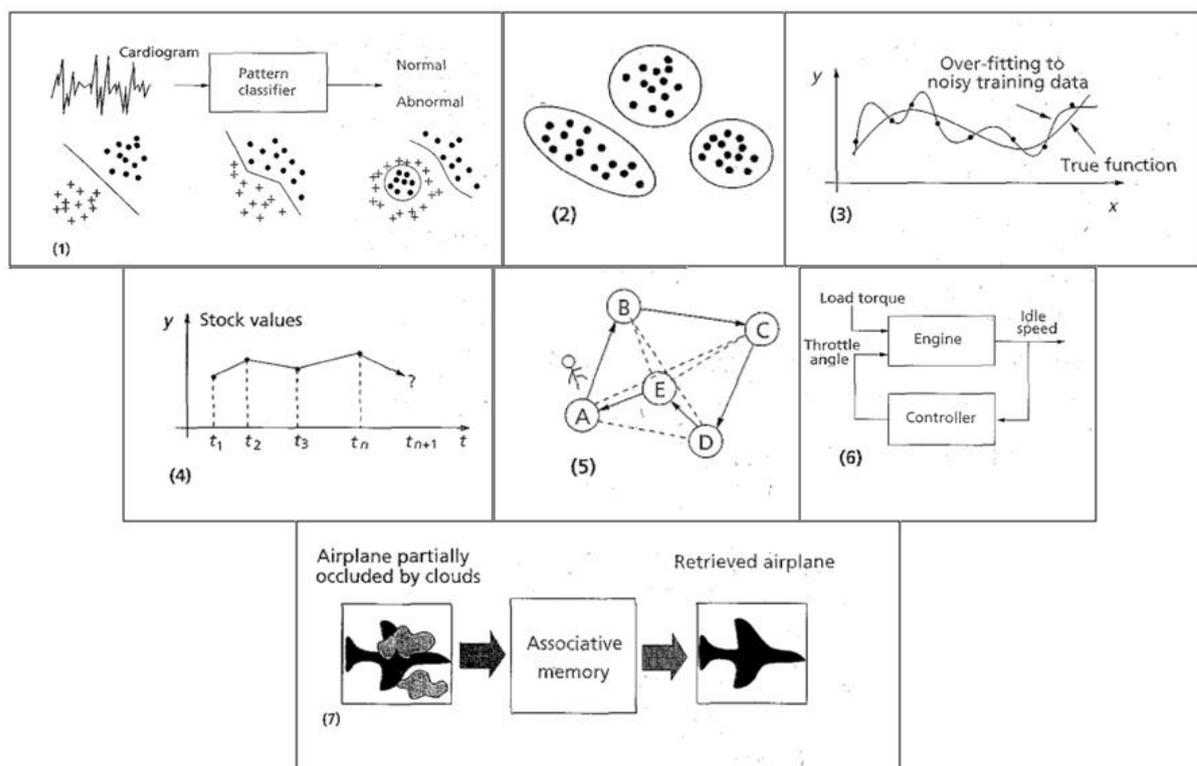
Figura 6 – Aprendizado supervisionado.



Fonte: Binoti (2010).

De forma geral, Jain Mao e Mohiuddin (1996) enumeraram os problemas tratáveis através de redes neurais que se enquadram nas tarefas de aprendizagem: classificação de padrões, agrupamento de dados, aproximação de função, predição (séries temporais), otimização, recuperação de conteúdo e controle (Figura 7).

Figura 7 – Tarefas da aprendizagem em RNA: (1) classificação de padrões, (2) agrupamento de dados, (3) aproximação de função, (4) predição, (5) otimização, (6) controle e (7) recuperação de produto.



Fonte: Adaptado de Jain, Mao e Mohiuddin (1996).

Estudos relativos à aplicação de RNAs na avaliação tecnológica da madeira e de seus derivados ainda são pouco encontrados na literatura, porém, alguns estudos realizados nas últimas décadas mostram que esta ferramenta pode ser empregada na solução de problemas desta área, principalmente aplicando tarefas de aprendizagem para aproximação de funções e classificação de padrões.

Avramidis e Iliadis (2005) empregaram as RNAs na predição da condutividade térmica da madeira, a partir de condições de teor de umidade, temperatura e densidade aparente da madeira, segundo dados de diferentes espécies disponíveis em literatura. Ao concluir as análises, foram verificados pelos autores $R^2=0,9994$ e $RMS=0,0123$, provando assim que o modelo desenvolvido é uma abordagem confiável com capacidade preditiva para a estimativa da condutividade térmica.

Já os autores Qi, Zhang e Yu (2008), empregaram técnicas de reconhecimento de padrões para detecção de defeitos por RNAs, a partir de características visuais dos parâmetros de defeitos de madeira extraídos de imagens digitais. Deste modo, obtiveram resultados que permitiram identificar defeitos internos como nós, rachaduras e podridão por algoritmos *Backpropagation*.

Em outra abordagem, Ribeiro (2007) propôs a modelagem por meio de RNAs para predição do grau de cozimento Kappa, a qual possibilitou ações operacionais mais proativas e conseqüente redução da variabilidade desta propriedade.

Em seguida, Stein (2010) desenvolveu modelagem a partir de dados da indústria de celulose Kraft empregando modelos aditivos generalizados e redes neurais artificiais, como ferramentas para avaliar a influência de algumas variáveis, da madeira e do processo, sobre a produção do digestor e carga alcalina. As RNAs foram utilizadas para relacionar a produção do digestor e a carga alcalina, com as variáveis: densidade da madeira, idade, precipitação, teor de umidade dos cavacos, densidade aparente dos cavacos, densidade básica dos cavacos, viscosidade da polpa e Kappa. Os autores, consideraram a aplicação de RNAs uma boa ferramenta, visto que foram obtidas correlações entre densidade e a produção do digestor e a carga alcalina acima de 88% e 60%, respectivamente.

São diversas as pesquisas que empregaram as RNAs como ferramenta para estimar propriedades da madeira e, ou, parâmetros relacionados ao seu processamento. Outro exemplo, é o trabalho de Nunes et al. (2011) que desenvolveram modelos utilizando RNAs para estimar a relação siringil:guaiacil (S:G)

e os percentuais de celulose, hemiceluloses e lignina na madeira de eucalipto, e como conclusão, destacaram que as RNAs apresentaram melhor desempenho na estimativa do teor de hemiceluloses e da relação S:G.

Yapici et al. (2015) também aplicaram RNAs para estimativa de propriedades da madeira. Os autores estimaram a resistência a compressão paralela a grã, a partir de dados das condições de tratamento térmico dado a madeira de *Pinus sylvestris* e demonstraram que o uso de RNAs foi eficiente na predição desta propriedade mecânica, com correlações de 97,33%.

Já Leite et al. (2016) empregaram as RNAs na predição da densidade básica da madeira, no qual concluíram que a estimativa desta propriedade a partir de dados obtidos no inventário florestal foi satisfatória por meio desta ferramenta.

A empregabilidade de RNAs na predição da qualidade de painéis aglomerados produzidos com madeira de *Eucalyptus grandis* foi avaliada por Melo e Miguel (2016). Os autores consideraram o tipo de adesivo empregado na produção dos painéis e a densidade final dos mesmos, como variáveis de entrada, para estimar as propriedades físicas (densidade, absorção de água após 24 horas de imersão e inchamento em espessura após 24 horas de imersão) e mecânicas (resistência a flexão estática e ligação interna) destes painéis. Como conclusão, verificaram que todas as propriedades avaliadas com uso desta técnica apresentaram modelos com ajustes superiores a 0,90.

Zanuncio et al. (2016) e (2017) avaliaram redes neurais artificiais como nova ferramenta para predição de propriedades físicas, mecânicas e colorimétricas da madeira. As RNAs baseadas na densidade básica e no tempo de secagem apresentaram alta precisão para avaliar e monitorar a umidade da madeira (ZANUNCIO et al., 2016) e demonstraram potencial no controle de processos de termorreificação deste material (ZANUNCIO et al., 2017).

Já Reis (2017), estimou as propriedades físico-mecânicas de madeiras da Amazônia a partir da densidade básica utilizando RNAs. A autora, estimou contração (tangencial, radial e volumétrica), flexão estática, compressão paralela e perpendicular às fibras, dureza Janka paralela e transversal, tração, fendilhamento e cisalhamento. Como uma das principais conclusões, foi verificado que as redes estimaram com alta precisão as propriedades mecânicas.

Os trabalhos desenvolvidos empregando as redes neurais artificiais como ferramentas para avaliação de propriedades da madeira e, ou, seu desempenho

durante o processamento ressaltam a capacidade desta ferramenta para a classificação de materiais a serem empregados na produção de celulose.

Diversas variáveis e configurações entre estas podem ser consideradas no estudo das RNAs, sejam elas associadas as propriedades da madeira, ao local de implementação dos plantios florestais, entre outras, de forma que, a seleção de materiais para a produção de celulose possa ser realizada em função de propriedades estimadas, a exemplo da densidade, permitindo a obtenção de máxima qualidade e rendimento da madeira para a produção de celulose.

2.4. Análise de regressão

O termo “regressão” foi abordado pela primeira vez em 1885 por Sir Francis Galton, em um estudo para demonstrar a relação entre a altura de filhos e de seus pais, e esta análise, denominada análise de regressão, refere-se a diferentes técnicas estatísticas que servem de base para inferências sobre relações entre duas ou mais variáveis (MYERS, 1989).

Segundo Ribeiro Júnior (2013), na análise de regressão linear simples são estudadas as relações entre duas variáveis, com base em dados de n pares de valores observados, a partir da qual é possível estimar os valores de uma variável resposta, dependente ou explicada (Y) quando se conhecem os valores de uma variável independente ou explicativa (X), com qual a Y se relaciona.

Dada a relação entre os pares $X_i Y_i$ das variáveis X e Y , com i variando de 1 a n , e admitindo-se que Y é função linear de X , é possível estabelecer um modelo de regressão linear simples, o qual é apresentado na Equação 1. Onde Y_i é o valor de Y na observação i , β_0 é a constante da regressão, β_1 é o coeficiente de regressão, X_i é o valor de X na observação i e ε_i erro aleatório associado ao valor observado Y_i (HOFFMANN, 2006; RIBEIRO JÚNIOR, 2013):

$$Y_i = \beta_0 + \beta_1 X_i + \varepsilon_i \quad (1)$$

A análise de regressão é uma técnica de análise estatística largamente utilizada e versátil, sendo projetada para explorar todos os tipos de relações de dependência. Estas relações podem ser expressas em função uma única variável dependente a partir de uma ou mais variáveis independentes. Quando apenas a

relação entre uma variável independente é avaliada, a técnica estatística é chamada regressão linear simples (Equação 1), porém, quando estão envolvidas duas ou mais variáveis independentes, chama-se regressão linear múltipla (HAIR JUNIOR et. al, 2005).

Quando admitimos que a variável dependente é função linear de duas ou mais variáveis explicativas, temos uma regressão linear múltipla (RLM) e o modelo estatístico, com p variáveis independentes, é apresentado na Equação 2. Onde Y_i é o valor de Y na observação i , β_0 é a constante da regressão, β_1 é o coeficiente de regressão de X_1 , β_2 é o coeficiente de regressão de X_2 , β_p é o coeficiente de regressão de X_p , X_{1i} é o valor de X_1 na observação i , X_{2i} é o valor de X_2 na observação i , X_{pi} é o valor de X_p na observação i e \mathcal{E}_i erro aleatório associado ao valor observado Y_i (HAIR JUNIOR et. al, 2005; RIBEIRO JÚNIOR, 2013):

$$Y_i = \beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \dots + \beta_p X_{pi} + \varepsilon_i \quad (2)$$

Em modelos de regressão múltipla geralmente um subconjunto de variáveis independentes, que melhor expliquem a variável resposta, é selecionado para explorar as relações de dependência entre a variável dependente e as variáveis independentes. Assim, entre todas as variáveis explicativas é determinado um subconjunto de variáveis importantes para o modelo.

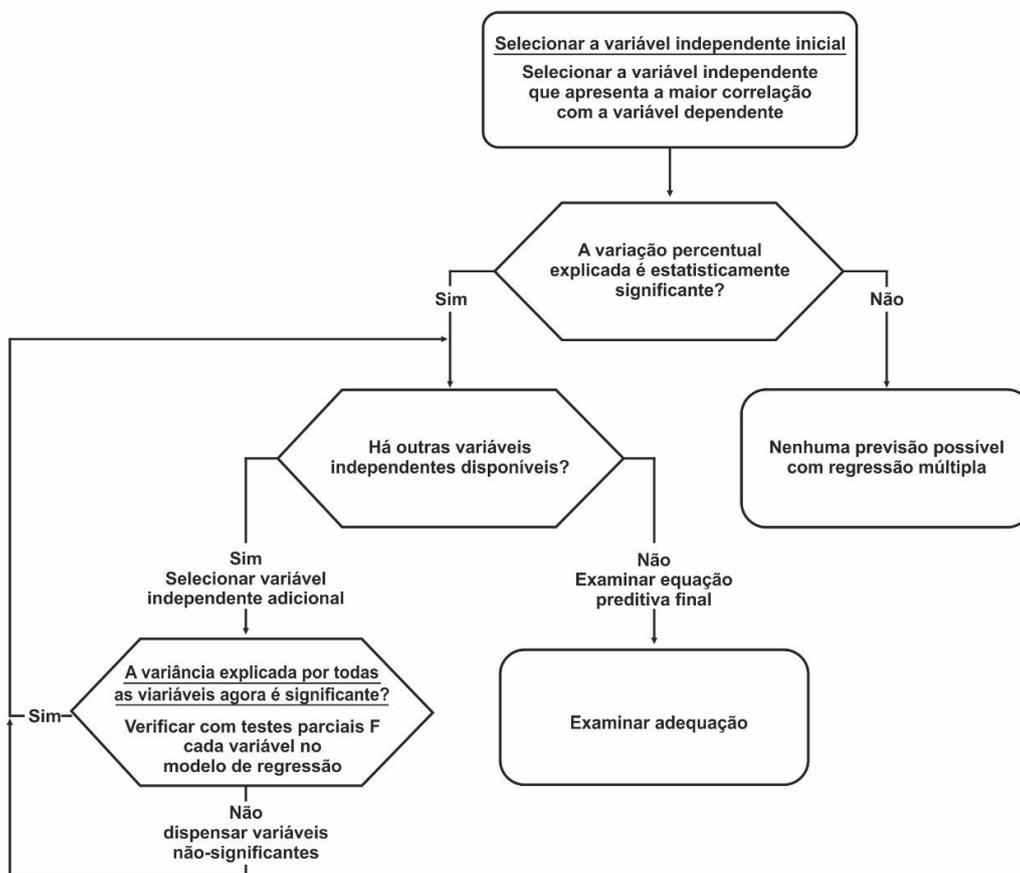
Uma vez que, à medida que o número de variáveis empregadas no modelo se aproxima de p (número de variáveis independentes) pode ocorrer *overfitting*, conhecido como ajuste forçado. O *overfitting* ocorre quando se verifica valor elevado do coeficiente de determinação decorrente do número excessivo de variáveis incluídas no modelo e não de seu ajuste natural aos valores observados das reais influências do ajuste (FERREIRA; MONTANARI; GAUDIO, 2002).

Diferentes estratégias para a seleção de variáveis são utilizadas, de modo que seja obtida máxima informação das variáveis independentes e que seja reduzido o *overfitting*, sendo a estimação *stepwise* a mais empregada (HAIR JUNIOR et. al, 2005).

A estimação *stepwise* consiste em examinar a contribuição de cada variável independente para o modelo de regressão, sendo consideradas cada uma das variáveis para inclusão antes do desenvolvimento da equação. Na Figura 8 é ilustrado

o fluxograma do procedimento *stepwise*, onde inicialmente um modelo de regressão simples, no qual a variável independente de maior correlação com a variável dependente é utilizada, é avaliado. Posteriormente, as demais variáveis independentes são selecionadas para inclusão em função da contribuição das mesmas sobre as variáveis já presentes na equação. Quando a presença da nova variável faz uma contribuição significativa, esta é incluída no modelo. Caso contrário, a variável é eliminada (HAIR JUNIOR et. al, 2005).

Figura 8 – Fluxograma do método de estimação *stepwise*.



Fonte: Hair Junior et. al (2005).

3. MATERIAL E MÉTODOS

3.1. Descrição dos dados

Os dados utilizados neste estudo foram provenientes de 352 árvores de clones do híbrido de *Eucalyptus grandis* x *Eucalyptus urophylla*, originados de plantios florestais localizados nos municípios de Aracruz e São Mateus, no estado do Espírito Santo, e Nova Viçosa e Teixeira de Freitas, no estado da Bahia.

As árvores amostras foram obtidas de 18 diferentes clones, distribuídos em espaçamento 3x3m, com idades variando de dois a oito anos, originadas de plantios comerciais destinados à produção de celulose.

As variáveis empregadas (Quadro 1) foram classificadas inicialmente em quatro categorias, sendo elas: (I) dados de inventário e avaliações dendrométricas das árvores; (II) regiões (local) dos plantios florestais; (III) caracterização climática e (IV) propriedade da madeira.

Quadro 1 – Variáveis utilizadas no estudo para estimativa da densidade da madeira de eucalipto

Categoria	Variáveis
(I) Dados do inventário e avaliações dendrométricas	Clone (identificados de 1 a 18), Idade (anos), DAP* (cm) e volume com casca (m ³)
(II) Regiões	Aracruz (1), São Mateus (2) e Bahia (3)
(III) Caracterização climática	Precipitação acumulada (mm), Temperatura do ar (°C) e Umidade relativa do ar (%)
(IV) Propriedade da madeira	Densidade básica (g.cm ⁻³)

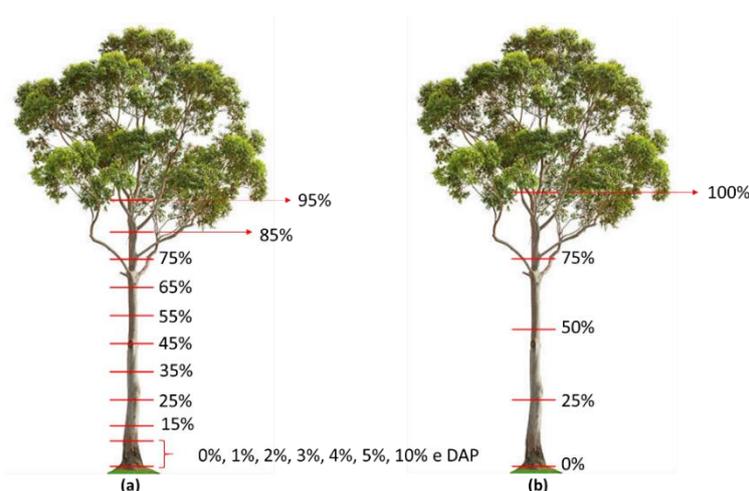
*DAP = diâmetro à altura do peito.

3.2. Amostragem da madeira

A amostragem consistiu na retirada de discos e toretes ao longo do comprimento das árvores, sendo selecionadas quatro árvores (repetições) com DAP correspondente ao DAP médio de cada talhão

Após a derrubada das árvores, foi medida a altura total (m) das mesmas e retirados 17 discos, nos quais, ainda em campo, foram realizadas as mensurações de diâmetros com casca e sem casca, para determinação do volume de madeira. Ainda nas mesmas árvores, também foram amostrados cinco toretes com 1m de comprimento, nos quais foi determinada a densidade básica da madeira em laboratório (Figura 9).

Figura 09 – Diagrama de amostragem dos discos (a) e toretes (b) nas árvores de eucalipto.



Fonte: a autora (2018).

No cálculo da estimativa do volume de madeira, uma adaptação da fórmula de Smalian (Equação 3) foi utilizada (SOARES, PAULA NETO, SOUZA, 2011).

$$V = \sum \left(\frac{g_i + g_{i+1}}{2} l_i \right) \quad (3)$$

Em que:

V : volume da seção considerada (m^3);

g_i : área basal da ponta fina (m^2);

g_{i+1} : área basal da ponta grossa (m^2);

l_i : comprimento da seção (m).

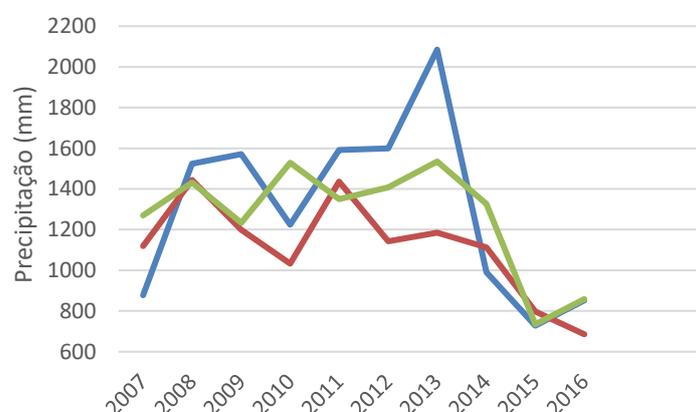
A densidade básica foi determinada de acordo com o preconizado na Norma Brasileira Regulamentadora – NBR 11941 da Associação Brasileira de Normas Técnicas – ABNT (2003). Os toretes retirados das árvores foram armazenados em laboratório e transformados em cavacos, posteriormente a densidade do material foi determinada pelo método de imersão preconizado na norma.

3.3. Variáveis climáticas

As variáveis climáticas de cada região, Aracruz, São Mateus e Bahia, empregadas foram precipitação acumulada (mm), temperatura média (°C) e umidade relativa média (%). Tais dados foram obtidos a partir do Banco de Dados Meteorológicos para Ensino e Pesquisa – BDMEP disponibilizado pelo INMET – Instituto Nacional de Meteorologia.

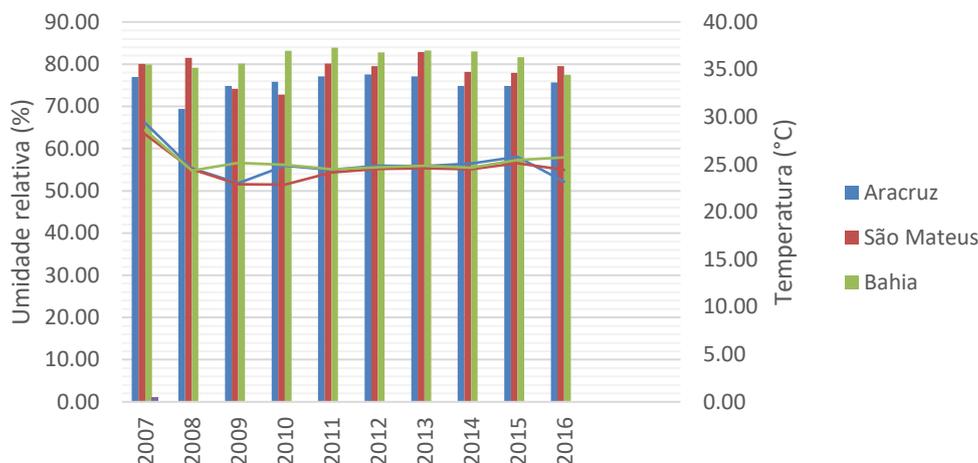
Nas Figuras 10 e 11, são ilustrados os comportamentos da precipitação acumulada anual (Figura 10) e médias anuais de umidade relativa do ar (%) e temperatura (°C) (Figura 11) das regiões Aracruz, São Mateus e Bahia, no período em que os plantios florestais estiveram instalados.

Figura 10 – Precipitação acumulada anual (mm), entre os anos de 2007 e 2016, das regiões Aracruz, São Mateus e Bahia.



Fonte: Adaptado de INMET.

Figura 10 – Características de umidade relativa do ar (%) e temperatura (°C) médias mensais, entre os anos de 2007 e 2016, das regiões Aracruz, São Mateus e Bahia.



Fonte: Adaptado de INMET.

3.4. Modelagem da densidade básica da madeira

Os dados foram divididos aleatoriamente em dois conjuntos, um para o treinamento das redes e ajuste dos modelos de regressão, e outro para avaliar a generalização das redes treinadas e a validação dos modelos, com proporções de 70% de dados para o treinamento e ajuste e 30% para validação das redes e dos modelos de regressão (BINOTI et al., 2015; BINOTI, 2010; SILVA; SPATTI; FLAUZINO, 2010). A estimativa da densidade básica da madeira foi realizada a partir das combinações de variáveis apresentadas no Quadro 2.

Na Tabela 3 é apresentada uma análise descritiva de todas as variáveis quantitativas utilizadas para a estimativa da densidade básica da madeira e na Figura 12 é apresentada a correlação entre a densidade básica da madeira e estas variáveis. Nos Apêndices A até BB, também são apresentadas as análises descritivas e as correlações das variáveis para cada combinação, para o banco de dados de treino das redes e ajuste dos modelos e validação de ambos.

Quadro 2 – Combinações de variáveis empregadas no treinamento das redes neurais e no ajuste dos modelos de regressão linear para a estimativa da densidade básica da madeira.

Combinação	Variáveis utilizadas
COMP Completa	Clone (identificados de 1 a 18), Idade (anos), DAP (cm), volume com casca (m ³), regiões (1 – Aracruz, 2 – São Mateus e 3 – Bahia), precipitação acumulada (mm), temperatura do ar (°C) e umidade relativa do ar (%).
REG-1 Aracruz	Clone (identificados de 1 a 18), Idade (anos), DAP (cm), volume com casca (m ³), precipitação acumulada (mm), temperatura do ar (°C) e umidade relativa do ar (%) para a região 1 – Aracruz.
REG-2 São Mateus	Clone (identificados de 1 a 18), Idade (anos), DAP (cm), volume com casca (m ³), precipitação acumulada (mm), temperatura do ar (°C) e umidade relativa do ar (%) para a região 2 – São Mateus.
REG-3 Bahia	Clone (identificados de 1 a 18), Idade (anos), DAP (cm), volume com casca (m ³), precipitação acumulada (mm), temperatura do ar (°C) e umidade relativa do ar (%) para a região 3 – Bahia.
CLAS-1 2 a 4 anos	Clone (identificados de 1 a 18), Idade (anos), DAP (cm), volume com casca (m ³), regiões (1 – Aracruz, 2 – São Mateus e 3 – Bahia), precipitação acumulada (mm), temperatura do ar (°C) e umidade relativa do ar (%) para a classe de idade 1 (dois a quatro anos).
CLAS-2 4 a 6 anos	Clone (identificados de 1 a 18), Idade (anos), DAP (cm), volume com casca (m ³), regiões (1 – Aracruz, 2 – São Mateus e 3 – Bahia), precipitação acumulada (mm), temperatura do ar (°C) e umidade relativa do ar (%) para a classe de idade 2 (quatro a seis anos).
CLAS-3 6 a 8 anos	Clone (identificados de 1 a 18), Idade (anos), DAP (cm), volume com casca (m ³), regiões (1 – Aracruz, 2 – São Mateus e 3 – Bahia), precipitação acumulada (mm), temperatura do ar (°C) e umidade relativa do ar (%) para a classe de idade 3 (seis a oito anos).

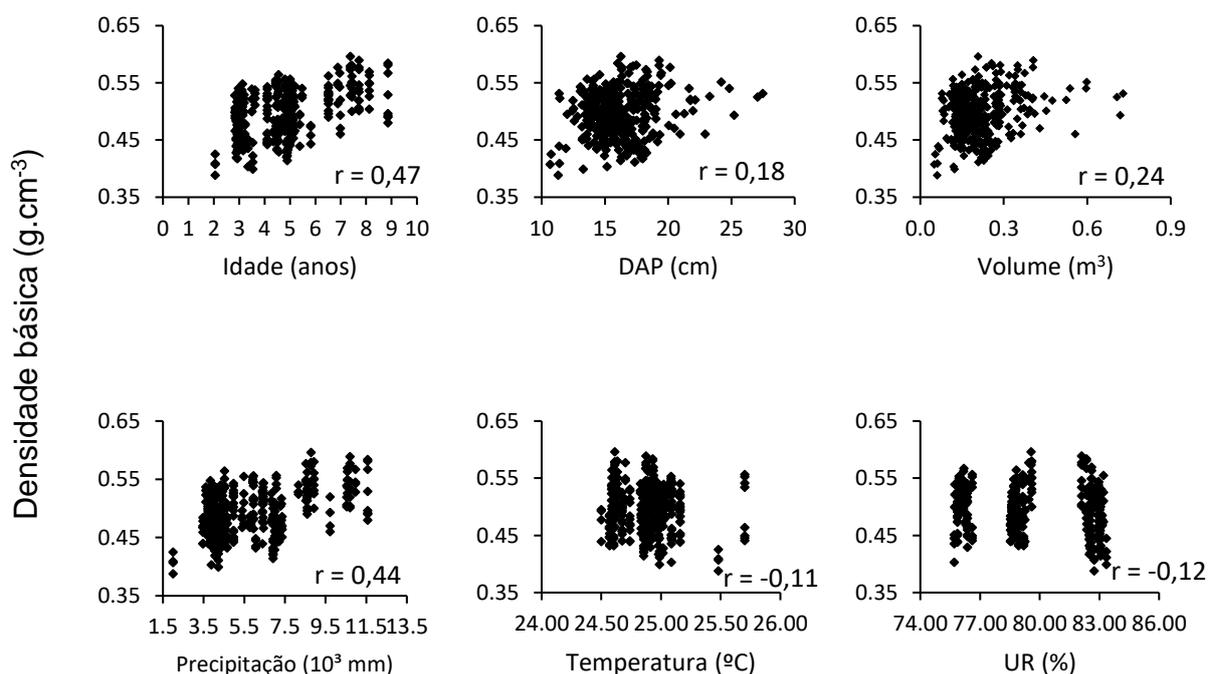
Em que: COMP = dados completos; REG = região; CLAS = classe de idade, DAP = diâmetro à altura do peito.

Tabela 3 – Análise descritiva das variáveis quantitativas relativas à avaliação das árvores dos 18 clones de eucalipto.

Variáveis	Mínimo	Média	Máximo	CV(%)
Idade (anos)	2,05	4,70	8,86	-
DAP (cm)	10,66	16,14	27,47	14,84
Volume (m ³)	0,050	0,216	0,729	45,80
Precipitação acumulada (mm)	1989,40	6073,64	11562,90	37,36
Temperatura (°C)	24,50	24,89	25,70	0,93
Umidade relativa (%)	75,70	79,98	83,34	3,52
Densidade básica (g.cm ⁻³)	388	493	589	8,35

CV : Coeficiente de variação.

Figura 12 – Correlação entre a densidade básica da madeira e as variáveis quantitativas do estudo, relativo à combinação COMP.



3.4.1. Modelagem por redes neurais artificiais

Após obtenção dos dados, as variáveis numéricas foram normalizadas linearmente no intervalo de 0 a 1 e -1 a 1, de acordo com a função de ativação na

camada oculta, e as variáveis categóricas foram normalizadas utilizando-se a metodologia “1-de-n” (GOLDSCHMIDT; PASSOS, 2005; HEATON, 2011).

As redes neurais foram treinadas para projetar a densidade básica da madeira, sendo empregada a arquitetura de rede do tipo *Multilayer Perceptron* (MLP), com uma camada de entrada e duas camadas, oculta e de saída, de processamento.

O número de neurônios que constituíram a camada de entrada variou de acordo com o número de variáveis empregadas em cada combinação (Quadro 2), sendo um neurônio para cada variável quantitativa e um neurônio para cada classe de variável qualitativa. As variáveis qualitativas clone e região foram transformadas em variáveis *dummy*, resultando, respectivamente, em dezoito e três neurônios na camada de entrada para cada uma destas variáveis.

Na camada oculta, foram testadas configurações com números de neurônios e funções de ativação, como descritos no Quadro 3, com as funções empregadas a logarítima hiperbólica (*logsig*) e a tangente hiperbólica (*tansig*) e algoritmos de treinamento *Levenberg-Marquardt* e *Resilient Propagation (RPROP+)*.

Na combinação completa (COMP) e nas combinações de classes de idade (CLAS-1, CLAS-2 e CLAS-3), foram testadas configurações com o número de neurônios variando de 10 até 50 e nas combinações de regiões (REF-1, REG-2 e REG-3), foram testadas configurações com o número de neurônios variando de 10 até 50, para deter Já a camada de saída, possuiu um único neurônio e a função de ativação utilizada foi a linear.

Quadro 3 – Número de neurônios e funções de ativação da camada oculta.

Combinação	Nº de neurônios da camada oculta	Funções de ativação
COMP	10 a 50	$logsig: f(x) = \frac{1}{1 + e^{-x}}$
REG-1		
REG-2	5 a 30	
REG-3		$tansig: f(x) = \frac{1}{1 + e^{-2x}} - 1$
CLAS-1		
CLAS-2	10 a 50	
CLAS-3		

Em que: COMP = dados completos; REG = região (1) Aracruz, (2) São Mateus e (3) Bahia; CLAS = classe de idade (1) 2 a 4 anos, (2) 4 a 6 anos 3 (3) 6 a 8 anos.

O processamento das RNAs foi realizado com o auxílio do *Toolbox* redes neurais artificiais do *software Matlab* versão R2016a e foram testadas cinco redes para cada configuração. O critério de parada adotado foi o número de ciclos igual a 1000 e a *early stopping*. Este último critério consiste na verificação constante do processo de treinamento a partir do uso de subconjuntos de validação, em que o mesmo é finalizado quando ocorre o aumento do erro quadrático entre os ciclos sucessivos (SILVA; SPATTI; FALUZINO, 2010). Assim, o treinamento foi finalizado quando um desses critérios foi alcançado.

3.4.2. Modelagem por regressão linear

A partir das variáveis correspondentes a cada combinação apresentada no Quadro 2, foram feitas análises de regressão múltipla para a obtenção da estimativa da densidade básica da madeira, empregando-se a função *stepwisefit* do *software Matlab* versão R2016a. Para isso, as variáveis categóricas, clone e região, foram transformadas em variáveis dummies, em que as 18 categorias observadas para clone e as 3 categorias das regiões resultaram, respectivamente, em 17 e 2 variáveis dummies.

Um modelo foi ajustado para cada uma das combinações inicialmente definidas, para as variáveis selecionadas com tolerâncias de entrada/saída de $\alpha=5\%$ a $\alpha=10\%$ para a composição dos modelos.

3.5. Avaliação das estimativas geradas pelos métodos empregados

As medidas estatísticas empregadas na avaliação das estimativas geradas foram a correlação entre os valores estimados e observados de densidade básica da madeira, o coeficiente de determinação dos modelos de regressão, a raiz do quadrado médio do erro e o viés (%) (Quadro 4).

A correlação entre os valores observados e estimados ($r_{\hat{Y}Y}$) é um importante recurso estatístico, pois indica a força e a direção da relação entre as duas variáveis, ou seja, a correlação indica o grau de associação entre valores observados e estimados e permite inferir sobre a qualidade da prognose ou estimação. Quanto mais próxima de 1, maior a correlação entre as variáveis (DANCEY e REIDY, 2006; CAMPOS e LEITE, 2009).

Quadro 4 – Estatísticas utilizadas para avaliar o desempenho das estimativas da densidade básica da madeira para os dados de ajuste e validação dos modelos de regressão.

Estatística	Fórmulas
Coeficiente de determinação	$R^2 = 1 - \frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{\sum_{i=1}^n (Y_i - \bar{Y})^2}$
Raiz do quadrado médio do erro expresso em porcentagem da média (%)	$RMSE (\%) = \frac{100}{\bar{Y}} \sqrt{\frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n}}$
Viés expresso em porcentagem da média (%)*	$V(\%) = \frac{100}{\bar{Y}} \frac{\sum_{i=1}^n Y_i - \sum_{i=1}^n \hat{Y}_i}{n}$

Em que: Y_i = densidade observada; \bar{Y} = média da densidade observada; \hat{Y}_i = densidade estimada e n = número de observações.

*Em modelos de regressão que incluem o intercepto e com os mesmos dados utilizados no ajuste, o viés é zero.

As mesmas medidas estatísticas, utilizadas na análise de regressão usual, foram adotadas na avaliação do treinamento e validação das redes neurais artificiais (Quadro 5).

Quadro 5 – Estatísticas utilizadas para avaliar o desempenho das estimativas da densidade básica da madeira para os dados de ajuste e validação dos modelos de regressão

Estatística	Fórmulas
Correlação	$r_{\hat{Y}Y} = \frac{\sum_{i=1}^n (Y_i - \bar{Y})(\hat{Y}_i - \hat{Y}_m)}{\sqrt{\sum_{i=1}^n (Y_i - \bar{Y})^2 \sum_{i=1}^n (\hat{Y}_i - \hat{Y}_m)^2}}$
Coeficiente de determinação	$R^2 = 1 - \frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{\sum_{i=1}^n (Y_i - \bar{Y})^2}$
Raiz do quadrado médio do erro (%)	$RMSE (\%) = \frac{100}{\bar{Y}} \sqrt{\frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n}}$
Viés (%)*	$V(\%) = \frac{100}{\bar{Y}} \frac{\sum_{i=1}^n Y_i - \sum_{i=1}^n \hat{Y}_i}{n}$

Em que: Y_i = densidade observada; \bar{Y} = média da densidade observada; \hat{Y}_i = densidade estimada; \hat{Y}_m = média estimada e n = número de observações.

*No treino e validação das RNAs e na validação dos modelos de RLM.

Pode-se demonstrar que na análise de regressão e sob normalidade, a expressão dada por $\sum_i^n (Y_i - \hat{Y}_i)^2 / n$ é o estimador da variância residual obtido pelo método da máxima verossimilhança, considerando os dados utilizados no ajuste do modelo. E ainda, $RMSE_{\bar{y}}(\%)$ é o coeficiente de variação, que é o desvio padrão residual expresso em porcentagem da média.

A raiz do quadrado médio do erro (RMSE%) avalia a diferença quadrática média entre os valores observados e os valores estimados, e quanto menor seu valor, melhor a precisão da estimativa (Mehtätalo et al., 2006).

Já o viés, refere-se a diferença entre o valor estimado e o observado, sendo valores de viés iguais zero, aliados a alta correlação e baixos RMSE%, relacionados a estimativas com maior exatidão (VAN LAAR; AKÇA, 2007; BATISTA; COUTO; SILVA FILHO, 2014).

Além das análises estatísticas, também foram analisados erros absolutos Equação (4) e gráficos da relação entre as variáveis observadas *versus* as variáveis estimadas, dispersão dos erros percentuais (Equação 5) e histogramas de frequência percentual dos erros percentuais.

$$erro_{abs} = |Y_i - \hat{Y}_i| 1000 \quad (4)$$

Em que,

$erro_{abs}$ = erro absoluto de cada observação (kg.m⁻³);

Y_i = é a saída observada nas análises;

\hat{Y}_i = é a saída estimada.

$$erro_{\%} = \frac{(Y_i - \hat{Y}_i)}{Y_i} 100 \quad (5)$$

Em que,

$erro_{\%}$ = erro percentual de cada observação;

Y_i = é a saída observada nas análises;

\hat{Y}_i = é a saída estimada.

4. RESULTADOS E DISCUSSÕES

Os resultados médios de densidade básica observados em cada combinação estão apresentados na Tabela 4.

Tabela 4 – Densidade básica média da madeira de eucalipto observada em cada combinação.

Combinação	Densidade básica (g.cm⁻³)
COMP – Completo	0,495
REG-1 – Aracruz	0,501
REG-2 – São Mateus	0,499
REG-3 – Bahia	0,490
CLAS-1 – Idades de 2 a 4 anos	0,479
CLAS-2 – Idades de 4 a 6 anos	0,490
CLAS-3 – Idades de 6 a 8 anos	0,534

Em que: COMP = dados completos; REG = região (1) Aracruz, (2) São Mateus e (3) Bahia; CLAS = classe de idade (1) 2 a 4 anos, (2) 4 a 6 anos 3 (3) 6 a 8 anos.

A densidade básica da madeira de árvores obtidas de uma mesma espécie ou material genético pode apresentar variações associadas à genética, ambiente e, ou, idade. Contudo, mesmo que relacionada a estes fatores, a amplitude da densidade observada na Tabela 4 demonstra que a densidade expressa pelos dezoito clones, nas três diferentes regiões e com idades variando de dois a oito anos foi pequena.

Entre as combinações, verificou-se máxima amplitude de 0,055g.cm⁻³ entre CLAS-1 e CLAS-3, expressando o impacto da idade das árvores na densidade da madeira. Porém, em consequência às pequenas variações entre as variáveis climáticas, quando comparadas as densidades entre combinações de regiões, essa amplitude foi cinco vezes menor.

Alguns estudos, como verificado por Barbosa (2013), ao avaliar a densidade básica da madeira de *Eucalyptus grandis* x *Eucalyptus urophylla* aos seis anos de idade em cinco diferentes regiões no Estado de Minas Gerais, foi evidenciado que em diferentes regiões, mesmo que para um mesmo material genético e a mesma idade, essas variações foram significativas.

Já Rocha (2018) concluiu em seu estudo, com clones de *Eucalyptus* sp. aos quatro anos de idade, que a resposta expressa da densidade básica às condições climáticas deve ser associada a avaliações anatômicas e químicas da madeira, para melhor entendimento da relação entre clima e qualidade da madeira. Quando avaliadas as densidades de árvores originadas de locais secos, foi verificada maior média de densidade. Contudo, em locais como úmidos e subúmidos, não foram verificadas diferenças significativas da densidade.

Após a avaliação dos dados observados de densidade básica da madeira, foram treinadas e validadas RNAs para a estimativa desta propriedade. Os resultados obtidos para a estimativa da densidade básica da madeira de eucalipto foram alcançados a partir do treinamento de 4840 redes neurais artificiais, as quais foram avaliadas e posteriormente selecionadas, para cada combinação, as que apresentaram melhor desempenho (Tabela 5), tratando-se de menores valores da raiz do quadrado médio do erro (RMSE%) e viés V% e maior correlação ($r_{Y\hat{Y}}$).

Com base nas configurações da camada oculta (algoritmo, função de ativação e número de neurônios), o algoritmo *Levenberg-Marquardt* apresentou melhor desempenho quando empregado no treinamento das RNAs para estimativa da densidade básica da madeira, em que apenas para árvores com idade variando de quatro a seis anos (CLAS-2) foi verificado melhor desempenho do algoritmo *Resilient-Propagation*. Tanto a função de ativação logarítmica quanto a hiperbólica apresentaram desempenho satisfatório e o número de neurônios na camada oculta variou de cinco a trinta e quatro.

Na avaliação das análises das estatísticas de desempenho das redes neurais selecionadas para cada combinação (Quadro 2), nota-se que de modo geral o coeficiente de correlação variou de 0,8864 a 0,9324 no treinamento e 0,8875 a 0,9591 na validação, com RMSE máximo de 3,55% e mínimo de 2,35%. Já o viés máximo observado, respectivamente para treinamento e validação, foi de -0,74% e 1,22%.

Nas Figuras 13 a 18 são apresentadas as análises gráficas de correlação entre as densidades observadas e estimadas pelas RNAs (Figuras 13 e 14), de distribuição dos erros percentuais (Figuras 15 e 16) e os histogramas dos erros percentuais (Figuras 17 e 18) para o treinamento e validação.

Tabela 5 – Estatísticas de treinamento e validação utilizadas para avaliar o desempenho das redes neurais artificiais na estimação da densidade da madeira de árvores de eucalipto.

RNA	Combinação	Configuração	Treino			Validação		
			RMSE (%)	V (%)	$r_{Y\hat{Y}}$	RMSE (%)	V (%)	$r_{Y\hat{Y}}$
1	COMP	lm – logsig – 34	3,55	-0,74	0,9095	3,49	-0,10	0,8875
2	REG-1	lm – logsig – 8	2,91	0,12	0,9252	2,35	0,49	0,9391
3	REG-2	lm – tansig – 5	2,89	-0,55	0,9172	2,88	1,22	0,9591
4	REG-3	lm – logsig – 10	3,31	-0,26	0,9324	3,34	-0,01	0,8980
5	CLAS-1	lm – tansig – 14	2,73	0,01	0,9270	3,43	-0,21	0,9161
6	CLAS-2	rp – tansig – 10	3,34	0,06	0,8864	2,97	-0,53	0,9146
7	CLAS-3	lm – tansig – 18	2,40	-0,01	0,9092	2,66	0,14	0,8879

Em que: Combinação = combinação de variáveis na camada de entrada; COMP = clone, região, idade, DAP, volume, precipitação, temperatura e umidade relativa; REG= clone, idade, DAP, volume, precipitação, temperatura e umidade relativa para a região (1) Aracruz, (2) São Mateus e (3) Bahia; CL= clone, região, idade, DAP, volume, precipitação, temperatura e umidade relativa para idades no intervalo de classe de (1) 2 a 4 anos, (2) 4 a 6 anos e (3) 6 a 8 anos. Configuração = configuração da RNA: algoritmo – função de ativação – n° de neurônios da camada oculta; rp = Resilient-Propagation; lm = Levenberg-Marquardt; logsig = Logarítmica hiperbólica e tansig = Tangente hiperbólica.

RMSE(%) = raiz do quadrado médio do erro em porcentagem (%).

V(%) = viés em porcentagem.

$r_{Y\hat{Y}}$ = coeficiente de correlação.

Figura 13 – Valores observados de densidade (g.cm^{-3}) versus estimados no treinamento das RNAs.

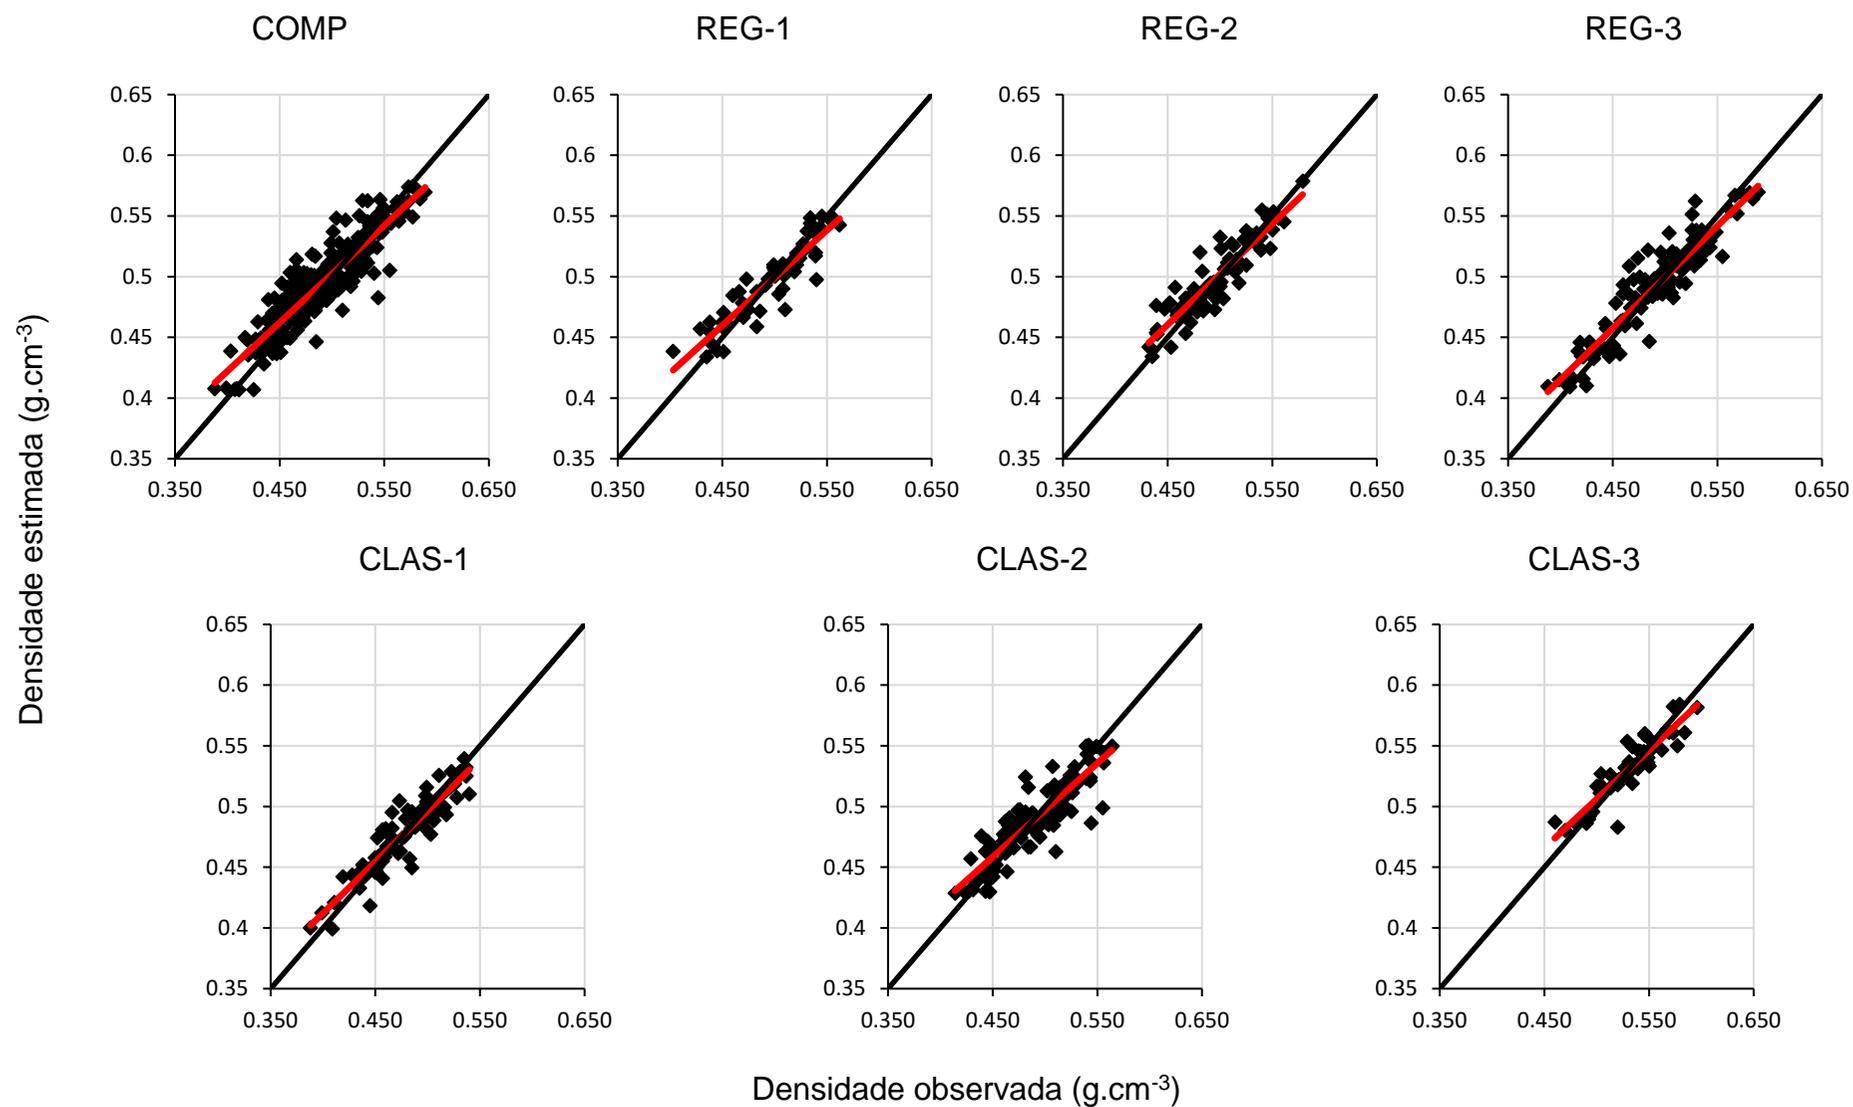


Figura 14 – Valores observados de densidade ($\text{g}\cdot\text{cm}^{-3}$) versus estimados na validação das RNAs.

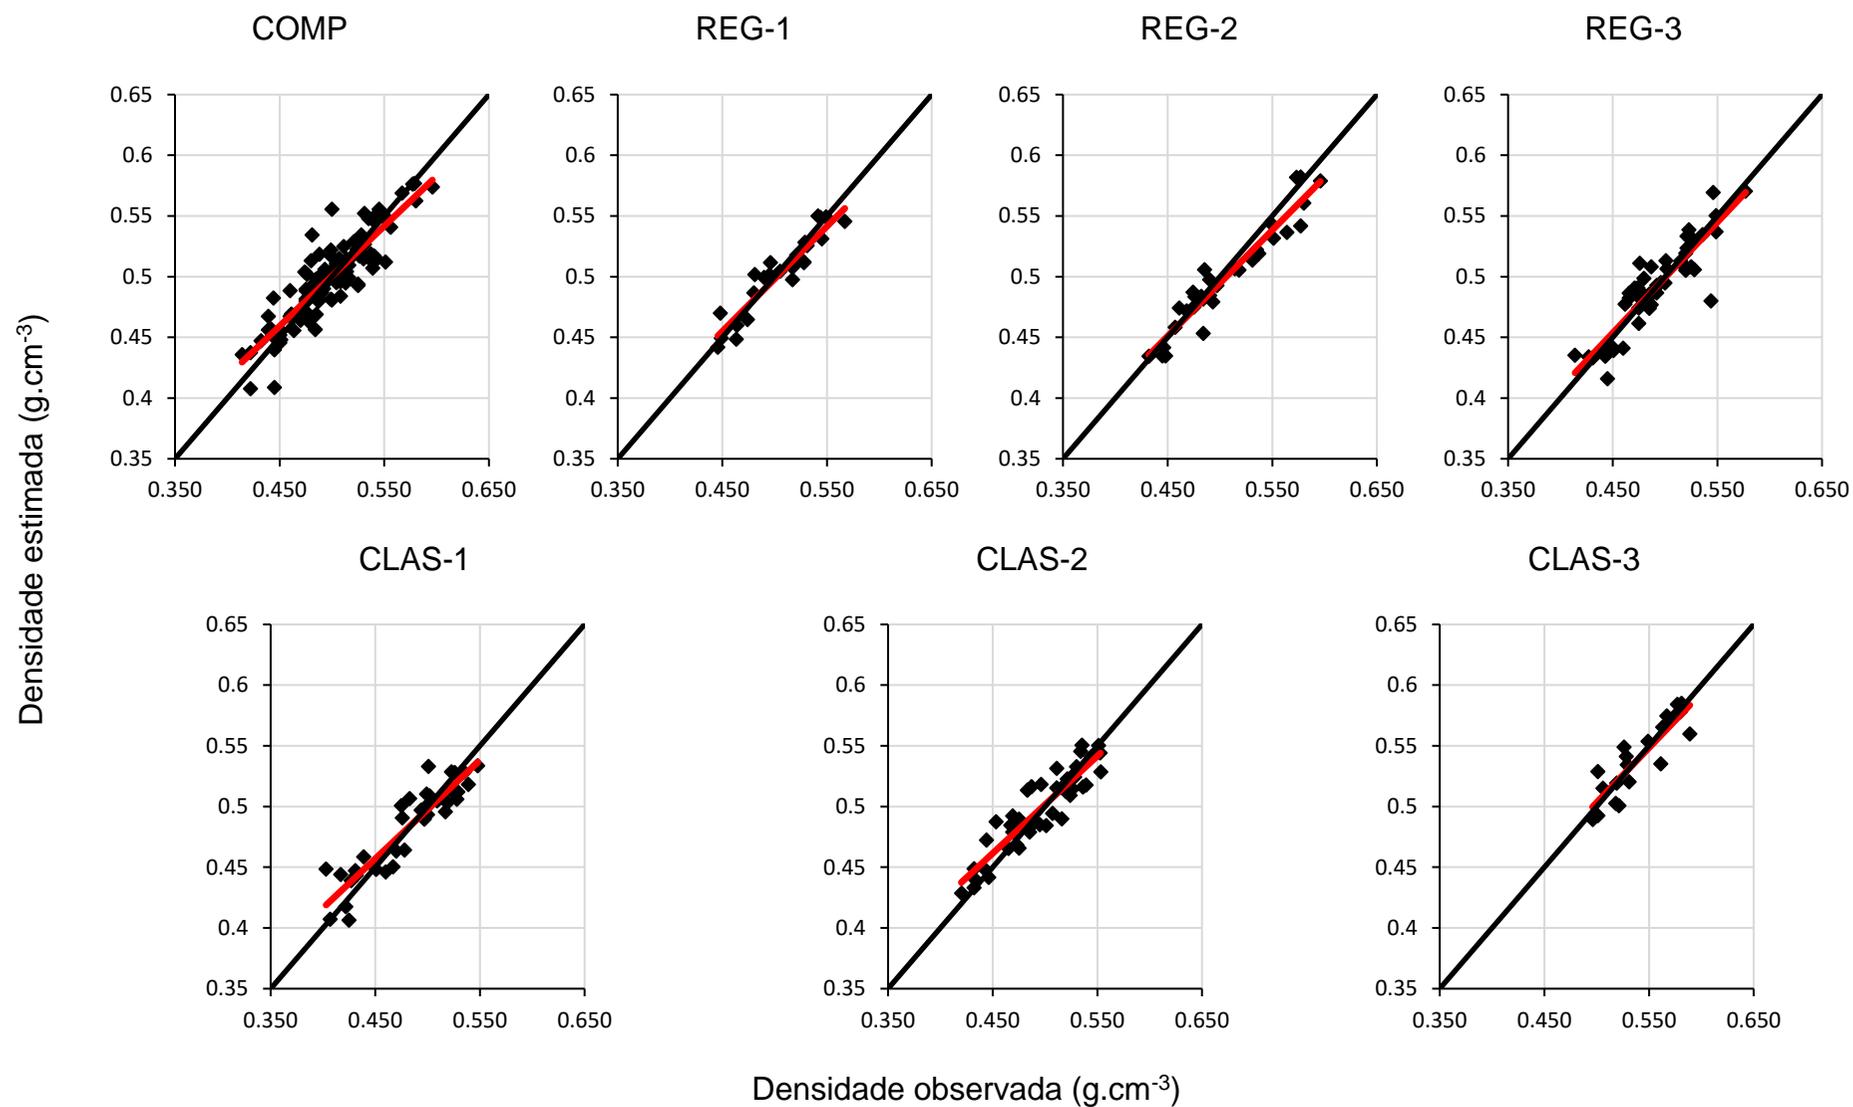


Figura 15 – Dispersão dos erros em porcentagem em relação aos valores estimados de densidade (g.cm^{-3}) no treinamento das RNAs.

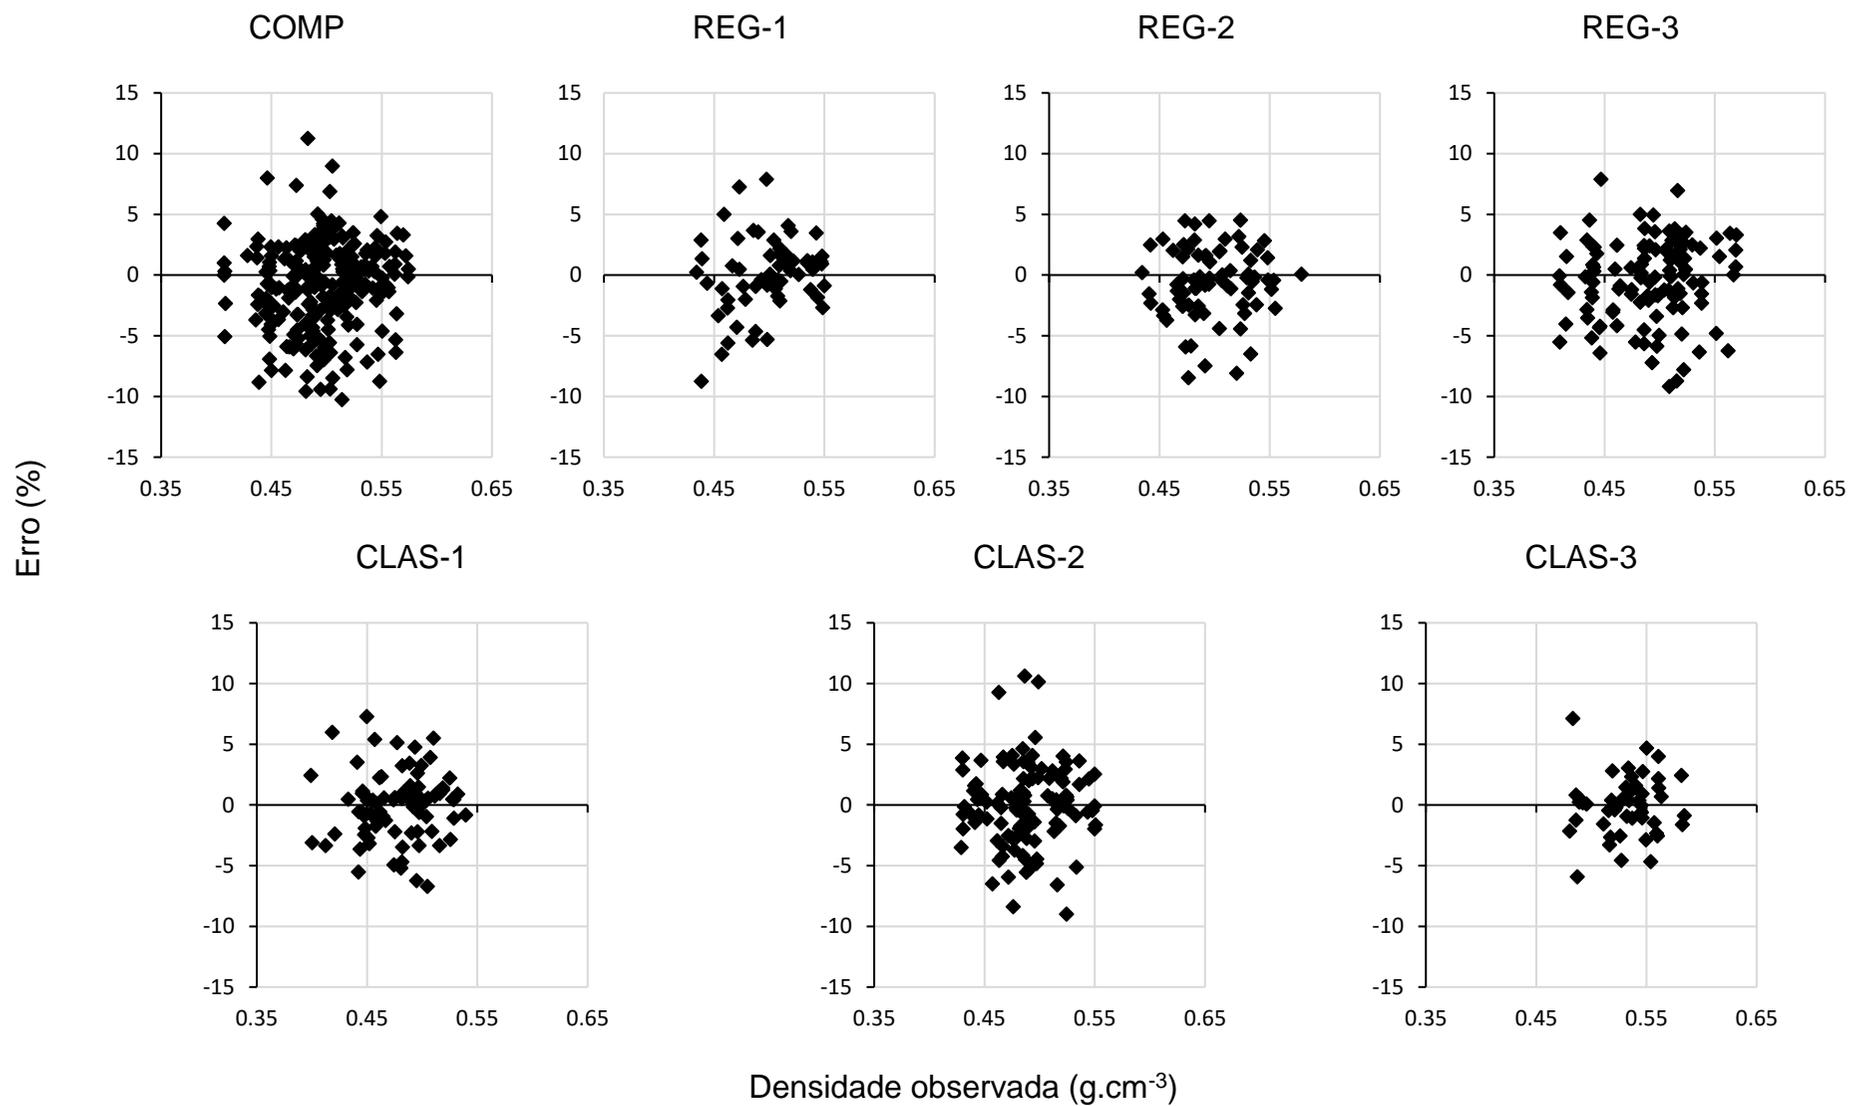


Figura 16 – Dispersão dos erros em porcentagem em relação aos valores estimados de densidade ($\text{g}\cdot\text{cm}^{-3}$) na validação das RNAs.

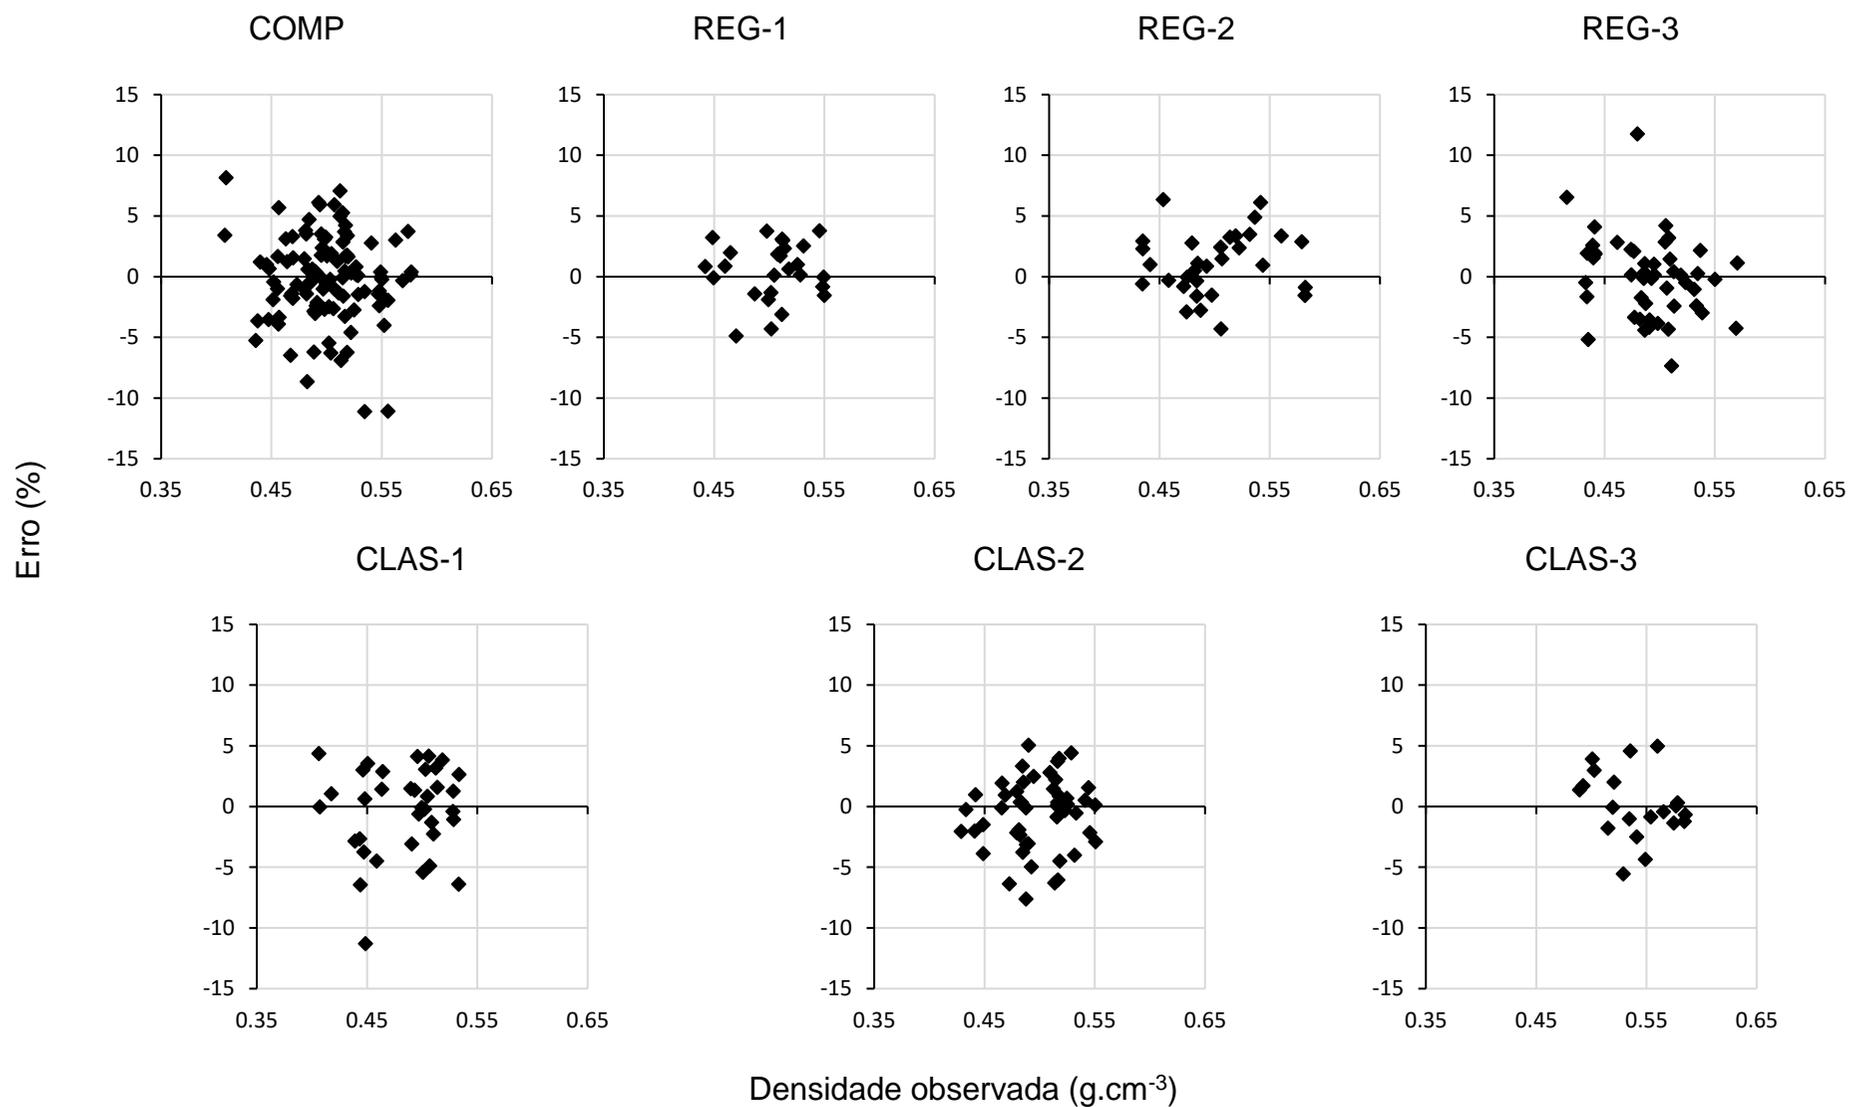


Figura 17 – Frequência relativa dos erros, em porcentagem, para estimativas de densidade (g.cm^{-3}) no treinamento das RNAs.

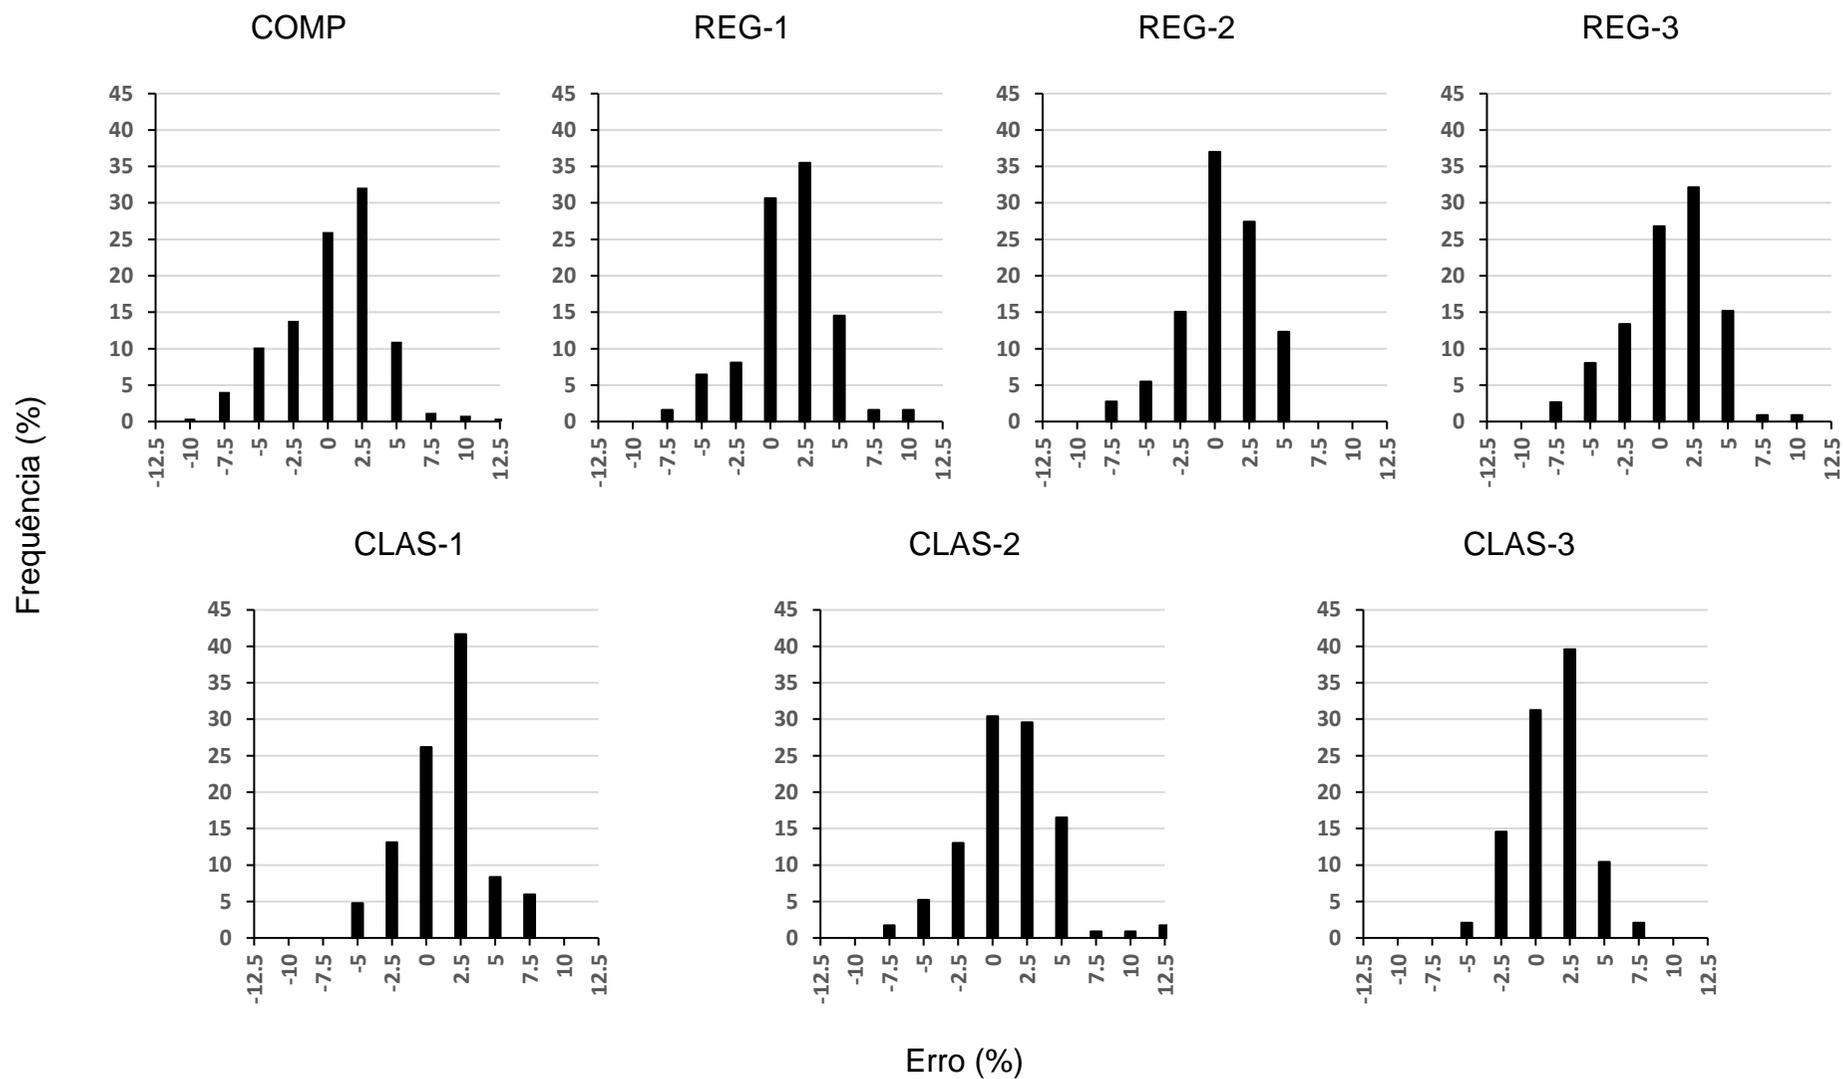
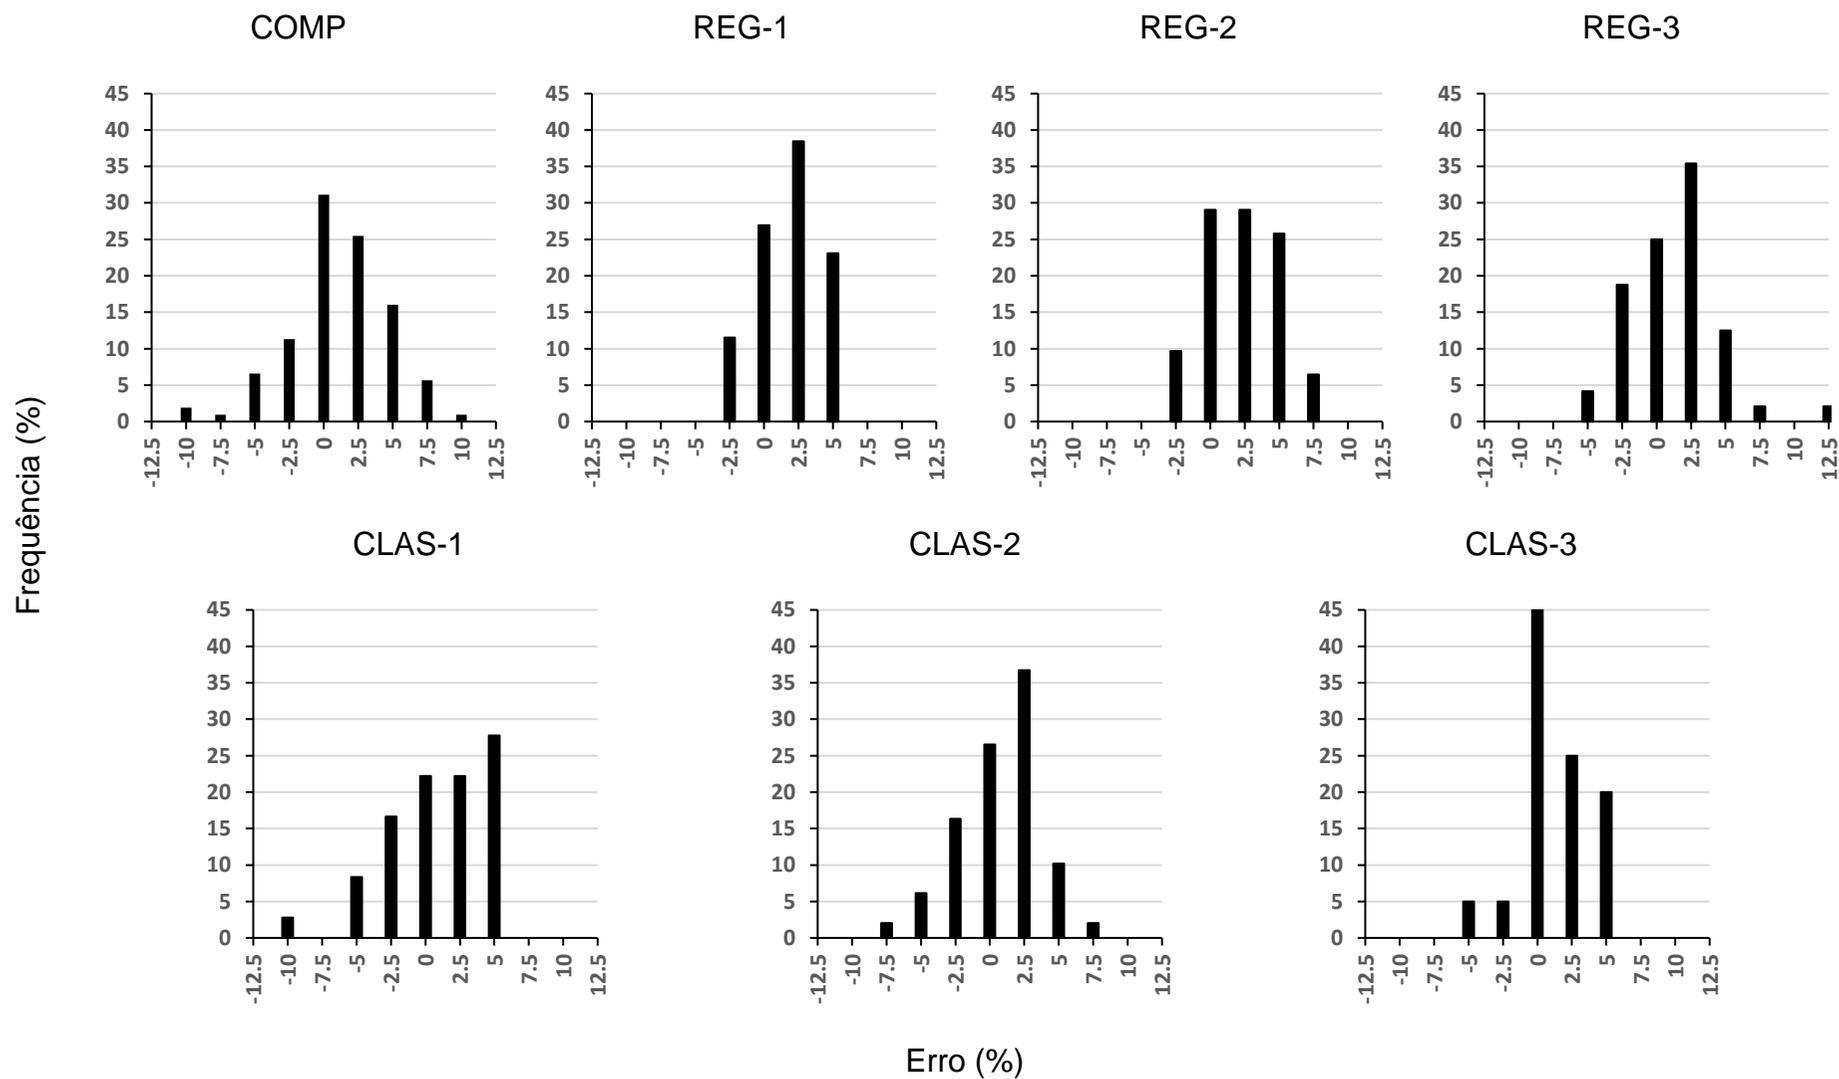


Figura 18 – Frequência relativa dos erros, em porcentagem, para estimativas de densidade (g.cm^{-3}) na validação das RNAs.



Com base na análise gráfica da densidade estimada *versus* densidade observada, afirmam-se os resultados de correlação observados nas análises estatísticas da Tabela 5, uma vez que nos gráficos dos dados de treinamento e ajuste das redes, para todas as combinações, observa-se a tendência de dispersão dos dados próximos a linha de 45°.

Assim como, a partir da análise dos histogramas de frequência relativa dos erros, observamos que em média, para todas as combinações, cerca de 60% dos erros estão contidos nas classes de $\pm 2,5\%$ e 90% destes em $\pm 5\%$, os quais associados aos baixos vies observados reafirmam a eficiência das redes neurais artificiais na estimativa da densidade básica da madeira de eucalipto.

Lopes (2018) empregou seleção de variáveis por força bruta para testar todas as possíveis combinações de variáveis de seu estudo na estimativa da densidade básica da madeira de eucalipto por RNAs. De modo geral, a autora obteve valores próximos de coeficiente de correlação no treinamento, variando de 0,84 a 0,94, e inferiores na validação, variando de 0,64 a 0,82. Os valores de vies máximo observados também foram próximos e referiram-se, respectivamente no treinamento e validação, a 1,16 e 0,79. Contudo, a amplitude de RMSE% verificados pela autora foi maior, observando-se valores máximos de 4,47% e 6,49%, respectivamente para treino e validação.

Densidade básica da madeira, temperatura de termorreificação, número de dias de secagem e material genético foram as variáveis utilizadas por Zanuncio et al. (2016; 2017) para avaliaram a aplicação de RNA na estimativa de outras propriedades físicas e em propriedades colorimétricas e mecânicas da madeira.

A densidade básica e o número de dias de secagem apresentaram melhores estatísticas ($r_{y\hat{y}} = 0,9906$ e $RMSE\% = 17,47\%$) sendo utilizadas como variáveis de entrada, quando comparadas a material genético e o número de dias de secagem ($r_{y\hat{y}} = 0,9883$ e $RMSE\% = 19,74\%$) no estudo de Zanuncio et al. (2016). Mas, ainda que a estimativa esteja associada a altas correlações, foram verificados altos percentuais de erros.

Já a temperatura de termorreificação empregada como variável de entrada para a estimativa da umidade de equilíbrio (UE%), inchamento volumétrico, MOE, MOR, luminosidade (L^*), coordenada vermelho-verde (a^*) e coordenada azul-amarelo (b^*), apresentou no estudo de Zanuncio et al. (2017) coeficientes correlações

máximos e mínimos, respectivamente, de 0,9915 e 0,9456, na validação. Os quais, ainda assim apresentaram grande amplitude de RMSE%, variando de 2,73% a 8,52%.

Avaliando-se as estatísticas (Tabela 5) das sete combinações de variáveis empregadas como variáveis de entrada para estimativa da densidade básica da madeira de eucalipto, destacam-se no treino das RNAs maiores correlações associadas às análises por regiões, porém nas classes de idade foram verificados menores valores de RMSE% e viés (%). Entre as combinações, a região Aracruz (REG-1) apresentou melhores estatísticas entre as regiões e, entre classes de idade, destaca-se a classe de quatro a seis anos (CLAS-2). Contudo, tanto no treinamento (Figura 17) quanto na validação (Figura 18), as estimativas das RNAs apresentaram tendência de superestimar os valores de densidade básica.

A análise de regressão é uma das técnicas mais empregadas em análise de dados nas Ciências Florestais. E, para atestar o desempenho das RNAs, modelos de regressão linear múltipla (RLM) foram gerados com o mesmo banco de dados para cada combinação e nas Tabelas 6 e 7 são apresentados os modelos selecionados e as estatísticas de ajuste (Tabela 6) e validação (Tabela 7) dos modelos.

As estimativas de densidade básica da madeira geradas a partir das RNAs apresentaram estatísticas próximas às dos modelos de RLM, sendo verificadas em algumas combinações melhores respostas. O viés (%) da validação dos modelos de RLM foram baixos, mas o RMSE% foi superior para a RLM quando comparadas todas as combinações, tanto para ajuste e treino quanto na validação.

Estes resultados podem estar associados ao menor número de variáveis empregadas na estimativa pelos modelos. Pois, foram aplicados os mesmos bancos de dados para cada combinação tanto para RNAs quanto para RLM, mas na seleção *stepwise* da RLM foram selecionados os modelos que apresentaram melhores estatísticas e em nenhum destes foram empregadas todas as variáveis de cada combinação, assim como nas RNAs.

Nas Figuras 19 a 24 são apresentadas as análises gráficas de correlação entre as densidades observadas e estimadas pelos modelos de RLM (Figuras 19 e 20), de distribuição dos erros percentuais (Figuras 21 e 22) e os histogramas dos erros percentuais (Figuras 23 e 24) para o ajuste e validação.

Assim como para as RNAs, foram obtidos melhores resultados entre os valores observados e estimados para as regiões (Figuras 19 e 20). Porém, com melhores ajustes observados no treino e validação para a região Bahia (REG-3).

Tabela 6 – Estatísticas utilizadas para avaliar o desempenho da regressão linear múltipla no ajuste da estimativa da densidade da madeira de árvores de eucalipto.

Combinação	Equação	Ajuste	
		R ²	RMSE (%)
COMP	$\hat{D} = 0,49016 + \hat{\beta}_{c_i}c_i - 0,016805I + \hat{\beta}_{c_i.I}c_i.I - 0,0029665DAP + 0,00123DAP.I$	0,7782	4,24
REG-1	$\hat{D} = 0,38094 + \hat{\beta}_{c_i}c_i + 0,0046458DAP$	0,7527	4,11
REG-2	$\hat{D} = 0,40064 + \hat{\beta}_{c_i}c_i + 1,52x10^{-5}P + \hat{\beta}_{c_i.P}c_i.P$	0,7714	4,12
REG-3	$\hat{D} = -11,076 + \hat{\beta}_{c_i}c_i + 0,0017318P + \hat{\beta}_{c_i.P}c_i.P + 0,13917UR + \hat{\beta}_{c_i.UR}c_i.UR - 2,09x10^{-5}P.UR$	0,8685	3,82
CLAS-1	$\hat{D} = -10,714 + \hat{\beta}_{c_i}c_i + 0,0021428DAP + 0,42831T + 0,4895I + \hat{\beta}_{c_i.I}c_i.I - 0,00024941P + \hat{\beta}_{c_i.P}c_i.P$	0,8096	3,89
CLAS-2	$\hat{D} = 0,4299 + \hat{\beta}_{c_i}c_i + 0,10747V$	0,6559	4,56
CLAS-3	$\hat{D} = 4,1007 + \hat{\beta}_{c_i}c_i - 0,14472T$	0,5864	4,16

Em que: COMP = clone, região, idade, DAP, volume, precipitação, temperatura e umidade relativa; REG= clone, idade, DAP, volume, precipitação, temperatura e umidade relativa para a região (1) Aracruz, (2) São Mateus e (3) Bahia; CL= clone, região, idade, DAP, volume, precipitação, temperatura e umidade relativa para idades no intervalo de classe de (1) 2 a 4 anos, (2) 4 a 6 anos e (3) 6 a 8 anos.

c_i = clone [$c_1 = 0$; $c_{2-18} = 1$]; $\hat{\beta}_{c_i}$ = estimativa do parâmetro da variável clone; $\hat{\beta}_{c_i.I}$ = estimativa do parâmetro da interação entre as variáveis clone (c_i) e idade; $\hat{\beta}_{c_i.P}$ = estimativa do parâmetro da interação entre as variáveis clone (c_i) e precipitação; $\hat{\beta}_{c_i.UR}$ = estimativa do parâmetro da interação entre as variáveis clone (c_i) e umidade relativa; I = idade (anos); DAP = diâmetro a altura do peito (cm); P = precipitação acumulada (mm); UR = umidade relativa (%), T = temperatura (°C) e V = volume (m³).

Os valores de $\hat{\beta}_{c_i}$; $\hat{\beta}_{c_i.I}$; $\hat{\beta}_{c_i.P}$ e $\hat{\beta}_{c_i.UR}$ estão apresentados nos Apêndices CC a II, para os clones 2 a 18 em cada combinação e equivalem a zero [$c_1 = 0$] para o clone 1.

R²= coeficiente de determinação.

RMSE(%) = raiz do quadrado médio do erro em porcentagem (%).

Tabela 7 – Estatísticas utilizadas para avaliar o desempenho da regressão linear múltipla na validação da estimativa da densidade da madeira de árvores de eucalipto.

Combinação	Equação	Validação		
		R ²	RMSE (%)	V (%)
COMP	$\hat{D} = 0,49016 + \hat{\beta}_{c_i}c_i - 0,016805I + \hat{\beta}_{c_i.I}c_i.I - 0,0029665DAP + 0,00123DAP.I$	0,7317	4,01	-0,65
REG-1	$\hat{D} = 0,38094 + \hat{\beta}_{c_i}c_i + 0,0046458DAP$	0,8039	3,04	-0,31
REG-2	$\hat{D} = 0,40064 + \hat{\beta}_{c_i}c_i + 1,52 \times 10^{-5}P + \hat{\beta}_{c_i.P}c_i.P$	0,9011	3,33	-1,65
REG-3	$\hat{D} = -11,076 + \hat{\beta}_{c_i}c_i + 0,0017318P + \hat{\beta}_{c_i.P}c_i.P + 0,13917UR + \hat{\beta}_{c_i.UR}c_i.UR - 2,09 \times 10^{-5}P.UR$	0,7950	3,59	0,08
CLAS-1	$\hat{D} = -10,714 + \hat{\beta}_{c_i}c_i + 0,0021428DAP + 0,42831T + 0,4895I + \hat{\beta}_{c_i.I}c_i.I - 0,00024941P + \hat{\beta}_{c_i.P}c_i.P$	0,7724	4,09	0,34
CLAS-2	$\hat{D} = 0,4299 + \hat{\beta}_{c_i}c_i + 0,10747V$	0,6606	4,19	-0,28
CLAS-3	$\hat{D} = 4,1007 + \hat{\beta}_{c_i}c_i - 0,14472T$	0,2708	5,03	-1,34

Em que: COMP = clone, região, idade, DAP, volume, precipitação, temperatura e umidade relativa; REG= clone, idade, DAP, volume, precipitação, temperatura e umidade relativa para a região (1) Aracruz, (2) São Mateus e (3) Bahia; CL= clone, região, idade, DAP, volume, precipitação, temperatura e umidade relativa para idades no intervalo de classe de (1) 2 a 4 anos, (2) 4 a 6 anos e (3) 6 a 8 anos.

c_i = clone [$c_1 = 0$; $c_{2-18} = 1$]; $\hat{\beta}_{c_i}$ = estimativa do parâmetro da variável clone; $\hat{\beta}_{c_i.I}$ = estimativa do parâmetro da interação entre as variáveis clone (c_i) e idade; $\hat{\beta}_{c_i.P}$ = estimativa do parâmetro da interação entre as variáveis clone (c_i) e precipitação; $\hat{\beta}_{c_i.UR}$ = estimativa do parâmetro da interação entre as variáveis clone (c_i) e umidade relativa; I = idade (anos); DAP = diâmetro a altura do peito (cm); P = precipitação acumulada (mm); UR = umidade relativa (%), T = temperatura (°C) e V = volume (m³).

Os valores de $\hat{\beta}_{c_i}$; $\hat{\beta}_{c_i.I}$; $\hat{\beta}_{c_i.P}$ e $\hat{\beta}_{c_i.UR}$ estão apresentados nos Apêndices CC a II, para os clones 2 a 18 em cada combinação e equivalem a zero [$c_1 = 0$] para o clone 1.

R²= coeficiente de determinação.

RMSE(%) = raiz do quadrado médio do erro em porcentagem (%).

V(%) = viés em porcentagem.

Figura 19 – Valores observados de densidade ($\text{g}\cdot\text{cm}^{-3}$) versus estimados no ajuste da RLM.

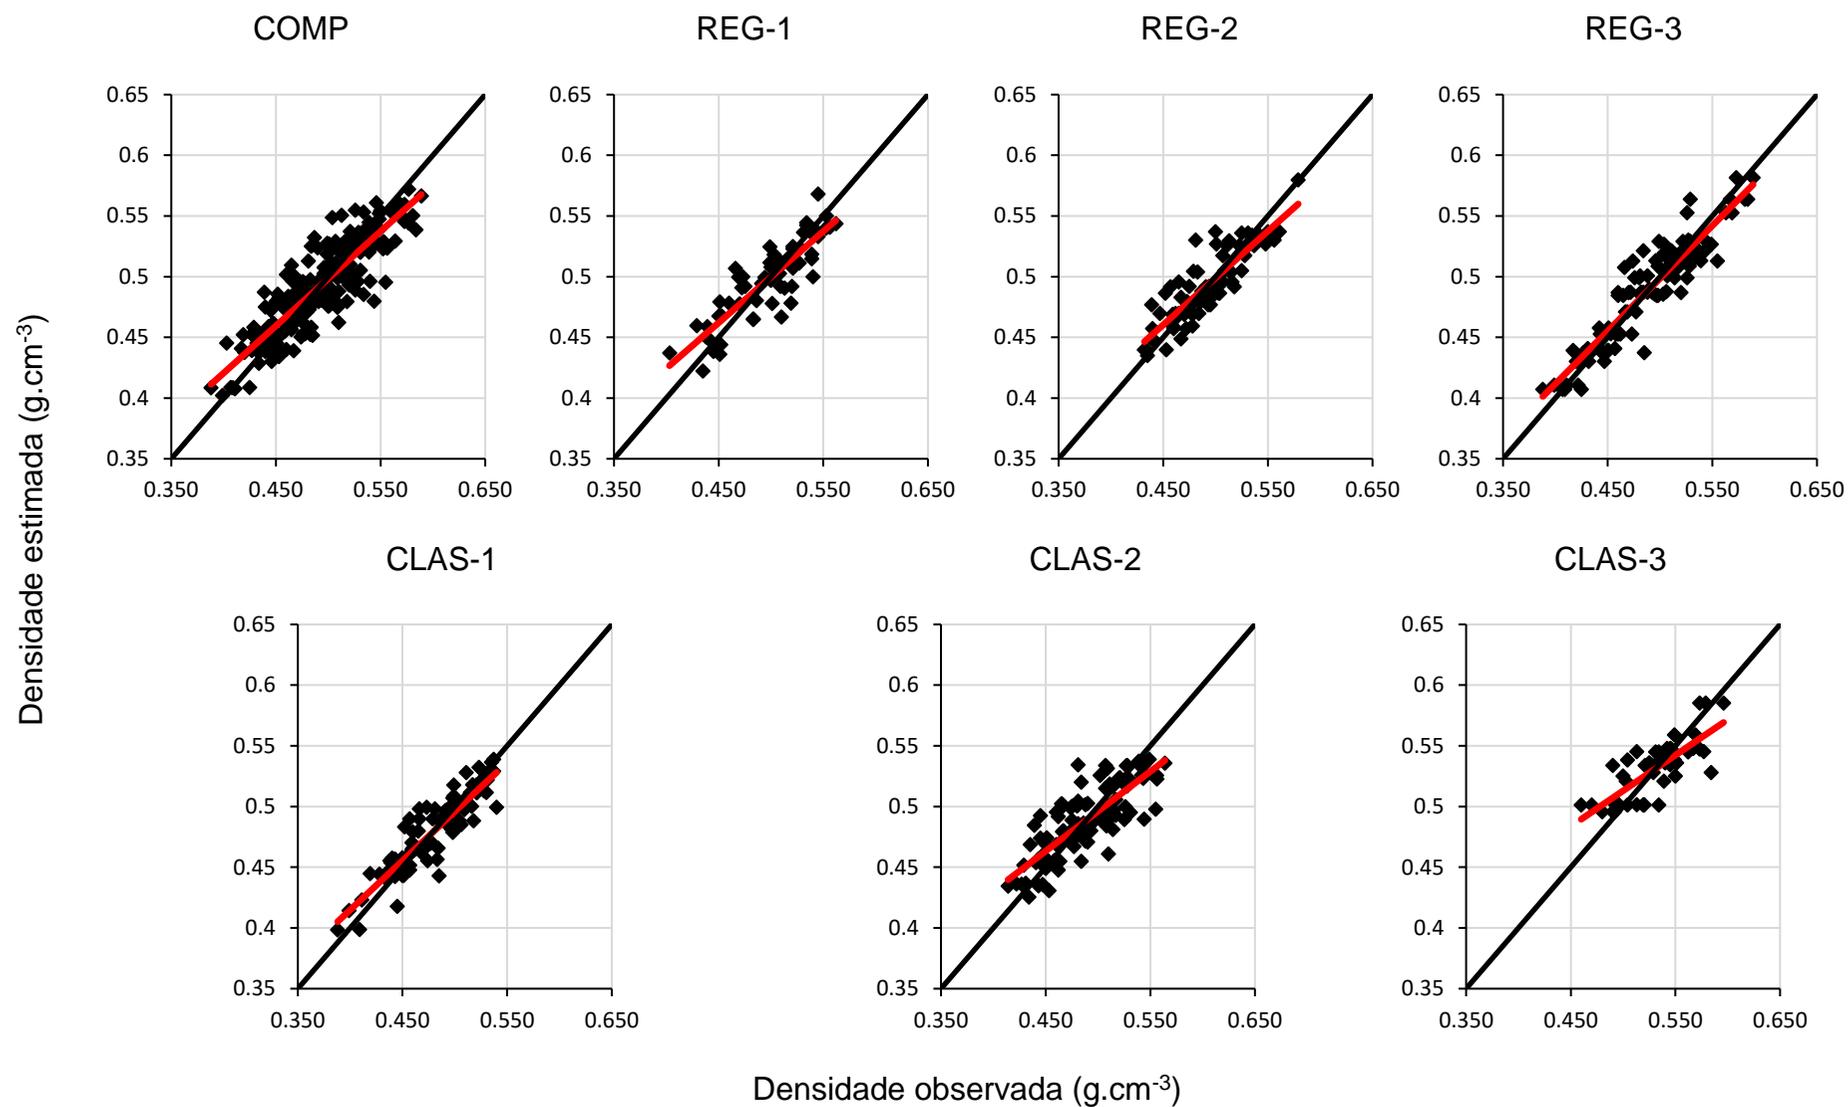


Figura 20 – Valores observados de densidade ($\text{g}\cdot\text{cm}^{-3}$) versus estimados na validação da RLM.

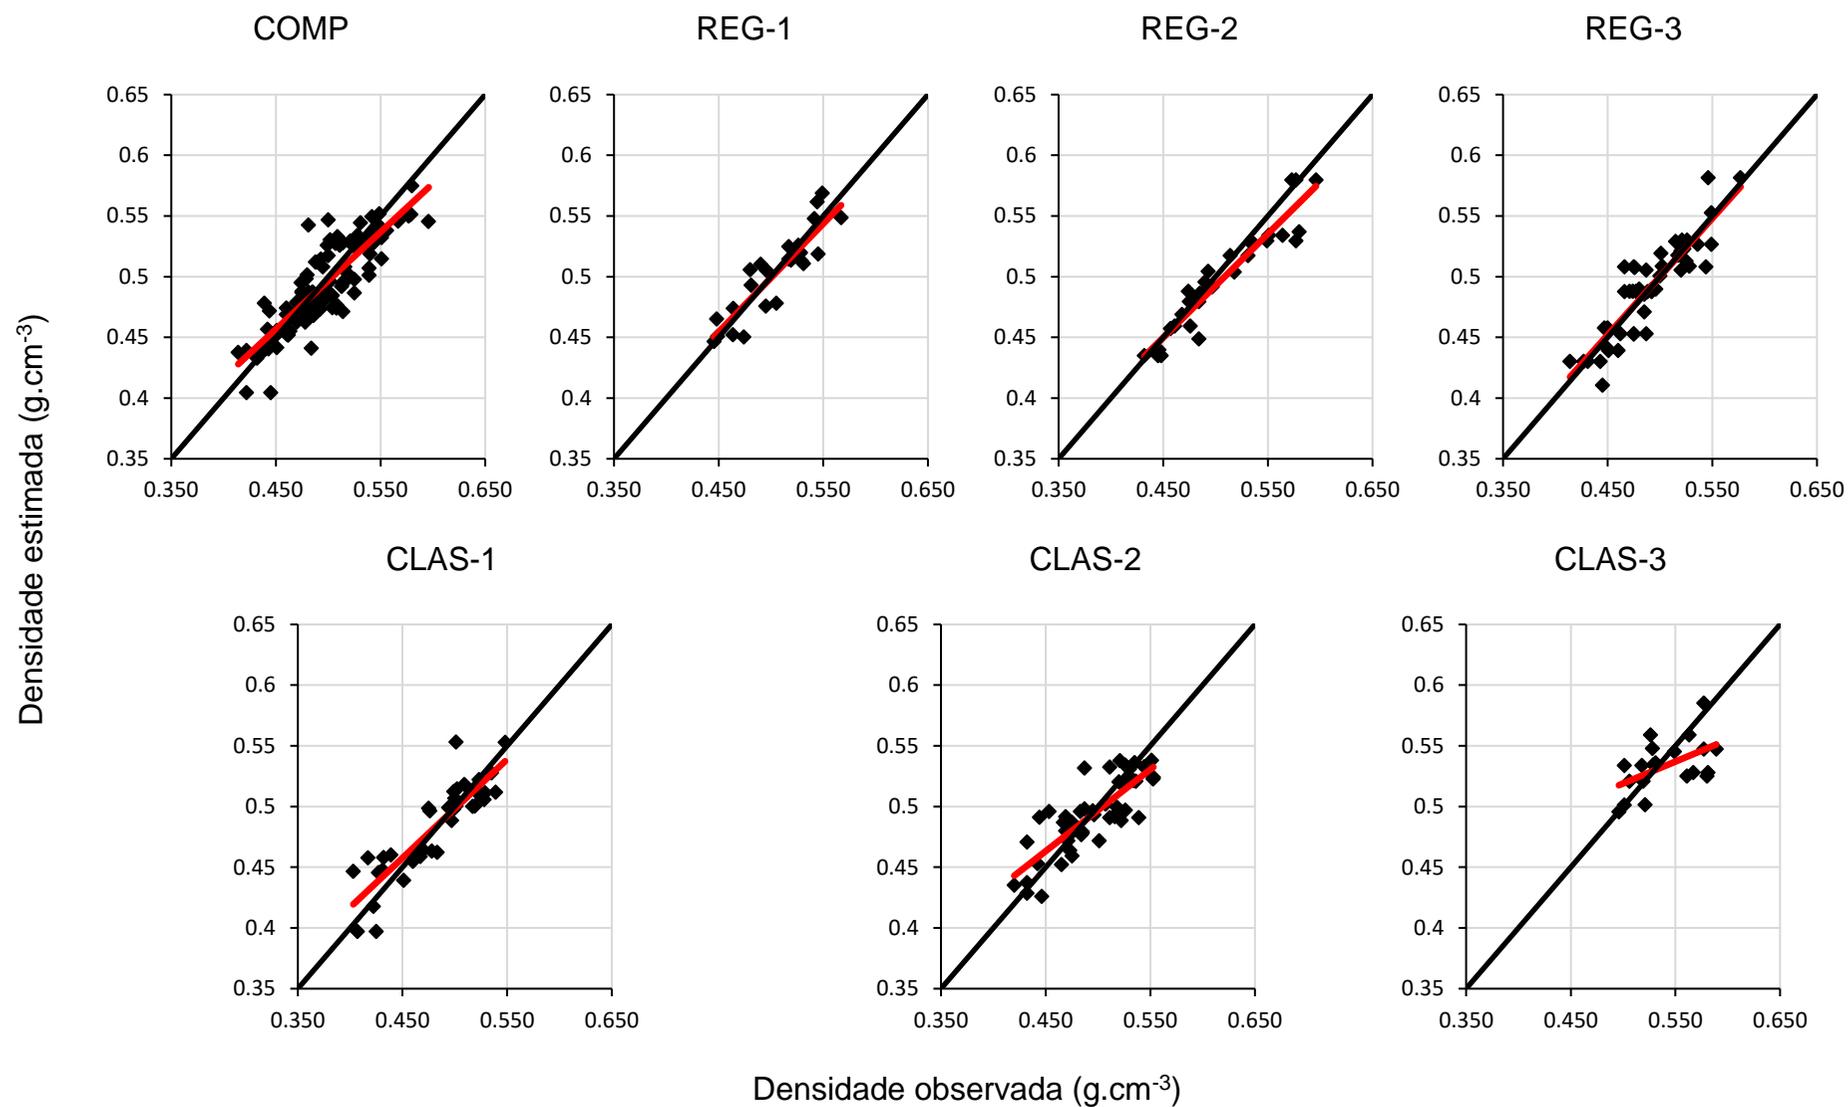


Figura 21 – Dispersão dos erros em porcentagem em relação aos valores estimados de densidade ($\text{g}\cdot\text{cm}^{-3}$) no ajuste da RLM.

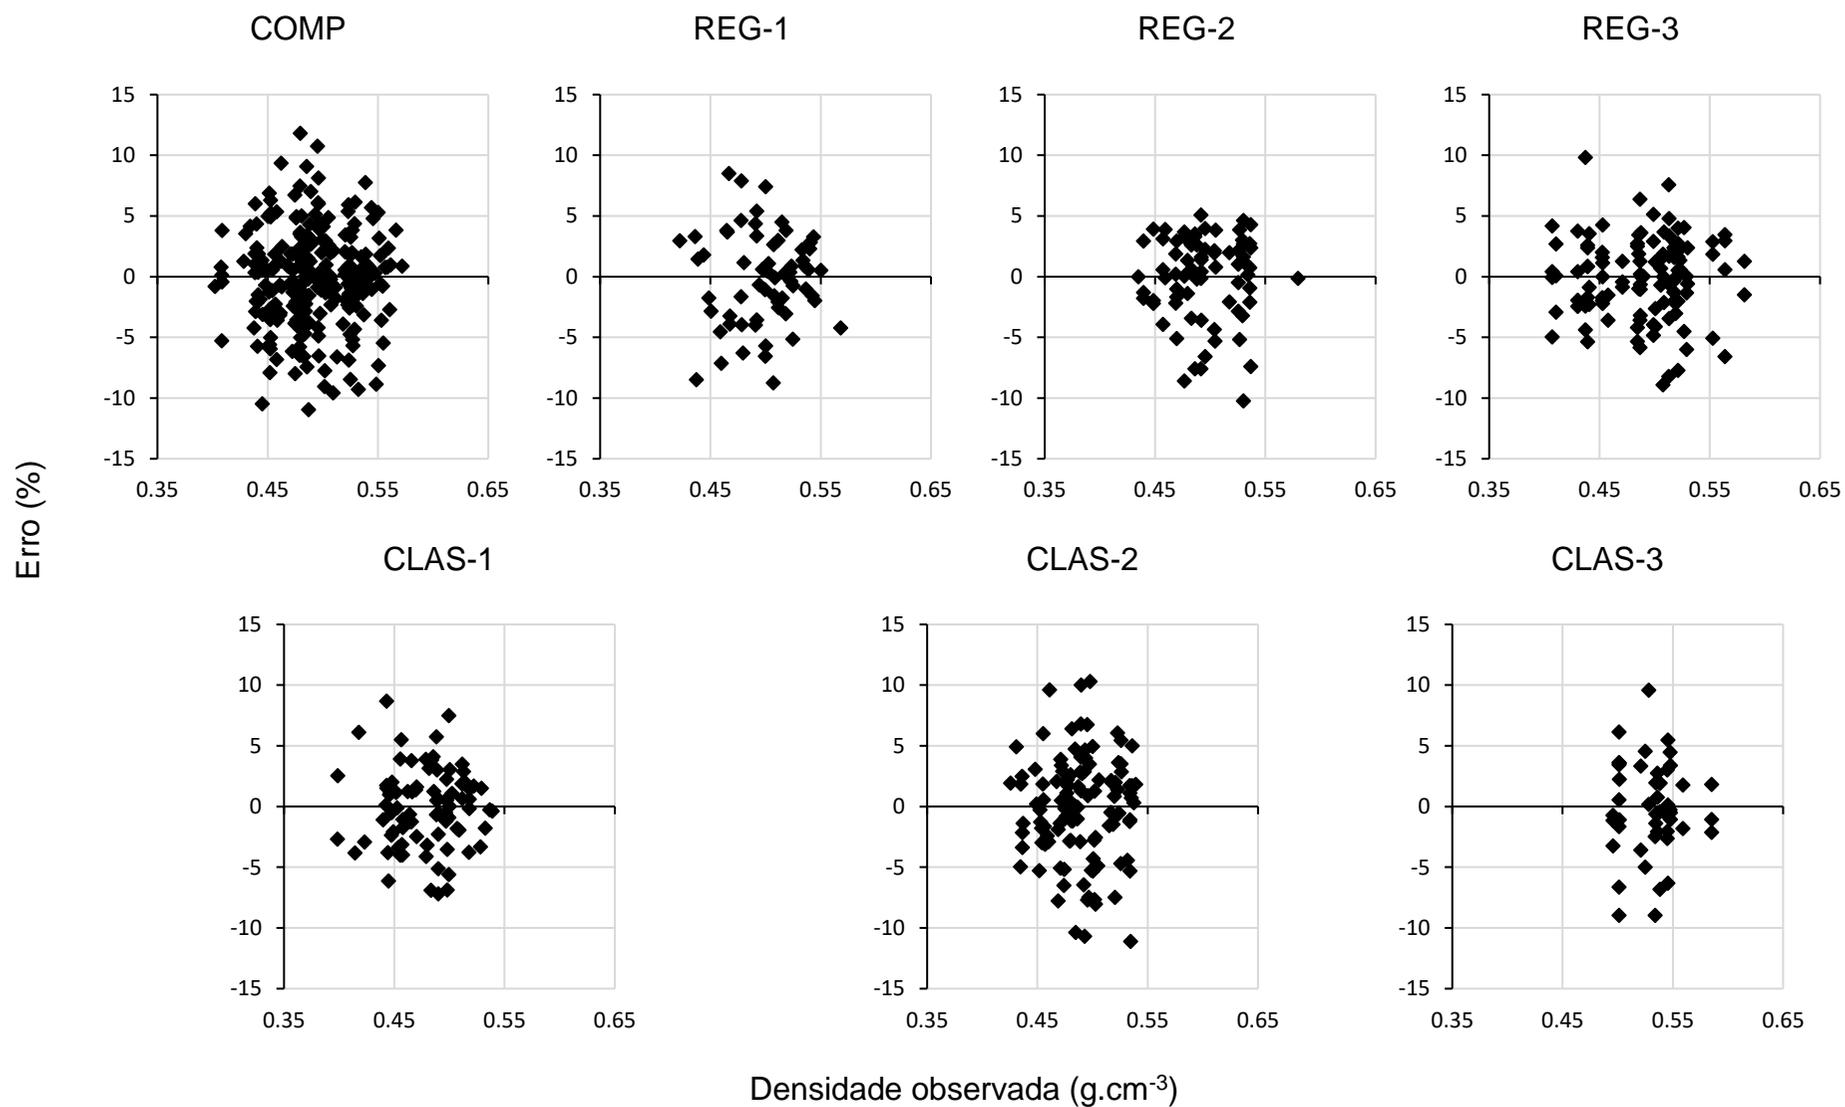


Figura 22 – Dispersão dos erros em porcentagem em relação aos valores estimados de densidade ($\text{g}\cdot\text{cm}^{-3}$) na validação da RLM.

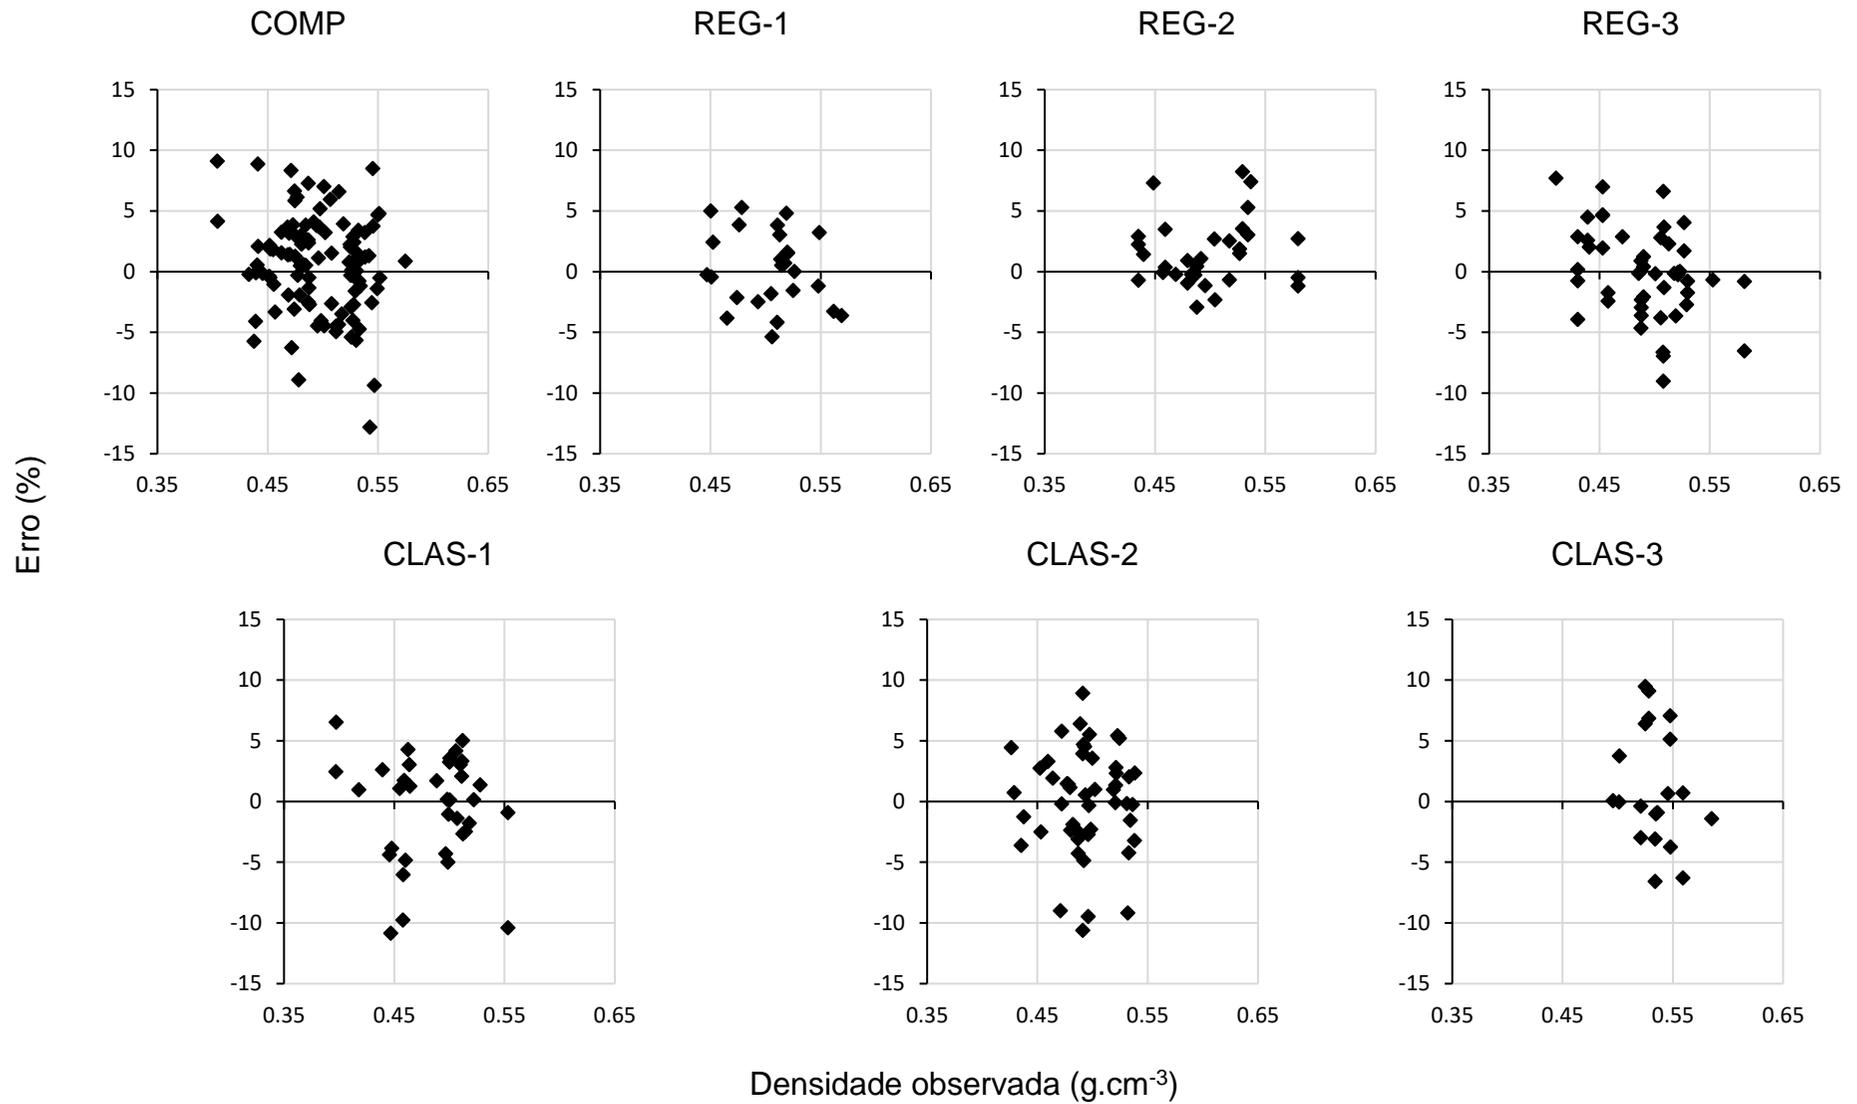


Figura 23 – Frequência relativa dos erros, em porcentagem, para estimativas de densidade (g.cm^{-3}) no ajuste da RLM.

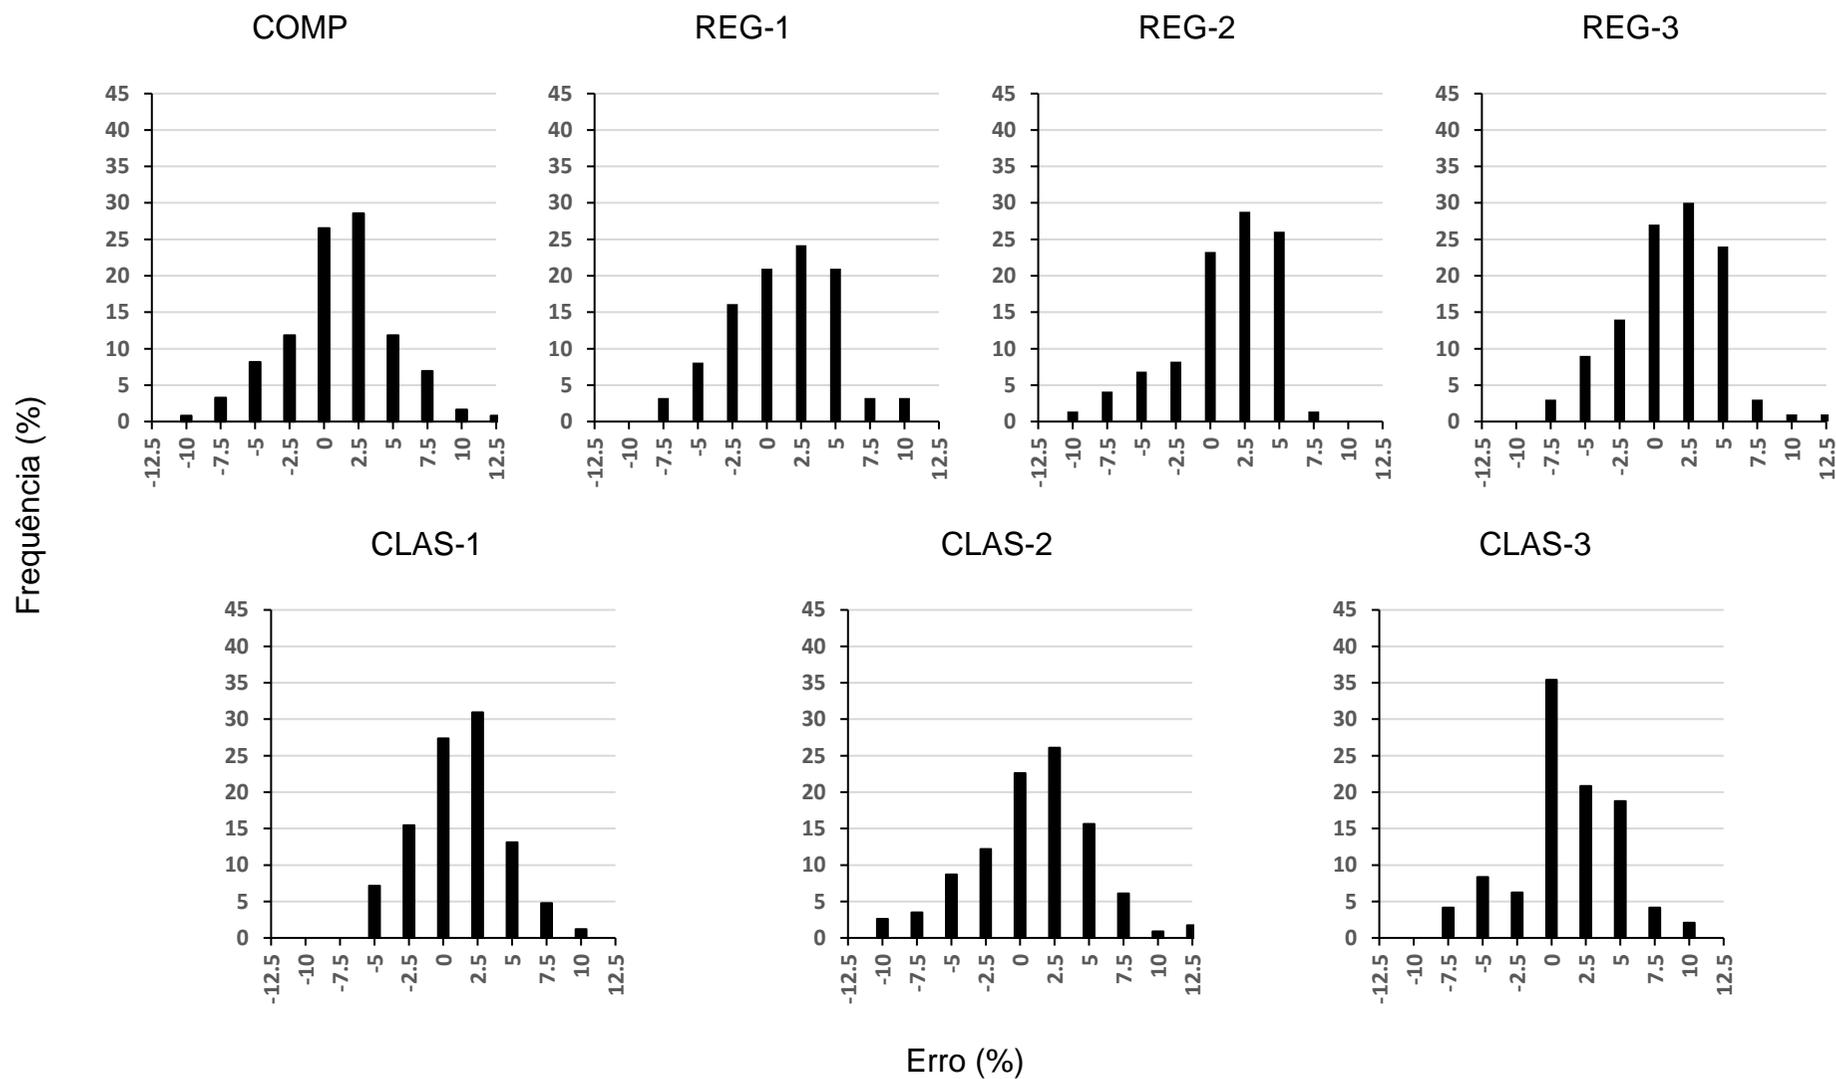
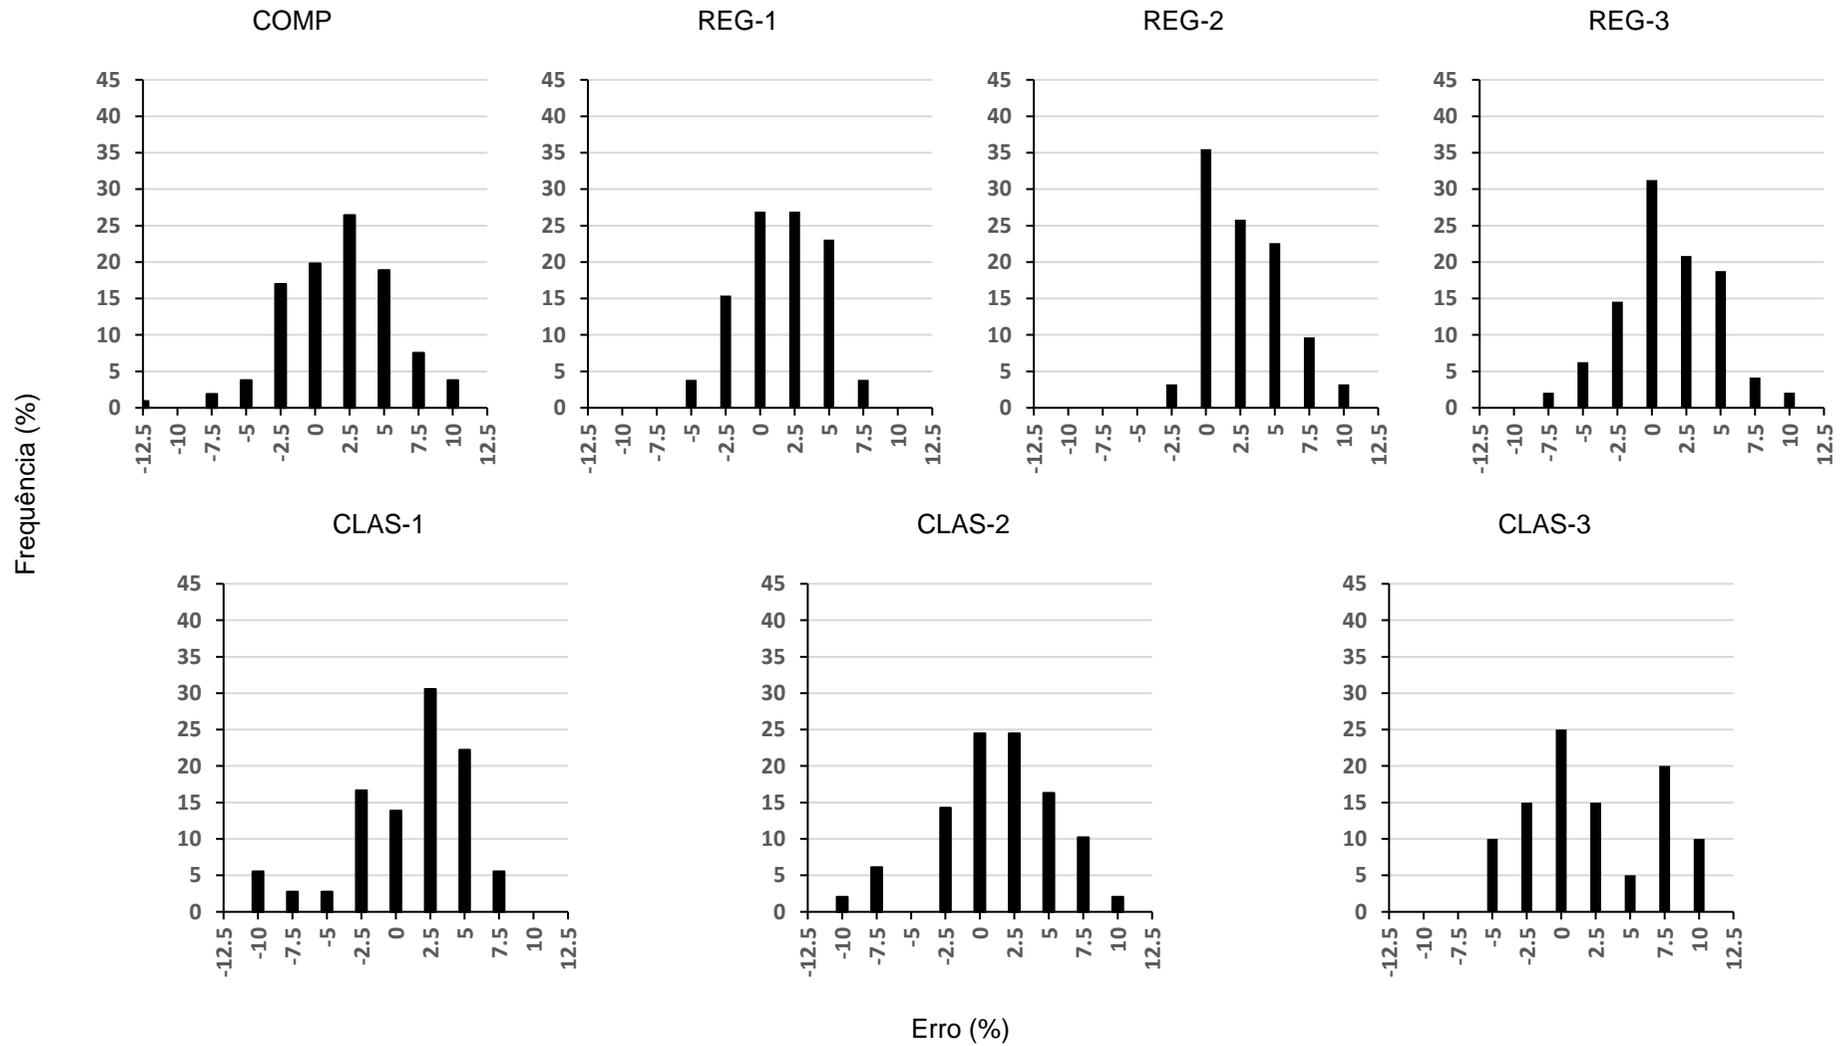


Figura 24 – Frequência relativa dos erros, em porcentagem, para estimativas de densidade básica (g.cm^{-3}) da madeira de eucalipto na validação da RLM.



Os modelos de RLM apresentaram maior dispersão de erros (Figuras 21 e 22) quando comparados as RNAs (Figuras 15 e 16), porém, nos histogramas de frequência relativa dos erros é possível verificar que a distribuição dos mesmos apresentou maior tendência a normalidade do que quando comparada às RNAs.

Na Tabela 8, são apresentados os valores de erro médio absoluto (kg.m^{-3}) do treinamento e validação das redes neurais artificiais e do ajuste e validação dos modelos de regressão linear múltipla.

Tabela 8 – Erros médios absolutos (Kg.cm^{-3}) para estimativa de densidade básica da madeira de eucalipto por RNAs e RLM.

Combinação	Erro médio absoluto (kg.m^{-3})			
	RNA		RLM	
	Treino	Validação	Ajuste	Validação
COMP	13,43	13,31	14,80	15,68
REG-1	10,92	9,77	15,12	13,03
REG-2	11,19	11,68	13,05	11,89
REG-3	12,91	12,08	12,72	13,61
CLAS-1	9,95	13,32	12,00	15,85
CLAS-2	12,10	11,44	16,09	16,46
CLAS-3	9,65	11,17	15,35	20,94

Em que: COMP = dados completos; REG = região (1) Aracruz, (2) São Mateus e (3) Bahia; CLAS = classe de idade (1) 2 a 4 anos, (2) 4 a 6 anos 3 (3) 6 a 8 anos.

Quando empregadas RNA e RLM para a estimativa da densidade básica da madeira na combinação de todas as variáveis, verificou-se diferença entre os erros médio absolutos, com tendência a serem observados maiores erros para as RLM.

De modo geral, entre treino das redes neurais artificiais e ajuste dos modelos de regressão, verifica-se em média um aumento de cerca de 24% dos erros ao empregarmos RLM quando comparado à RNA. Já ao avaliarmos a validação, a tendência da média é que os erros sejam aumentados em cerca de 30% quando empregados modelos de RLM em comparação às RNA.

5. CONCLUSÕES

As redes neurais artificiais apresentaram bom desempenho na estimativa da densidade básica da madeira de eucalipto, e todas as combinações de variáveis empregadas na estimativa foram eficientes. Contudo, houve tendência de superestimação dos valores.

Especificar as regiões e as classes de idade permitiu que fossem alcançados melhores resultados na estimativa por RNAs. E, entre as RNAs treinadas para estimar a densidade da madeira de eucalipto para as três regiões, na região Aracruz (REG-1) foi possível obter resultados mais precisos. Assim como, para árvores com idade variando de quatro a seis anos (CLAS-2) também foram verificados melhores resultados.

As redes neurais apresentaram resultados satisfatórios, quando comparadas a técnica de regressão linear múltipla, sendo esta uma técnica já reconhecida nas análises da Ciência Florestal. Deste modo, é possível assegurar a eficiência das redes neurais na estimativa da densidade básica da madeira de eucalipto.

6. REFERÊNCIAS BIBLIOGRÁFICAS

AMPARADO, K. F.; CARVALHO, A. M.; GARCIA, R. A.; LATORRACA, J. V. F.. Caracterização em madeira serrada de *Eucalyptus saligna* Smith nas condições verde e seca. **Revista Forestal Venezolana**, Mérida, v. 52, n.1, p 71-76, 2008.

ANDRADE, A. S. de. **Qualidade da madeira, celulose e papel em *Pinus taeda* L.: influência da idade e classe de produtividade**. 107p. Dissertação (Mestrado em Ciências Florestais) – Programa de Pós-Graduação em Engenharia Florestal, Universidade Federal do Paraná. Curitiba, 2006.

ANDRIONI, J. L. **Fabricação de papel**: preparo da massa. Curitiba: SENAI, 2006.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS – ABNT. **NBR-11941**: madeira - determinação da densidade básica. Rio de Janeiro: 2003.

AVRAMIDIS, S.; ILIADIS, L. Predicting wood thermal conductivity using artificial neural networks. **Wood and Fiber Science**, v. 37, n. 4, p. 682–690, 2005.

BARBOSA, T. L. **Qualidade da madeira de clones de *Eucalyptus grandis* x *Eucalyptus urophylla* cultivados em cinco regiões do estado de minas gerais para produção de celulose**. 125p. Dissertação (Mestrado em Ciências Florestais) – Programa de Pós-Graduação em Ciências Florestais, Universidade Federal do Espírito Santo, Jerônimo Monteiro, 2013.

BATISTA, D. C. **Modificação térmica da madeira de *Eucalyptus grandis* em escala industrial pelo processo brasileiro VAP HolzSysteme®**. 339p. Tese (Doutorado em Engenharia Florestal) – Programa de Pós-Graduação em Engenharia Florestal – Universidade Federal do Paraná, Curitiba, 2012.

BATISTA, J. L. F.; COUTO, H. T. Z.; SILVA FILHO, D. F. da. **Quantificação de recursos florestais**: árvores, arvoredos e florestas. São Paulo: Oficina de Textos, 2014.

BINOTI, M. L. M. da S. **Redes neurais artificiais para prognose da produção de povoamentos não desbastados de eucalipto**. 64p. Tese (Doutorado em Ciência Florestal) – Programa de Pós-Graduação em Ciência Florestal – Universidade Federal de Viçosa, Viçosa, 2010.

BINOTI, M. L. M.; LEITE, H. G.; BINOTI, D. H. B.; GLERIANI, J. M. Prognose em nível de povoamento de clones de eucalipto empregando redes neurais artificiais. **Cerne**, Lavras, v. 21, n. 1, p. 97-105, 2015.

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

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

CARDOSO, G. da S. **Fabricação de celulose**. Curitiba: SENAI, 2006.

DANCEY, C. P.; REIDY, J. **Estatística sem matemática para psicologia: usando SPSS para Windows**. Porto Alegre: Artmed, 2006. 608p.

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.

DOSSA, D.; SILVA, H. D.; BELLOTE, A. F. J.; RODIGHIERI, H. R. Comunicado técnico 83: produção e rentabilidade do eucalipto em empresas florestais. **Embrapa Florestas**, Paraná. 2010.

DUARTE, F. A. S. **Avaliação da madeira de Betula pendula, Eucalyptus globulus e de híbrido de Eucalyptus grandis x Eucalyptus urophylla destinadas à produção de celulósica Kraft**. 2007. 107p. Dissertação (Mestrado em Recursos Florestais), Universidade de São Paulo, Escola Superior de Agricultura "Luiz de Queiroz", Piracicaba, 2007.

FOOD AND AGRICULTURE ORGANIZATION OF THE UNITED NATIONS – FAO. **Yearbook 2015: Forest products**. FAO: Roma, 2017.

FANTUZZI NETO, H. **Qualidade da madeira de eucalipto para produção de celulose kraft**. 119p. Tese (Doutorado em Ciência Florestal) – Programa de Pós-Graduação em Ciência Florestal, Universidade Federal de Viçosa, Viçosa, 2012.

FAUSETT, L. **Fundamentals of neural networks: architectures, algorithms and applications**. New Jersey: Prentice-Hall, 1994.

FERREIRA, M. M. C.; MONTANARI, C. A.; GAUDIO, A. C. Seleção de variáveis em QSAR. **Química nova**, v. 25, n. 3, p. 439-448, 2002.

FIBRIA. **Relatório 2017: uma floresta de oportunidades**. 2017. Disponível em: <<http://www.fibria.com.br/comunicacao/relatorios-anuais/>>. Acesso em: 02 ago. 2018.

FOELKEL, C. **Eucalyptus online book – Capítulo 17: diferenciando polpas de mercado e papéis de eucalipto através da gestão dos finos celulósicos da polpa**. 2009. Disponível em: <<http://www.eucalyptus.com.br>>. Acesso em: 17 dez. 2013.

FOELKEL, C. **Eucalyptus online book – Capítulo 31: aspectos práticos e conceituais sobre a fabricação de celulose de mercado do tipo kraft branqueada a partir de madeira de eucalipto**. 2013. Disponível em: <<http://www.eucalyptus.com.br>>. Acesso em: 17 dez. 2013.

FOELKEL, C. **Eucalyptus online book – Capítulo 41: qualidade da madeira do eucalipto – reflexões acerca da utilização da densidade básica como indicador de qualidade da madeira no setor de base florestal**. 2015a. Disponível em: <<http://www.eucalyptus.com.br>>. Acesso em: 27 out. 2017.

FOELKEL, C. **Eucalyptus online book – Capítulo 42:** qualidade da madeira do eucalipto – acerca dos acertos e erros na utilização da densidade básica como indicador de qualidade de madeiras. 2015b. Disponível em: <<http://www.eucalyptus.com.br>>. Acesso em: 27 out. 2017.

GOLDSCHMIDT, R.; PASSOS, E. **Data mining:** um guia prático. Rio de Janeiro: Elsevier, 2005.

GOMIDE, J. L.; FANTUZZI NETO, H.; LEITE, H. G. Estratégia de análise da qualidade de madeira de Eucalyptus sp. para produção de celulose. **Revista Árvore**, Viçosa, v.28, n.3, p. 443-450, 2004.

GÖRGENS, E. **Estimação do volume de utilizando redes neurais artificiais.** 2006. 84p. Dissertação (Mestrado em Ciência Florestal) - Programa de Pós-Graduação em Ciência Florestal – Universidade Federal de Viçosa, Viçosa, MG, 2006.

GOUVÊA, A. de F. G.; TRUGILO, P. F.; COLODETTE, J. L.; LIMA, J. T.; SILVA, J. R. N M. da; GOMIDE, J. L. Avaliação da madeira e da polpação kraft em clones de eucaliptos. **Revista Árvore**, Viçosa, v.33, n.6, p.1175-1185, 2009.

GURNEY, K. **An introduction to neural networks.** London: Routledgere, 1997.

HAIR JUNIOR, J. F.; ANDERSON, R. E.; TATHAM, R. L; BLACK, W. C. trad. SANT'ANNA, A. S.; CHAVES NETO, A. **Análise multivariada dos dados.** 5 ed. Porto Alegre: Bookman, 2005.

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

HEATON, J. **Programming Neural Networks with Encog3 in Java.** 2ed. Missouri: Heaton Research, Incorporated, 2011.

HOFFMANN, R. **Análise de regressão:** uma introdução à econometria. 4 ed. São Paulo: Editora Hucitec, 2006.

HU, Y. H.; HWANG, J. Introduction to neural networks for signal processing. In: HU, Y. H.; HWANG, J. **Handbook of neural network signal processing.** Boca Raton: CRC, 2001.

INDÚSTRIA BRASILEIRA DE ÁRVORES – IBÁ. **Relatório anual 2017.** Brasília: IBA, 2017.

INSTITUTO NACIONAL DE METEOROLOGIA – INMET. **Banco de Dados Meteorológicos para Ensino e Pesquisa.** Disponível em: <<http://www.inmet.gov.br/portal/index.php?r=bdmep/bdmep>>. Acesso em: 03 jul. 2018.

JAIN, A. K.; MAO, J.; MOHIUDDIN, K. M. Artificial Neural Networks: a tutorial. **Computer**, v. 29, n. 3, p. 31-44, 1996.

KHARE, M.; NAGENDRA, S. M. S. **Artificial neural networks in vehicular pollution modelling**. Heidelberg: Springer, 2007.

LEITE, H. G.; BINOTI, D. H. B.; OLIVEIRA NETO, R. R.; LOPES, P. F.; CASTRO, R. R.; PAULINO, E. J.; BINOTI, M. L. M. S.; COLODETTE, J. L. Redes Neurais Artificiais para a estimação da densidade básica da madeira. **Scientia Forestalis**, Piracicaba, v.44, n.109, p.149-154, 2016.

LOPES, I. L. **Avaliação e seleção de variáveis preditoras na estimativa da densidade da madeira de eucalipto**. 73p. Dissertação (Mestrado em Ciências Florestais) – Programa de Pós-Graduação em Ciências Florestais, Universidade Federal do Espírito Santo, Jerônimo Monteiro, 2018.

MA, H.; DONG, Y.; CHEN, Z.; LIAO, W.; LEI, B.; GAO, K.; LI, S.; AN, X. variation in the growth traits and wood properties of hybrid white poplar clones. **Forests**, v. 6, p. 1107-1120, 2015.

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.

MELO, R. R.; MIGUEL, E. P. Use of artificial neural networks in predicting particleboard quality parameters. **Revista Árvore**, v. 40, n. 5, p. 949-958, 2016.

MYERS, R. H. **Classical and modern regression with applications**. Boston: PWS-KENT Publishing Company, 1989.

NAHUZ, M. Atividades industriais, usos e aplicações de madeiras no Brasil, com ênfase em *Pinus* e *Eucalyptus*. In: **Tecnologias aplicadas ao setor madeireiro II**. Eds.: OLIVEIRA, J. T. S.; FIEDLER, N. C.; NOGUEIRA, M. Jerônimo Monteiro, 2007.

NUNES, C. A.; LIMA, C. F.; BARBOSA, L. C. A.; COLODETTE, J. L.; FIDÊNCIO, P. H. Determinação de constituintes químicos em madeira de eucalipto por Pi-CG/EM e calibração multivariada: comparação entre redes neurais artificiais e máquinas de vetor suporte. **Química Nova**, v. 34, n. 2, p. 279-283, 2011.

PANSHIN, A. J.; DE ZEEUW, C. **Textbook of wood technology: structure, identification, properties and uses of the commercial woods of the United States and Canada**. 4. ed. New York: McGraw-Hill, 1980.

PEDRAZZI, C.; COLODETTE, J. L.; OLIVEIRA, R. C. de.; WILLE, V. K. D. Avaliação morfológica das fibras de polpas kraft de Eucalipto com diferentes conteúdos de Xilanas. **Scientia Forestalis**, Piracicaba, v. 41, n. 100, p. 515-522, 2013.

PEREIRA, J. C. D.; STURION, J. A.; HIGA, A. R.; HIGA, R. C. V.; SHIMIZU, J. Y. **Características da madeira de algumas espécies de eucalipto plantadas no Brasil**. Colombo: Embrapa Florestas, 2000.

PONCE, R. H. Madeira serrada de eucalipto: desafios e perspectivas. In: SEMINÁRIO INTERNACIONAL DE UTILIZAÇÃO DE MADEIRA DE EUCALIPTO PARA SERRARIA. São Paulo, 1995. **Anais...** Piracicaba, São Paulo: IPEF, p.50-58, 1995.

QI, D.; ZHANG, P.; YU, L. Study on wood defect detection based on artificial Neural network. 2008. In: **IEEE Conference on Cybernetics and Intelligent Systems**, 2008, pp. 951-956.

QUEIROZ, L. R. S.; BARRICHELO, L. E. G. **O eucalipto: um século no Brasil**. São Paulo: Neoband Soluções Gráficas, 2007.

REIS, P. C. M. R. **Análise estrutural e propriedades tecnológicas da Madeira de espécies da Amazônia**. Tese (Doutorado em Ciência Florestal) – Programa de Pós-graduação em Ciência Florestal – Universidade Federal de Viçosa, Viçosa, 2017.

RIBEIRO, R. N. **Utilização de redes neurais artificiais e tecnologia FT-NIR para predição do número kappa em um processo kraft de cozimento de madeira em indústria de celulose**. 144p. Dissertação (Mestrado em Engenharia Industrial) – Programa de Pós-Graduação em Engenharia – Centro Universitário do Leste de Minas Gerais, Coronel Fabriciano, 2007.

RIBEIRO JÚNIOR, J. I. **Análises estatísticas no Excel: guia prático**. 2 ed. Viçosa: Editora UFV, 2013.

ROCHA, S. M. G. **Densidade básica da madeira de eucalipto em gradientes climáticos no Brasil**. 48p. Dissertação (Mestrado em Ciências Florestais) – Programa de Pós-Graduação em Ciências Florestais, Universidade Federal do Espírito Santo, Jerônimo Monteiro, 2018.

SANTOS, S. R. **Influência da qualidade da madeira de híbridos de *Eucalyptus grandis* x *Eucalyptus urophylla* e do processo Kraft de polpação na qualidade da polpa branqueada**. 178p. Dissertação (Mestrado em Recursos Florestais) – Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo, Piracicaba, 2005.

SHMULSKY, R. JONES, P. D. **Forest Products & Wood Science: an introduction**. 6 ed. New Jersey: Wilwey-Blackwell. 2011.

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

SILVA, J. C.; CASTRO, V. R. **Propriedades e usos da madeira de eucalipto**. Viçosa: Arbotec, 2014.

SOARES, C. P. B.; PAULA NETO, F. de.; SOUZA, A. L. de. **Dendrometria e inventário florestal**. 2ª ed. Viçosa: Editora da UFV, 2011.

STEIN, F. da R. **Modelagem de produção industrial de celulose kraft com modelos aditivos generalizados e redes neurais**. 109p. Dissertação (Mestrado

Profissional em Tecnologia de Celulose e Papel) – Universidade Federal de Viçosa, Viçosa, 2010.

SWENSON, N. G.; ENQUIST, B. J. Ecological and evolutionary determinants of a keyplant functional trait: wood density and its community-wide variation across latitude and elevation. **American Journal of Botany**, n. 94, v. 3, p. 451–459. 2007.

TRUGILHO, P. F.; BIANCHI, M. L.; ROSADO, S. C. S.; LIMA, J. T. Qualidade da madeira de clones de espécies e híbridos naturais de Eucalyptus. **Scientia Forestalis**, n. 73, p. 55-62, 2007.

VAN LAAR, A.; AKÇA, A. **Forest Mensuration**. 2. ed. Dordrecht: Springer, 2007.

YAPICI, F.; ESEN, R.; ERKAYMAZ, O.; BAS, H. Modeling of compressive strength parallel to grain of heat treated scotch pine (*Pinus sylvestris* L.) wood by using artificial neural network. **Drvna Industrija**, v. 66, n.4, p. 347-352, 2015.

ZANETTI, S. S.; CECÍLIO, R. A.; ALVES, E. G.; SILVA, V. H.; SOUSA, E. F. Estimation of the moisture content of tropical soils using colour images and artificial neural networks. **Catena**, n. 135, p.100-106, 2015 (a).

ZANETTI, S. S.; CECÍLIO, R. A.; ALVES, E. G.; SILVA, V. H. General calibration of TDR to assess the moisture of tropical soils using artificial neural networks. **Catena**, n. 135, p.100-106, 2015 (b).

ZANUNCIO, A. J. V., CARVALHO, A. G.; SILVA, L. F.; CARNEIRO, A. C. O.; COLODETE, J. L. Artificial neural networks as a new tool for assessing and monitoring wood moisture content. **Revista Árvore**, v.40, n.3, p.543-549, 2016.

ZANUNCIO, A. J. V., CARVALHO, A. G.; SILVA, L. F.; SILVA, M. G.; CARNEIRO, A. C. O.; COLODETE, J. L. Prediction of the physical, mechanical and colorimetric properties of Eucalyptus grandis heat-treated wood using artificial neural networks. **Scientia Forestalis**, v. 45, n. 113, p. 109-118, 2017.

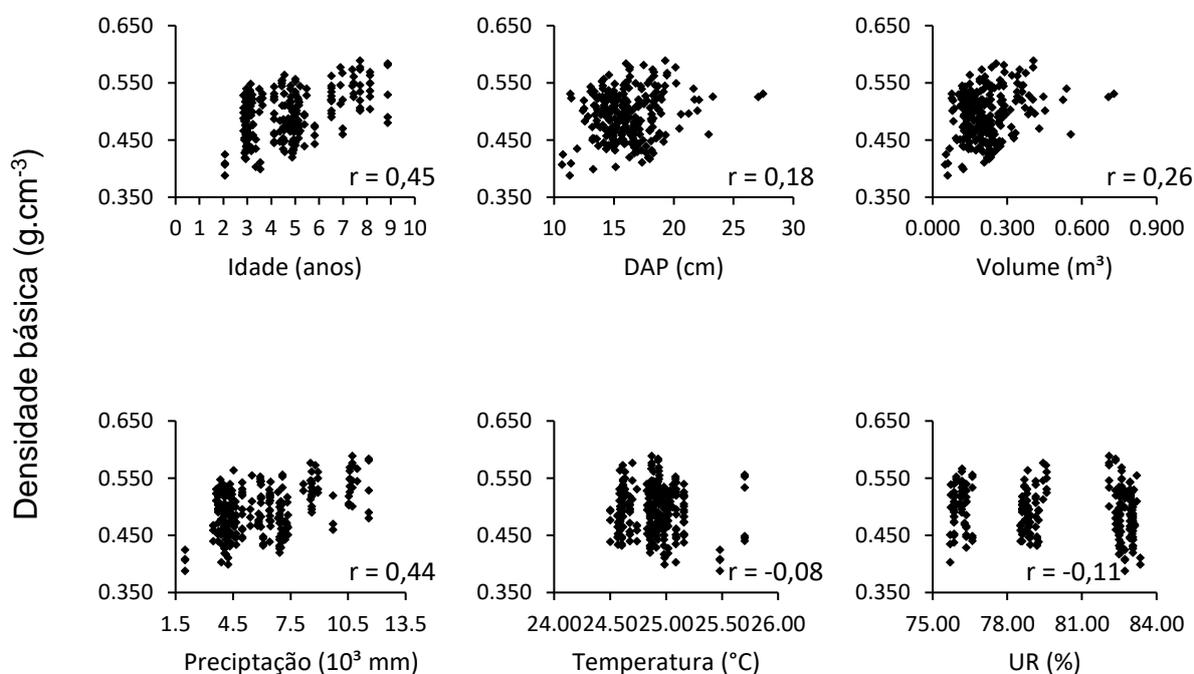
APÊNDICES

APÊNDICE A – Análise descritiva das variáveis quantitativas relativas ao treino das redes e ajuste dos modelos na combinação COMP (completos).

Variáveis	Mínimo	Média	Máximo	CV(%)
Idade (anos)	2,05	4,64	8,86	-
DAP (cm)	10,66	16,11	27,47	14,84
Volume (m ³)	0,050	0,215	0,729	45,80
Precipitação acumulada (mm)	1989,40	6017,04	11562,90	37,36
Temperatura (°C)	24,50	24,90	25,70	0,93
Umidade relativa (%)	75,70	79,98	83,34	3,52
Densidade básica (g.cm ⁻³)	0,388	0,493	0,589	8,35

CV : Coeficiente de variação.

APÊNDICE B – Correlação entre a densidade básica da madeira e as variáveis quantitativas do estudo, relativo ao treino das redes e ajuste dos modelos na combinação COMP (completos).

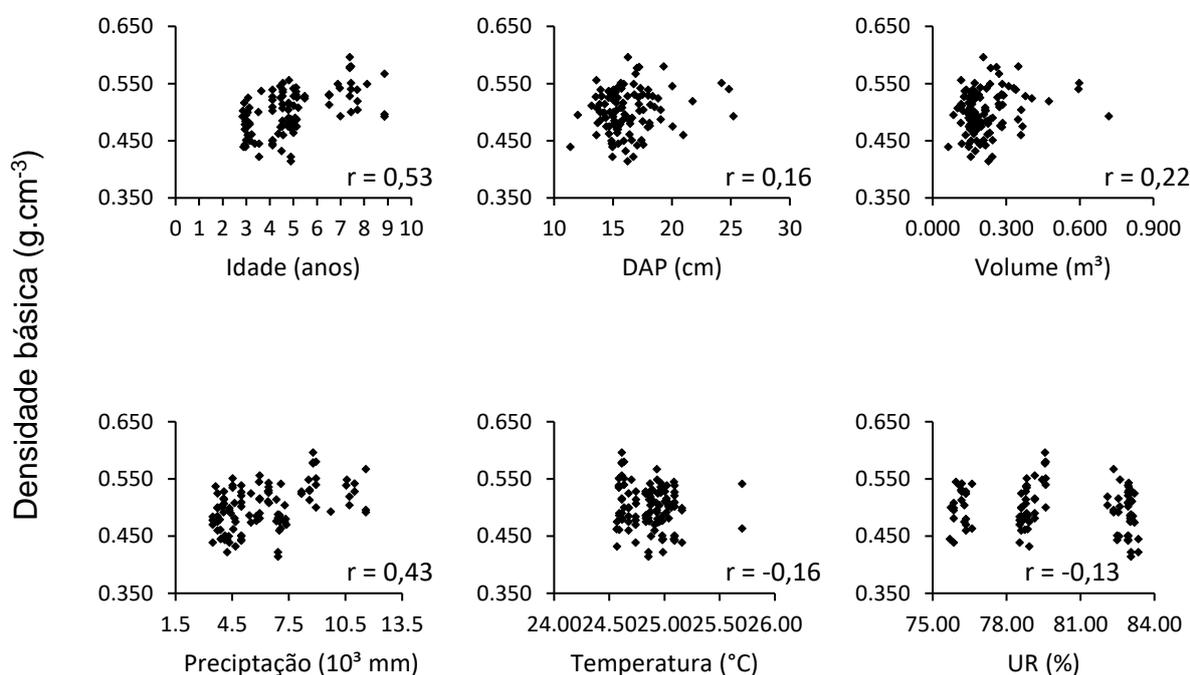


APÊNDICE C – Análise descritiva das variáveis quantitativas relativas à validação das redes e dos modelos na combinação COMP (completos).

Variáveis	Mínimo	Média	Máximo	CV(%)
Idade (anos)	2,84	4,85	8,86	-
DAP (cm)	11,36	16,21	25,21	14,23
Volume (m ³)	0,063	0,219	0,718	47,39
Precipitação acumulada (mm)	3466,10	6205,00	11562,90	35,68
Temperatura (°C)	24,57	24,87	25,70	0,84
Umidade relativa (%)	75,70	79,97	83,34	3,40
Densidade básica (g.cm ⁻³)	0,414	0,500	0,596	7,58

CV : Coeficiente de variação.

APÊNDICE D – Correlação entre a densidade básica da madeira e as variáveis quantitativas do estudo, relativo à validação das redes e dos modelos na combinação COMP (completos).

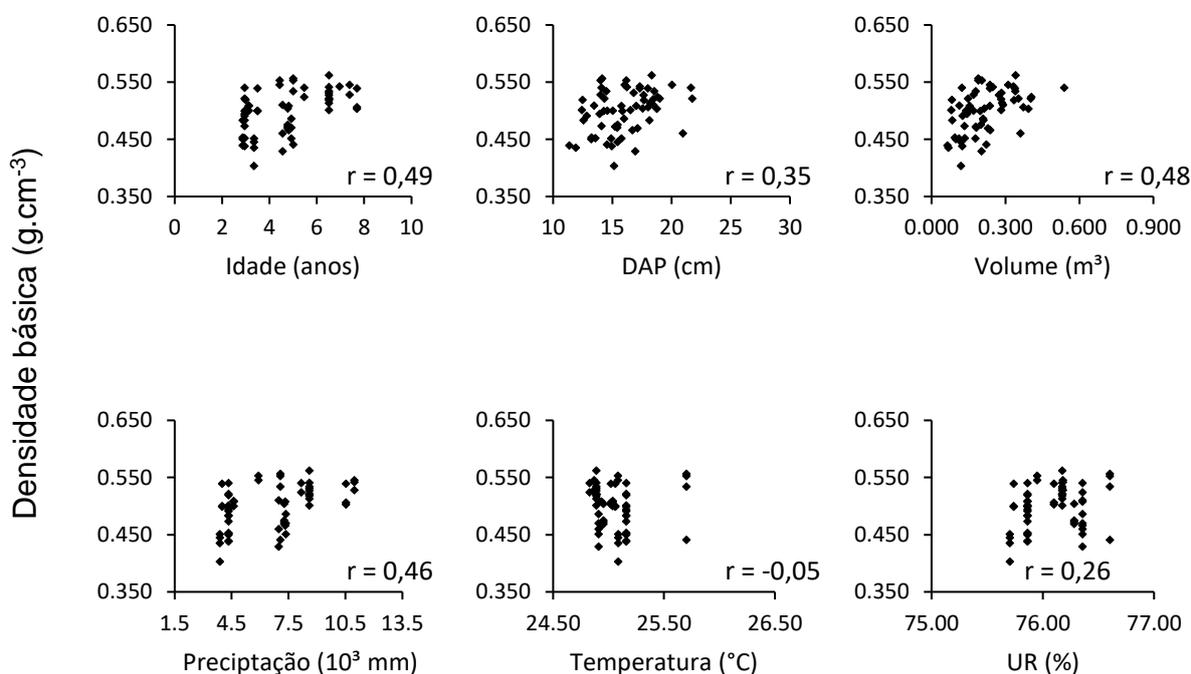


APÊNDICE E – Análise descritiva das variáveis quantitativas relativas ao treino das redes e ajuste dos modelos na combinação REG-1 (Aracruz).

Variáveis	Mínimo	Média	Máximo	CV(%)
Idade (anos)	2,88	4,69	7,70	-
DAP (cm)	11,36	16,01	21,74	14,78
Volume (m ³)	0,063	0,217	0,538	46,72
Precipitação acumulada (mm)	3879,70	6593,10	10964,70	33,49
Temperatura (°C)	24,83	25,05	25,70	0,82
Umidade relativa (%)	75,70	76,09	76,60	0,33
Densidade básica (g.cm ⁻³)	0,403	0,499	0,562	7,56

CV : Coeficiente de variação.

APÊNDICE F – Correlação entre a densidade básica da madeira e as variáveis quantitativas do estudo, relativo ao treino das redes e ajuste dos modelos na combinação REG-1 (Aracruz).

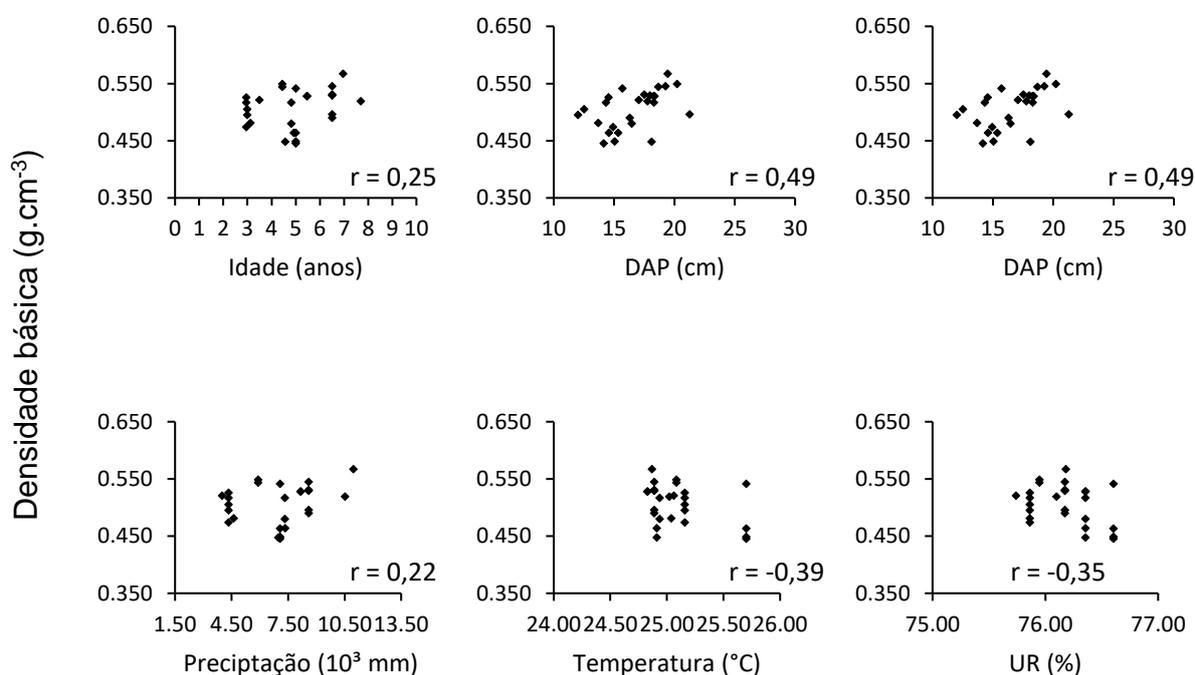


APÊNDICE G – Análise descritiva das variáveis quantitativas relativas à validação das redes e dos modelos na combinação REG-1 (Aracruz).

Variáveis	Mínimo	Média	Máximo	CV(%)
Idade (anos)	2,95	4,91	7,70	-
DAP (cm)	12,00	16,61	21,26	11,26
Volume (m ³)	0,085	0,252	0,410	23,42
Precipitação acumulada (mm)	4006,70	6932,51	10964,70	17,90
Temperatura (°C)	24,83	25,10	25,70	1,11
Umidade relativa (%)	75,74	76,17	76,60	0,35
Densidade básica (g.cm ⁻³)	0,446	0,506	0,567	6,07

CV : Coeficiente de variação.

APÊNDICE H – Correlação entre a densidade básica da madeira e as variáveis quantitativas do estudo, relativo à validação das redes e dos modelos na combinação REG-1 (Aracruz).

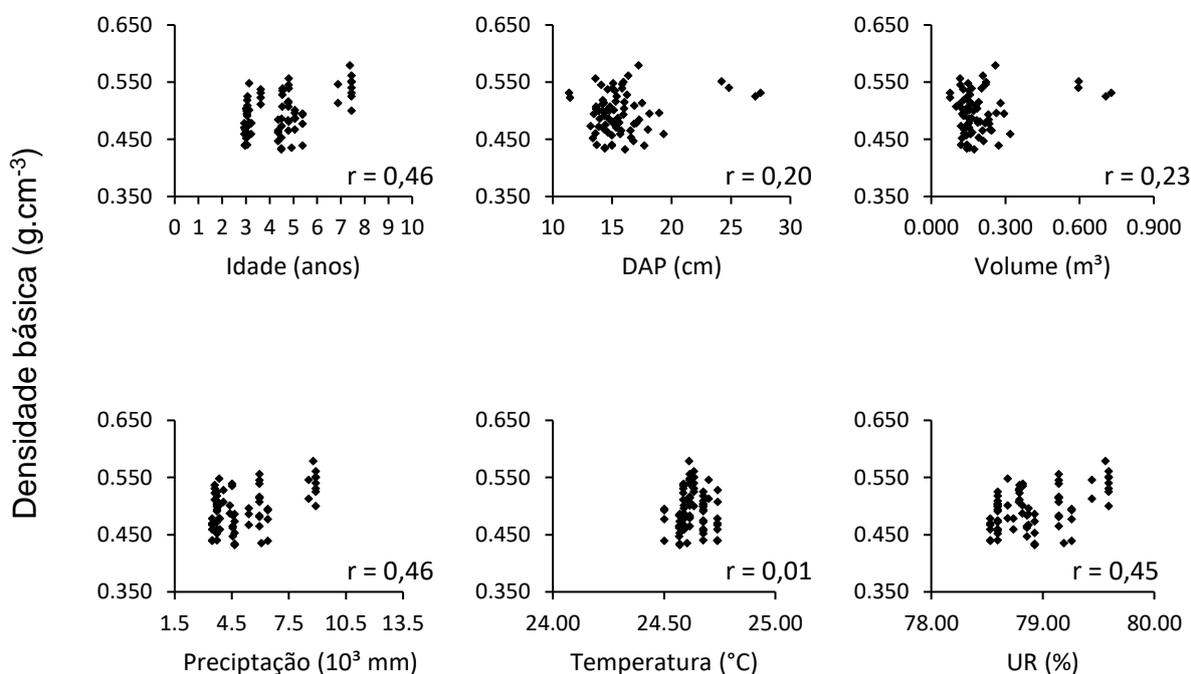


APÊNDICE I – Análise descritiva das variáveis quantitativas relativas ao treino das redes e ajuste dos modelos na combinação REG-2 (São Mateus).

Variáveis	Mínimo	Média	Máximo	CV(%)
Idade (anos)	2,93	4,45	7,44	-
DAP (cm)	11,36	15,82	27,47	18,15
Volume (m ³)	0,077	0,199	0,729	61,58
Precipitação acumulada (mm)	3466,10	5115,19	8921,20	34,32
Temperatura (°C)	24,50	24,63	24,74	0,25
Umidade relativa (%)	78,53	78,93	79,59	0,42
Densidade básica (g.cm ⁻³)	0,432	0,495	0,579	7,18

CV : Coeficiente de variação.

APÊNDICE J – Correlação entre a densidade básica da madeira e as variáveis quantitativas do estudo, relativo ao treino das redes e ajuste dos modelos na combinação REG-2 (São Mateus).

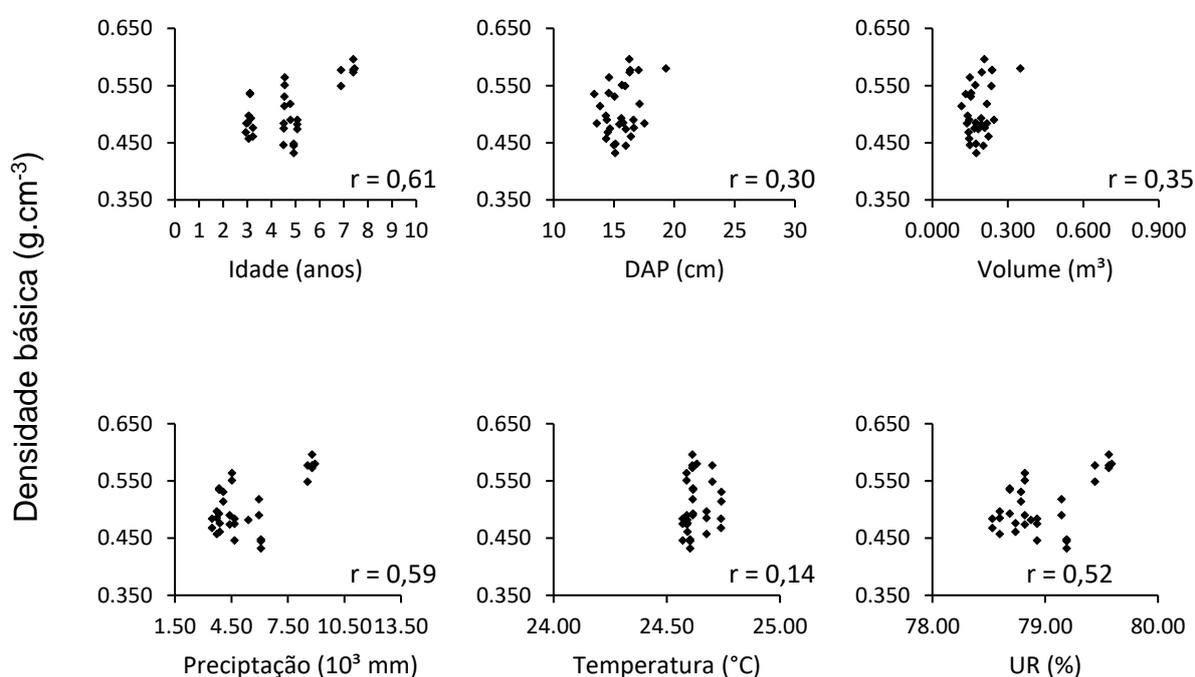


APÊNDICE K – Análise descritiva das variáveis quantitativas relativas à validação das redes e dos modelos na combinação REG-2 (São Mateus).

Variáveis	Mínimo	Média	Máximo	CV(%)
Idade (anos)	2,93	4,69	7,44	-
DAP (cm)	13,37	15,55	19,29	8,18
Volume (m ³)	0,116	0,186	0,349	25,14
Precipitação acumulada (mm)	3466,10	5325,65	8921,20	35,12
Temperatura (°C)	24,57	24,63	24,74	0,22
Umidade relativa (%)	78,53	78,97	79,59	0,43
Densidade básica (g.cm ⁻³)	0,432	0,506	0,596	9,25

CV : Coeficiente de variação.

APÊNDICE L – Correlação entre a densidade básica da madeira e as variáveis quantitativas do estudo, relativo à validação das redes e dos modelos na combinação REG-2 (São Mateus).

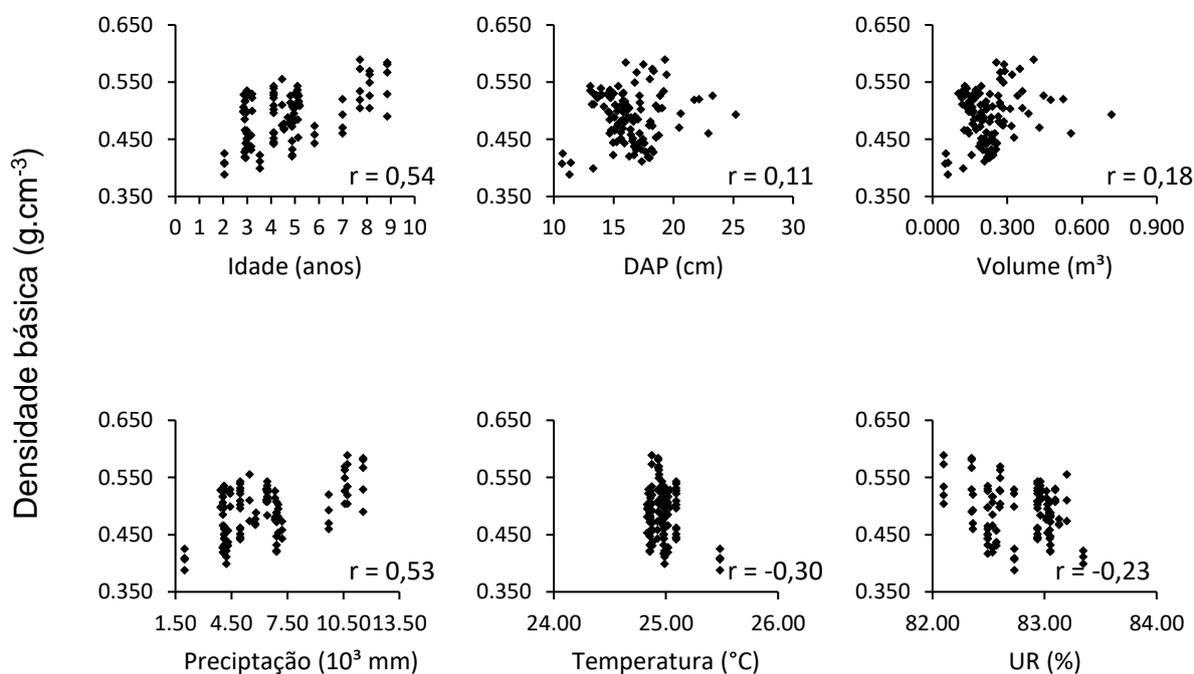


APÊNDICE M – Análise descritiva das variáveis quantitativas relativas ao treino das redes e ajuste dos modelos na combinação REG-3 (Bahia).

Variáveis	Mínimo	Média	Máximo	CV(%)
Idade (anos)	2,05	4,71	8,86	-
DAP (cm)	10,66	16,36	25,21	14,73
Volume (m ³)	0,050	0,226	0,718	45,26
Precipitação acumulada (mm)	1989,40	6210,78	11562,90	38,48
Temperatura (°C)	24,83	24,97	25,48	0,50
Umidade relativa (%)	82,10	82,78	83,34	0,37
Densidade básica (g.cm ⁻³)	0,388	0,489	0,589	9,15

CV : Coeficiente de variação.

APÊNDICE N – Correlação entre a densidade básica da madeira e as variáveis quantitativas do estudo, relativo ao treino das redes e ajuste dos modelos na combinação REG-3 (Bahia).

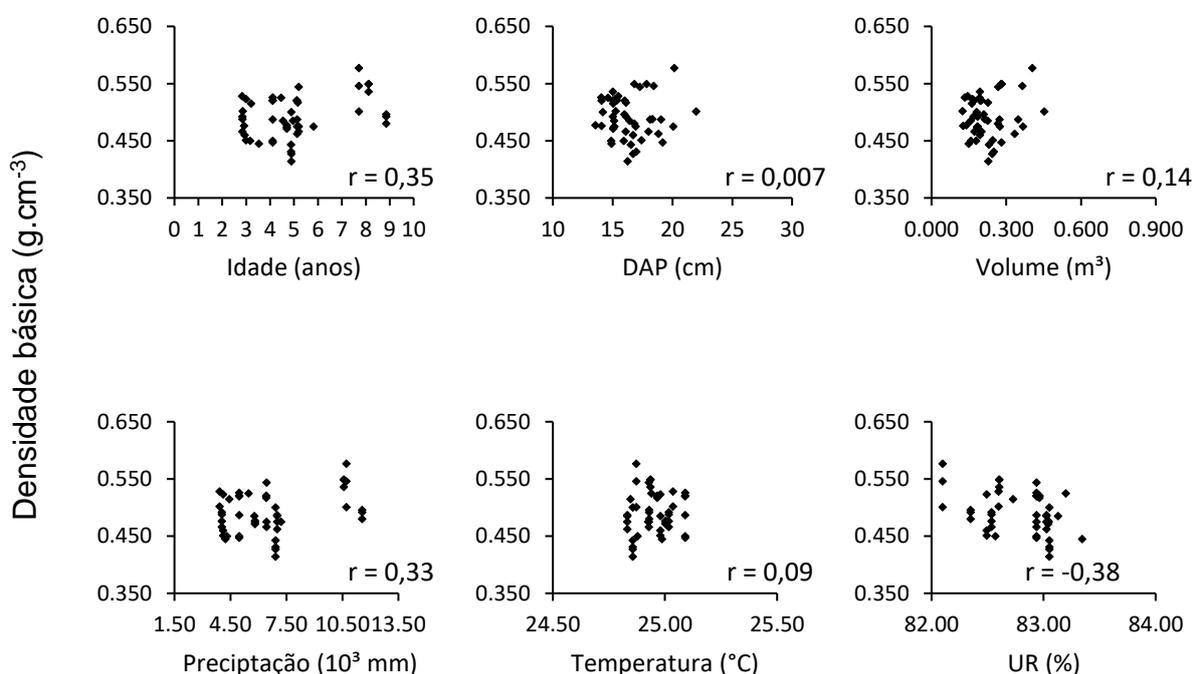


APÊNDICE O – Análise descritiva das variáveis quantitativas relativas à validação das redes e dos modelos na combinação REG-3 (Bahia).

Variáveis	Mínimo	Média	Máximo	CV(%)
Idade (anos)	2,83	4,98	8,86	-
DAP (cm)	13,56	16,39	21,96	11,06
Volume (m ³)	0,124	0,222	0,452	33,61
Precipitação acumulada (mm)	3918,70	6558,15	11562,90	36,89
Temperatura (°C)	24,83	24,95	25,09	0,32
Umidade relativa (%)	82,10	82,79	83,34	0,37
Densidade básica (g.cm ⁻³)	0,414	0,491	0,577	7,40

CV : Coeficiente de variação.

APÊNDICE P – Correlação entre a densidade básica da madeira e as variáveis quantitativas do estudo, relativo à validação das redes e dos modelos na combinação REG-3 (Bahia).

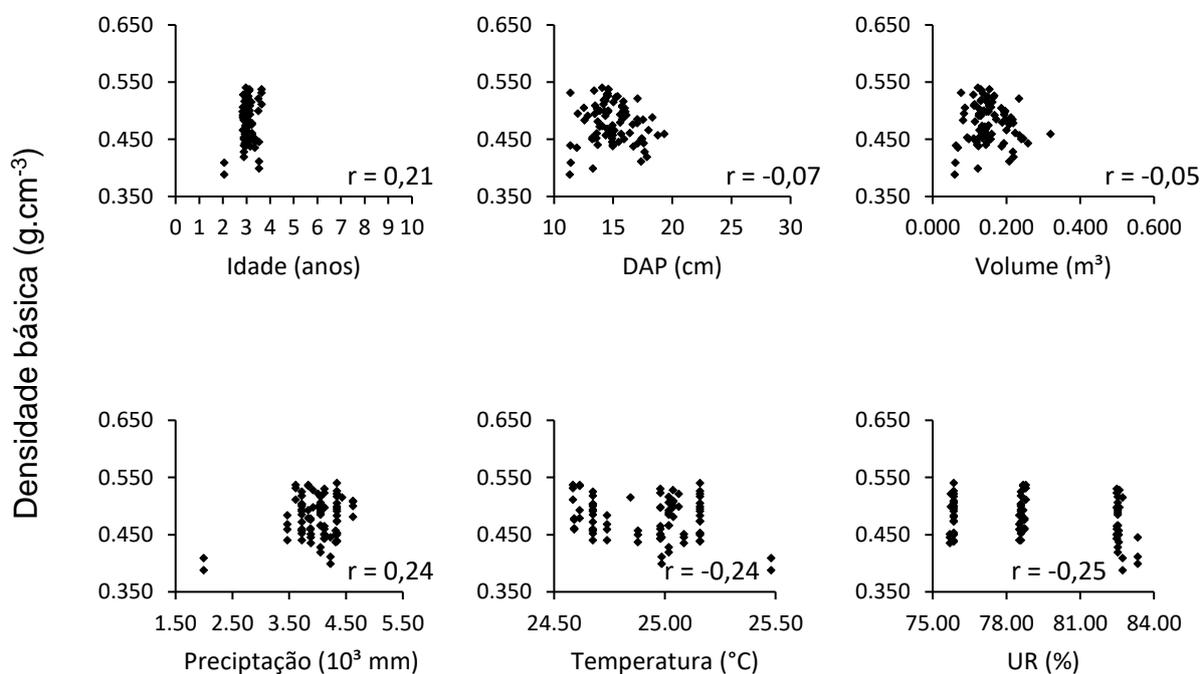


APÊNDICE Q – Análise descritiva das variáveis quantitativas relativas ao treino das redes e ajuste dos modelos na combinação CLAS-1 (2 a 4 anos).

Variáveis	Mínimo	Média	Máximo	CV(%)
Idade (anos)	2,05	3,05	3,63	-
DAP (cm)	11,30	14,96	19,32	11,81
Volume (m ³)	0,060	0,153	0,319	31,75
Precipitação acumulada (mm)	1989,40	3982,87	4619,10	10,72
Temperatura (°C)	24,59	24,92	25,48	0,88
Umidade relativa (%)	75,70	79,23	83,34	3,52
Densidade básica (g.cm ⁻³)	0,388	0,478	0,540	7,32

CV : Coeficiente de variação.

APÊNDICE R – Correlação entre a densidade básica da madeira e as variáveis quantitativas do estudo, relativo ao treino das redes e ajuste dos modelos na combinação CLAS-1 (2 a 4 anos).

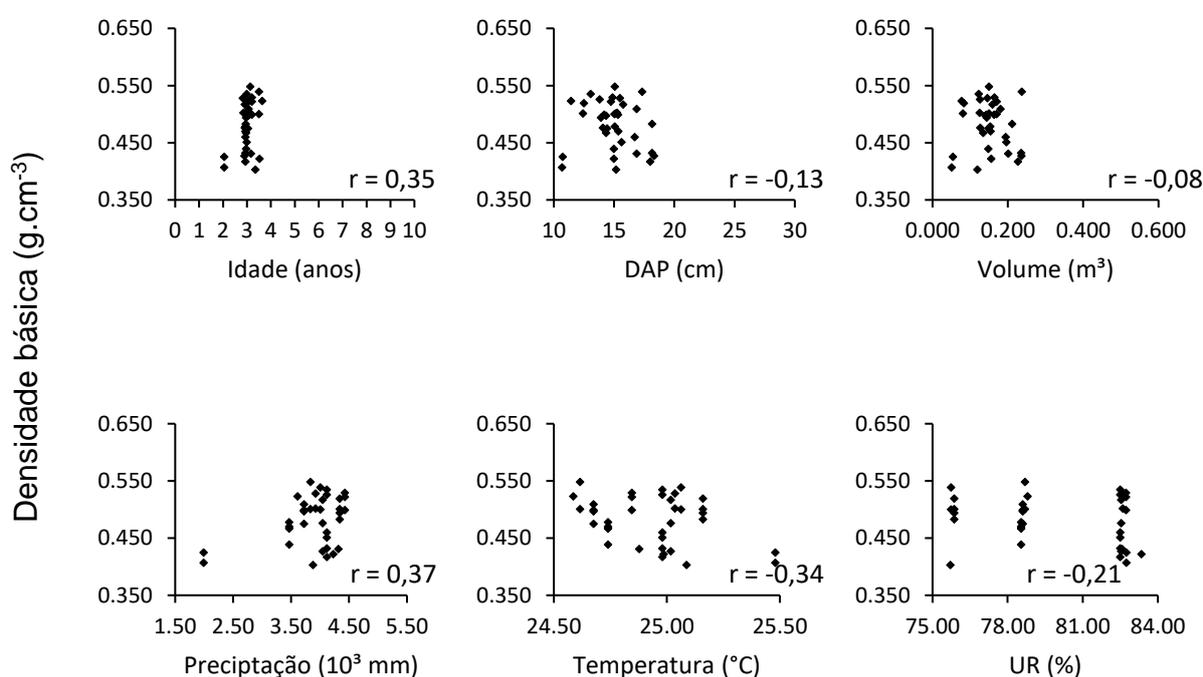


APÊNDICE S – Análise descritiva das variáveis quantitativas relativas à validação das redes e dos modelos na combinação CLAS-1 (2 a 4 anos).

Variáveis	Mínimo	Média	Máximo	CV(%)
Idade (anos)	2,05	3,02	3,63	-
DAP (cm)	10,66	14,94	18,30	12,82
Volume (m ³)	0,050	0,152	0,237	31,19
Precipitação acumulada (mm)	1989,40	3881,08	4428,10	14,12
Temperatura (°C)	24,59	24,94	25,48	0,88
Umidade relativa (%)	75,70	80,07	83,34	3,47
Densidade básica (g.cm ⁻³)	0,403	0,482	0,548	8,63

CV : Coeficiente de variação.

APÊNDICE T – Correlação entre a densidade básica da madeira e as variáveis quantitativas do estudo, relativo à validação das redes e dos modelos na combinação CLAS-1 (2 a 4 anos).

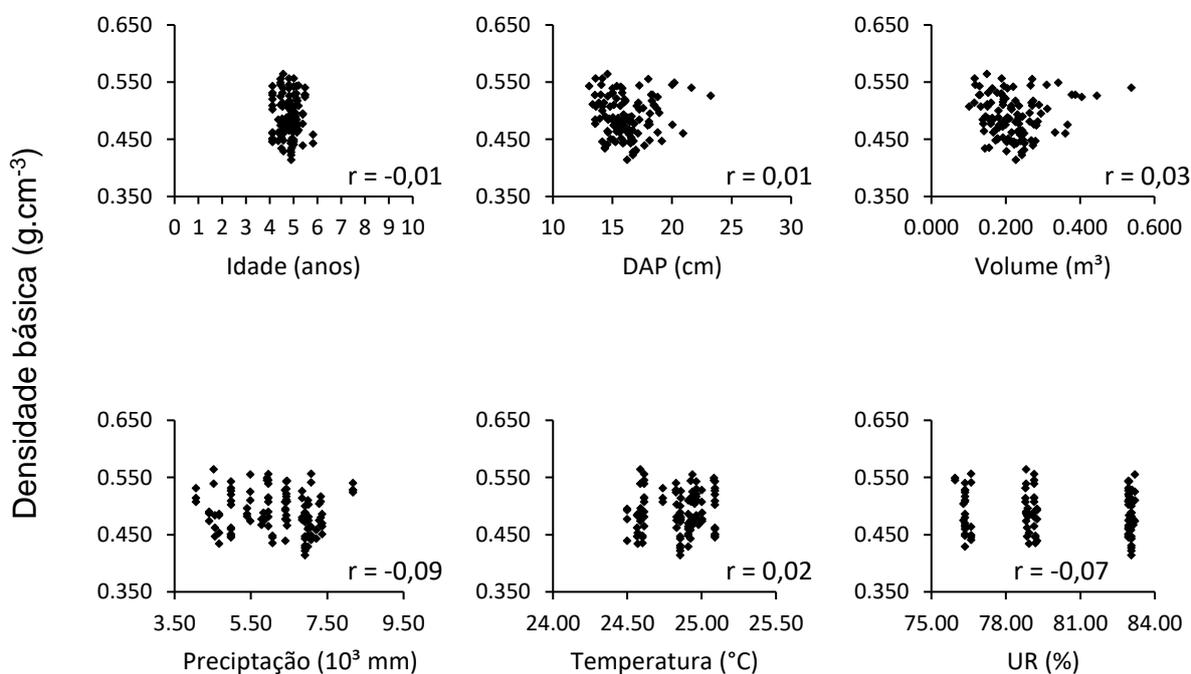


APÊNDICE U – Análise descritiva das variáveis quantitativas relativas ao treino das redes e ajuste dos modelos na combinação CLAS-2 (4 a 6 anos).

Variáveis	Mínimo	Média	Máximo	CV(%)
Idade (anos)	4,11	4,81	5,81	-
DAP (cm)	13,05	16,18	23,27	11,42
Volume (m ³)	0,102	0,220	0,538	32,12
Precipitação acumulada (mm)	4057,90	6164,11	8167,10	32,12
Temperatura (°C)	24,50	24,88	25,70	1,05
Umidade relativa (%)	75,95	80,33	83,20	3,43
Densidade básica (g.cm ⁻³)	0,414	0,489	0,564	7,24

CV : Coeficiente de variação.

APÊNDICE V – Correlação entre a densidade básica da madeira e as variáveis quantitativas do estudo, relativo ao treino das redes e ajuste dos modelos na combinação CLAS-2 (4 a 6 anos).

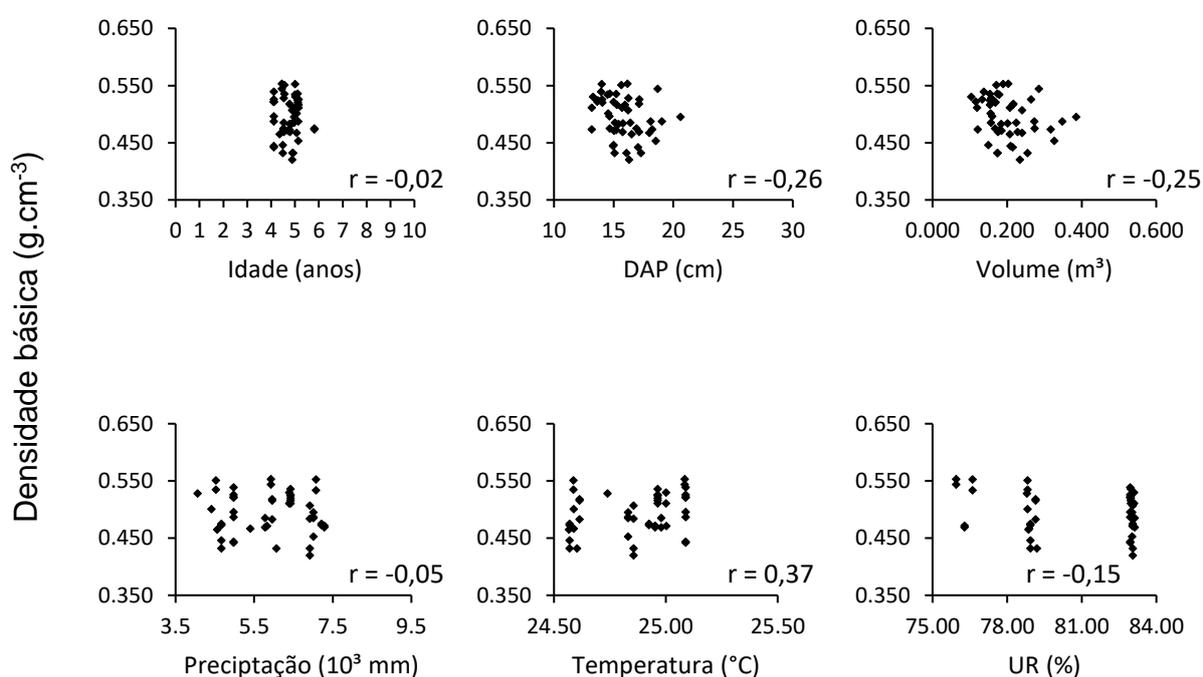


APÊNDICE W – Análise descritiva das variáveis quantitativas relativas à validação das redes e dos modelos na combinação CLAS-2 (4 a 6 anos).

Variáveis	Mínimo	Média	Máximo	CV(%)
Idade (anos)	4,11	4,75	5,81	-
DAP (cm)	13,18	15,79	20,59	10,47
Volume (m ³)	0,104	0,200	0,385	30,47
Precipitação acumulada (mm)	4057,90	5900,22	7281,10	16,54
Temperatura (°C)	24,57	24,90	25,70	1,01
Umidade relativa (%)	75,95	81,02	83,13	3,14
Densidade básica (g.cm ⁻³)	0,420	0,495	0,533	7,25

CV : Coeficiente de variação.

APÊNDICE X – Correlação entre a densidade básica da madeira e as variáveis quantitativas do estudo, relativo à validação das redes e dos modelos na combinação CLAS-2 (4 a 6 anos).

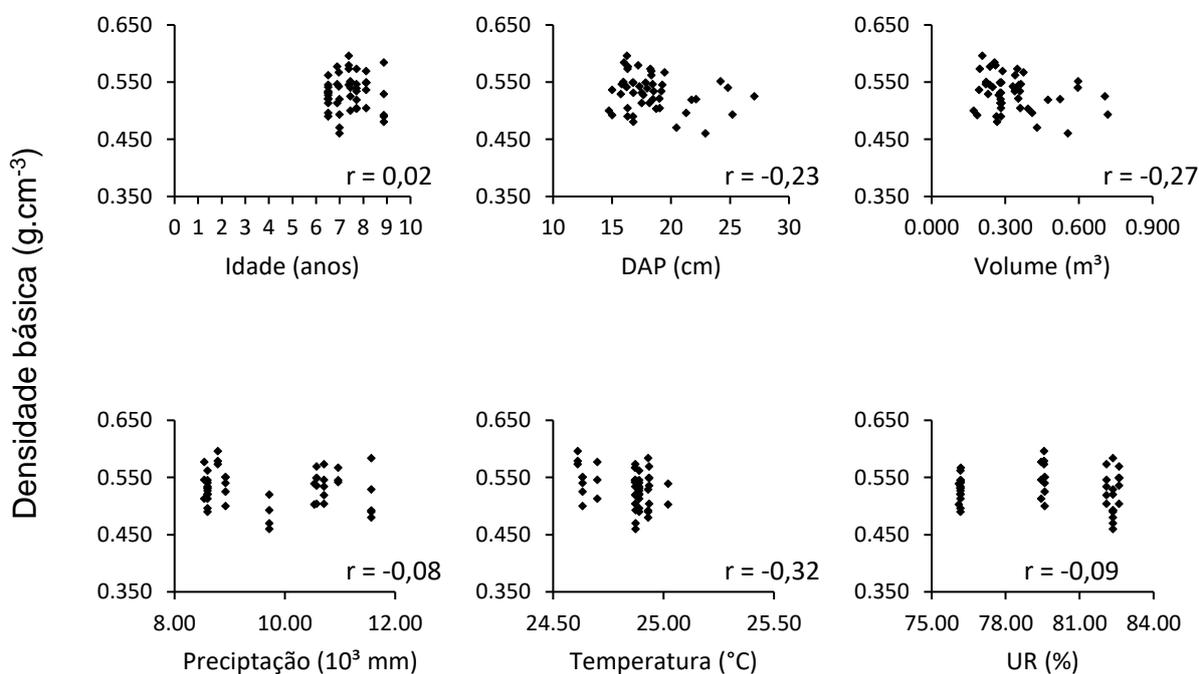


APÊNDICE Y – Análise descritiva das variáveis quantitativas relativas ao treino das redes e ajuste dos modelos na combinação CLAS-3 (6 a 8 anos).

Variáveis	Mínimo	Média	Máximo	CV(%)
Idade (anos)	6,51	7,38	8,86	-
DAP (cm)	14,74	18,34	27,06	15,28
Volume (m ³)	0,172	0,334	0,718	38,33
Precipitação acumulada (mm)	8536,80	9734,68	11562,90	11,35
Temperatura (°C)	24,61	24,84	25,02	0,47
Umidade relativa (%)	76,10	79,52	82,60	3,45
Densidade básica (g.cm ⁻³)	0,460	0,531	0,596	5,82

CV : Coeficiente de variação.

APÊNDICE Z – Correlação entre a densidade básica da madeira e as variáveis quantitativas do estudo, relativo ao treino das redes e ajuste dos modelos na combinação CLAS-3 (6 a 8 anos).

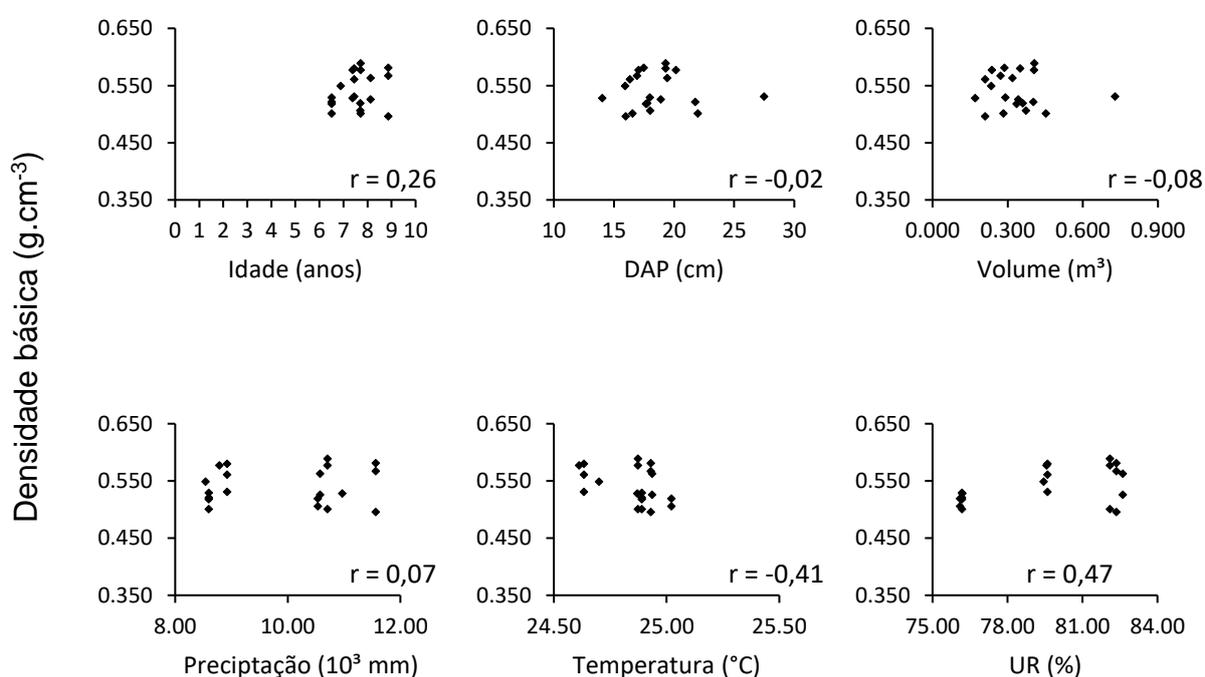


APÊNDICE AA – Análise descritiva das variáveis quantitativas relativas à validação das redes e dos modelos na combinação CLAS-3 (6 a 8 anos).

Variáveis	Mínimo	Média	Máximo	CV(%)
Idade (anos)	6,51	7,57	8,86	-
DAP (cm)	14,01	18,49	27,47	15,56
Volume (m ³)	0,169	0,333	0,729	36,18
Precipitação acumulada (mm)	8536,80	9921,72	11562,90	11,76
Temperatura (°C)	24,61	24,85	25,02	0,52
Umidade relativa (%)	76,10	79,47	82,60	3,44
Densidade básica (g.cm ⁻³)	0,496	0,541	0,589	5,71

CV : Coeficiente de variação.

APÊNDICE BB – Correlação entre a densidade básica da madeira e as variáveis quantitativas do estudo, relativo à validação das redes e dos modelos na combinação CLAS-3 (6 a 8 anos).



APÊNDICE CC – Estimativa dos parâmetros da variável clone ($\hat{\beta}_{c_i}$) e parâmetro da interação entre as variáveis clone e idade ($\hat{\beta}_{c_i,I}$) dos modelos de RLM para a combinação COMP (completos).

Clone	Estimativa dos parâmetros	
	$\hat{\beta}_{c_i}$	$\hat{\beta}_{c_i,I}$
2	0,07814	-0,00118
3	0,87664	-0,17994
4	0,04225	-0,00169
5	0,10887	-0,00422
6	0,13638	-0,02569
7	0,07329	0,00089
8	0,03413	0,00409
9	-0,00830	0,01074
10	0,49016	-0,00297
11	0,03798	-0,00283
12	0	0,01883
13	0	0,01217
14	0,00414	0,00266
15	-0,04617	0,02737
16	0	-0,01329
17	-0,04936	0,01292
18	-0,05837	0,00791

APÊNDICE DD – Estimativa dos parâmetros da variável clone ($\hat{\beta}_{c_i}$) dos modelos de RLM para a combinação REG-1 (Aracruz).

Clone	Estimativa dos parâmetros
	$\hat{\beta}_{c_i}$
2	0,09399
4	0,05027
6	0,03918
7	0,07744
8	0,05372
9	0,04839
10	0,02522
11	0,05709
16	-0,01410
18	0,02522

APÊNDICE EE – Estimativa dos parâmetros da variável clone ($\hat{\beta}_{c_i}$) e parâmetro da interação entre as variáveis clone e precipitação ($\hat{\beta}_{c_i,P}$) dos modelos de RLM para a combinação REG-2 (São Mateus).

Clone	Estimativa dos parâmetros	
	$\hat{\beta}_{c_i}$	$\hat{\beta}_{c_i,P}$
2	0	1,94x10 ⁻⁵
3	0	-9,51x10 ⁻⁶
4	0,14077	-2,85x10 ⁻⁵
5	0,13134	-1,55x10 ⁻⁵
7	0,08529	-4,49x10 ⁻⁶
8	0,11989	-1,94x10 ⁻⁵
9	-0,02100	5,72x10 ⁻⁶
10	0,11179	-2,08x10 ⁻⁵
12	0	1,08x10 ⁻⁷
13	0,04324	-7,93x10 ⁻⁶
14	-0,25610	7,67x10 ⁻⁵
16	0	-1,32x10 ⁻⁶
17	0	-6,80x10 ⁻⁶

APÊNDICE FF – Estimativa dos parâmetros da variável clone ($\hat{\beta}_{c_i}$), parâmetro da interação entre as variáveis clone e precipitação ($\hat{\beta}_{c_i,P}$) e parâmetro da interação entre as variáveis clone e umidade relativa ($\hat{\beta}_{c_i,UR}$) dos modelos de RLM para a combinação REG-3 (Bahia).

Clone	Estimativa dos parâmetros		
	$\hat{\beta}_{c_i}$	$\hat{\beta}_{c_i,P}$	$\hat{\beta}_{c_i,UR}$
2	-7,83400	1,09x10 ⁻⁵	0,09438
3	0	1,46x10 ⁻⁵	-0,00066
7	2,07320	-5,22x10 ⁻⁶	-0,02381
8	2,62260	-2,57x10 ⁻⁶	-0,03080
10	-11,07600	-8,61x10 ⁻⁶	0,01476
13	-1,13350	1,90x10 ⁻⁶	0
15	0	-1,63x10 ⁻⁵	0
16	0	-6,25 x10 ⁻⁴	3,37220
17	-275,6	2,41x10 ⁻⁶	-0,00049
18	0	4,42x10 ⁻⁵	0,12355

APÊNDICE GG – Estimativa dos parâmetros da variável clone ($\hat{\beta}_{c_i}$), parâmetro da interação entre as variáveis clone e idade ($\hat{\beta}_{c_i,I}$) e parâmetro da interação entre as variáveis clone e precipitação ($\hat{\beta}_{c_i,P}$) dos modelos de RLM para a combinação CLAS-1 (2 a 4 anos).

Clone	Estimativa dos parâmetros		
	$\hat{\beta}_{c_i}$	$\hat{\beta}_{c_i,I}$	$\hat{\beta}_{c_i,P}$
2	0	0	-5,39x10 ⁻⁵
4	0	0	1,43x10 ⁻⁵
6	0	0	7,08x10 ⁻⁶
7	-0,13098	0,15468	-6,18x10 ⁻⁵
8	0,25459	-0,03543	-2,51x10 ⁻⁵
9	-4,31310	1,46170	-3,97x10 ⁻⁵
10	1,04240	-0,24971	-6,52x10 ⁻⁵
11	0	0	-6,47x10 ⁻⁵
13	0	0	-5,77x10 ⁻⁶
14	0	0	1,47x10 ⁻⁵
15	0	0	-6,52x10 ⁻⁵
16	1,84270	-0,71223	6,57x10 ⁻⁵
17	0	0	-0,00017

APÊNDICE HH – Estimativa dos parâmetros da variável clone ($\hat{\beta}_{c_i}$) dos modelos de RLM para a combinação CLAS- 2 (4 a 6 anos).

Clone	Estimativa dos parâmetros
	$\hat{\beta}_{c_i}$
2	0,07244
3	0,02220
4	0,03897
5	0,08324
6	0,03739
7	0,08984
8	0,04624
9	0,04634
10	0,02531
13	0,03134
14	0,07417
16	0,03089
17	-0,01980
18	0,03870

APÊNDICE II – Estimativa dos parâmetros da variável clone ($\hat{\beta}_{c_i}$) dos modelos de RLM para a combinação CLAS-3 (6 a 8 anos).

Clone	Estimativa dos parâmetros
	$\hat{\beta}_{c_i}$
2	0,06683
4	0,04126
5	0,01917
7	0,04619
8	0,03512
9	0,03554
10	4,10070
12	0,00261