

GABRIELA CRISTINA COSTA SILVA

**USO DE REDES NEURAS ARTIFICIAIS NA PREDIÇÃO DE PARÂMETROS E
CALIBRAÇÃO DO MODELO 3-PG**

Tese apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Ciência Florestal, para obtenção do título de *Doctor Scientiae*.

Orientador: Helio Garcia Leite

Coorientador: Júlio César Lima Neves

**VIÇOSA – MINAS GERAIS
2021**

**Ficha catalográfica elaborada pela Biblioteca Central da Universidade
Federal de Viçosa - Campus Viçosa**

T

S586u
2021
Silva, Gabriela Cristina Costa, 1992-
Uso de redes neurais artificiais na predição de parâmetros e
calibração do modelo 3-PG / Gabriela Cristina Costa Silva. –
Viçosa, MG, 2021.

1 tese eletrônica (201 f.): il. (algumas color.).

Orientador: Helio Garcia Leite.

Tese (doutorado) - Universidade Federal de Viçosa,
Departamento de Engenharia Florestal, 2021.

Inclui bibliografia.

DOI: <https://doi.org/10.47328/ufvbbt.2022.007>

Modo de acesso: World Wide Web.

1. *Eucalyptus* - Crescimento - Modelos matemáticos.
2. Florestas - Manejo. 3. Inteligência artificial. I. Leite, Helio
Garcia, 1960-. II. Universidade Federal de Viçosa. Departamento
de Engenharia Florestal. Programa de Pós-Graduação em
Ciência Florestal. III. Título.

CDO adapt. CDD 22. ed. 634.91825

Bibliotecário(a) responsável: Alice Regina Pinto CRB6 2523

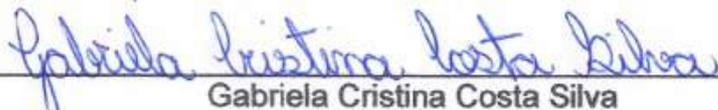
GABRIELA CRISTINA COSTA SILVA

**USO DE REDES NEURAIS ARTIFICIAIS NA PREDIÇÃO DE PARÂMETROS E
CALIBRAÇÃO DO MODELO 3-PG**

Tese apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Ciência Florestal, para obtenção do título de *Doctor Scientiae*.

APROVADA: 20 de outubro de 2021.

Assentimento:



Gabriela Cristina Costa Silva
Autora



Helio Garcia Leite
Orientador

A Deus

Aos meus pais, José e Marlene

Aos meus irmãos, Daniel e Camila

Aos meus orientadores, Helio e Júlio

Aos meus familiares e amigos

A todos que me ajudaram e incentivaram

A todos que encontrarem aqui alguma forma de aprendizado ou colaboração

DEDICO

AGRADECIMENTOS

A Deus, meu grande amparo, por me conceder paz, consolo e alegria, por iluminar o meu caminho para que eu chegasse a esse momento com saúde e tranquilidade.

Aos meus amados pais, José e Marlene, e irmãos, Daniel e Camila, pelo apoio incondicional às minhas escolhas, por acreditarem em mim e me incentivarem a seguir em frente, com muita fé em Deus e otimismo, pelo carinho, por serem exemplo de leveza, honestidade, força e alegria de viver.

A todos os meus familiares, por sempre torcerem por mim, por tanto carinho e apoio, em especial a minha prima Naty pela ajuda, conselhos e amizade.

Aos amigos maravilhosos que Deus colocou em meu caminho durante esse tempo que estive em Viçosa, Jadson, Fernanda, Lucas, Epifanía, Cátia, Júlia, Ivaldo, Agust, Sindy, Thales, Duber, Aline, Débora, Bruna, Gustavo e Gabriel, por todo apoio e ajuda, em todos os momentos, tornando essa caminhada mais leve e divertida. Vocês fizeram toda a diferença!

Aos amigos do DEF e da salinha do manejo, Fardin, que me acolheu tão bem, Pedro, Ricardo, Rafael, Gian, Merly, Aline, Vicente, Samuel, Monique, Ana, Thaynara, Magdaline, Aguida, Kemelly, Rodrigo e Rafael, pela ajuda nos momentos de estudo e troca de ideias. E a Verônica pela amizade e estudos compartilhados na salinha virtual.

Aos amigos da equipe de inventário florestal, com quem tanto aprendi e me diverti, Mariana, Diego, Anyelle, Jéssica, Hiago, Taciano, Demétrio, Vinícius e Othon.

Ao amigo, professor e orientador Helio, pelo acolhimento e confiança, por toda a ajuda, sempre com tanta boa vontade e paciência, obrigada pela oportunidade maravilhosa de ser sua orientada, te admiro muito e sempre levarei os seus ensinamentos comigo, você é um exemplo de profissional e de ser humano.

Ao professor e coorientador Júlio, pela grande ajuda e contribuição fundamental nesse trabalho, pela oportunidade, confiança, amizade e paciência.

Aos professores Carlos Pedro, Carlos Moreira, Sebastião Valverde e Levi Lelis, por toda ajuda e por compartilharem seus conhecimentos durante as disciplinas.

Aos professores José Marinaldo, Daniel Binoti e Natalino Calegario, pela colaboração no desenvolvimento desse trabalho.

Aos professores Carlos Araújo, Álvaro e Duber, pela disponibilidade e boa vontade em me ajudar no desenvolvimento do trabalho e esclarecimento de dúvidas. Ao Jarbas e Gualter pela ajuda com os dados e ao Liliano pela ajuda com o computador.

Aos professores e amigos da UFSJ, que tive o privilégio de conhecer, Renato Castro, Mayra, Gustavo, Franscine, Evânia, João, Carine, Rúbia, Aderbal, Glauciana, Elaine, Cidália, Patrícia, Renato Vieira, Ana Flávia e Marina, uma equipe exemplar de professores, que me acolheram tão bem e com quem tanto aprendi. A amiga Clarissa, com quem compartilhei essa experiência, pelo apoio e companheirismo. A Vanessa, Adriane e Márcia, sempre muito atenciosas e competentes, pela amizade e ajuda. Aos amigos Jianne, Lívia, Lucas e Joyce, pelo acolhimento e ajuda durante esta etapa. A todos os alunos que estiveram comigo durante as disciplinas, pelo carinho e paciência, estarei sempre torcendo por vocês!

Às moradoras da república R.B.O., Laura, Camila e Raíssa, pela acolhida, carinho e ajuda.

Às amigas da república 504, Flávia, Adaiane, Laura e Beatriz, pelo companheirismo, animação, conversas e lanches.

Às amigas da república M4, Fernanda, Taiane e Ximena, com quem iniciei essa caminhada desde o mestrado, pelo apoio e carinho.

Às psicólogas Ana Luísa e Danielle, por me ajudarem no crescimento pessoal e por todos os ensinamentos sobre a vida.

Ao Alexandre e Dilson, por todo o apoio, pela ajuda fundamental em todas as etapas, pela paciência e disponibilidade e a Caroline pela ajuda com as correções.

Ao Chiquinho, Bety e Neusa, pela ajuda, sorrisos e agradáveis conversas.

À Universidade Federal de Viçosa, ao Departamento de Engenharia Florestal e ao Programa de Pós-graduação em Ciência Florestal e a todos os funcionários e professores, por contribuírem com o meu aprendizado e formação profissional.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), pela concessão da bolsa de estudo.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

A todos que, direta ou indiretamente, contribuíram para a realização deste trabalho.

Muito Obrigada!! ♥

*“O correr da vida embrulha tudo,
a vida é assim:
esquenta e esfria,
aperta e daí afrouxa,
sossega e depois desinquieta.
O que ela quer da gente é coragem.”*
(João Guimarães Rosa)

RESUMO

SILVA, Gabriela Cristina Costa, D.Sc., Universidade Federal de Viçosa, outubro de 2021. **Uso de redes neurais artificiais na predição de parâmetros e calibração do modelo 3-PG**. Orientador: Helio Garcia Leite. Coorientador: Júlio César Lima Neves.

A produtividade de um plantio florestal tende a variar conforme o genótipo, idade, manejo, clima, fisiografia, algumas características do solo, práticas silviculturais e operações florestais durante a rotação. No contexto atual, mudanças climáticas, ganhos genéticos já não muito significativos e, além disso, a expansão para áreas, possivelmente, menos produtivas, contribuem para o fato da produtividade do eucalipto no Brasil não estar aumentado como em décadas passadas. Dessa forma, modelos orientados por variáveis climáticas, edáficas e fisiológicas, chamados modelos processuais, são cada vez mais importantes para auxiliar no planejamento e manejo florestal. O 3-PG (*Physiological Principles Predicting Growth*) é um exemplo dessa categoria de modelo, que além de calcular a quantidade de carbono fixada e alocada pelas árvores, também simula o crescimento em diâmetro à 1,30 m de altura (D), altura total e volume do povoamento. Ao analisá-lo, percebeu-se que alguns aspectos do 3-PG poderiam ser aprimorados com o uso de redes neurais artificiais (RNA), integradas ao modelo, e no processo de parametrização do mesmo. Diante do exposto, os objetivos deste trabalho foram: estimar a produtividade do eucalipto utilizando o modelo 3-PG, já calibrado para algumas regiões do Brasil; Configurar e treinar RNA para substituir os modelos de regressão do modelo 3-PG, propondo uma abordagem mista; Configurar e treinar RNA para prever alguns dos parâmetros do 3-PG, que geram maior sensibilidade ao modelo. Foram selecionadas na literatura 16 parametrizações para eucalipto, com as quais foi produzido um banco de dados, usado no treinamento das RNA. Foi avaliado o comportamento do modelo 3-PG, nas diferentes regiões climáticas. O tipo de RNA utilizada foi a *multilayer perceptron* com uma camada intermediária e o algoritmo de aprendizagem *resilient backpropagation*. Foram testadas diferentes combinações entre variáveis climáticas e relacionadas com a saída desejada. O mesmo foi feito para a predição dos parâmetros analisados, porém, considerando duas abordagens de treinamento das redes. O modelo 3-PG, associado às RNA, foi aplicado em todo o Brasil. As estimativas do modelo 3-PG apresentaram resultados consistentes com

cada sítio. As predições das RNA foram precisas, a partir de variáveis de fácil acesso. As redes de melhor desempenho foram para prever o D , altura total, volume do povoamento, biomassa foliar e os parâmetros a_p e n_p . Para a predição dos demais parâmetros, as redes apresentaram resultados precisos nas duas abordagens de treinamento, principalmente para os parâmetros da função para estimar o D (a_s e n_s) e a fração máxima de biomassa alocada para raízes (η_{Rx}). As principais conclusões foram: parâmetros e saídas do modelo 3-PG podem ser estimadas com eficiência empregando RNA; Maior flexibilidade e generalismo podem ser conferidos ao 3-PG por meio da inclusão de variáveis climáticas e processuais, integradas por uma RNA; O ajuste de um modelo sigmoide às estimativas de volume do 3-PG possibilita avaliar biologicamente as etapas do crescimento, em diferentes cenários; Nos casos onde houve baixa precisão, foi devido a falta de informações explicativas, principalmente relacionadas a fertilidade do solo. Os modelos de RNA e o modelo proposto (3-PG + RNA) foram disponibilizados.

Palavras-chave: *Eucalyptus*. Modelagem processual. Inteligência artificial. Aprendizado de máquina. Parametrização. Manejo florestal.

ABSTRACT

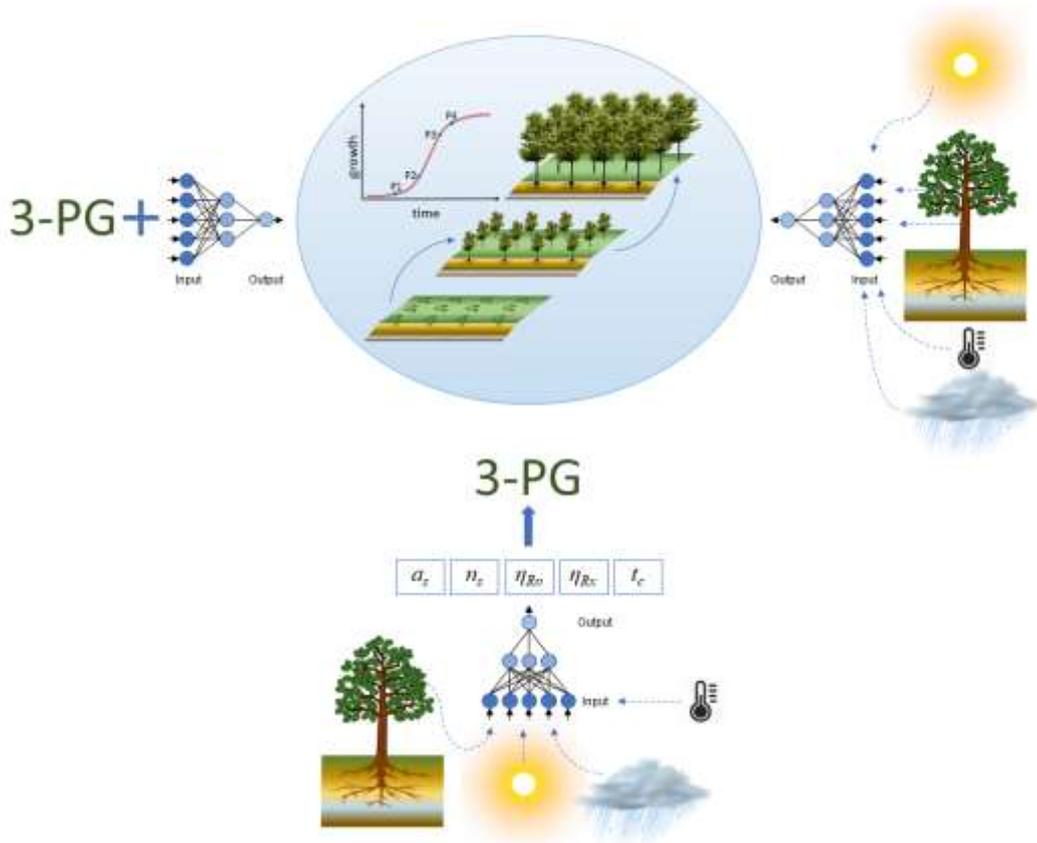
SILVA, Gabriela Cristina Costa, D.Sc., Universidade Federal de Viçosa, October, 2021. **Prediction of parameters and calibration of the 3-PG model using artificial neural networks.** Adviser: Helio Garcia Leite. Co-Adviser: Júlio César Lima Neves.

A forest stand productivity tends to vary according to genotype, age, management, climate, physiography, some soil characteristics, silvicultural practices and forestry operations during the rotation. In the current context, climate change, genetic gains that are no longer very significant and, in addition, expansion into possibly less productive areas, contribute to the fact that eucalyptus productivity in Brazil has not increased as in past decades. Thus, models guided by climatic, edaphic and physiological variables, called process-based models, are increasingly important to assist in forest planning and management. The 3-PG (Physiological Principles Predicting Growth) is an example of this type of model, which in addition to calculating the amount of carbon fixed and allocated by the trees, also simulates the growth in diameter at 1.30 m height (D), total height and stand volume. When analyzing it, it was noticed that some aspects of 3-PG could be improved with the use of artificial neural networks (ANN), integrated to the model, and in the process of its parameterization. Given the above, the objectives of this work were: to estimate the productivity of eucalyptus using the 3-PG model, already calibrated for some regions of Brazil; Configure and train RNA to replace the 3-PG regression models, proposing a mixed approach; Configure and train RNA to predict some of the 3-PG parameters, which generate greater sensitivity to the model. Sixteen parameterizations for eucalyptus were selected in the literature, with which a database was produced and used in the ANN training. The 3-PG behavior was evaluated in different climatic regions. Multilayer perceptron with one intermediate layer and the resilient backpropagation learning algorithm was used. Different combinations between climatic variables and those related to the desired output were tested. The same was done for the parameters prediction, however, considering two approaches to training the networks. The 3-PG model, associated with ANN, was applied throughout Brazil. The 3-PG model estimates showed results consistent with each site. ANN predictions were accurate, based on easily accessible variables. The

best performing networks were to predict D , total height, stand volume, leaf biomass and a_p and n_p parameters. For the other parameters prediction, the nets presented precise results in both training approaches, mainly for the parameters of the function to estimate D (a_s and n_s) and the maximum fraction of biomass allocated to roots (η_{Rx}). The main conclusions were: 3-PG parameters and outputs can be efficiently estimated using ANN; Greater flexibility and generalism can be given to 3-PG through the inclusion of climatic and physiological variables, integrated by an ANN; Fitting a sigmoid model to 3-PG volume estimates makes it possible to biologically assess the stages of growth in different scenarios; In cases where there was low precision, it was due to the lack of explanatory information, mainly related to soil fertility. The RNA models and the proposed model (3-PG + RNA) are available.

Keywords: *Eucalyptus*. Process-based modeling. Artificial intelligence. Machine learning. Parameterization. Forest management.

RESUMO GRÁFICO



SUMÁRIO

1	INTRODUÇÃO GERAL	15
2	OBJETIVOS	19
	CAPÍTULO I - REVISÃO DE LITERATURA	20
1	MODELO 3-PG: ESTADO DA ARTEB	20
2	APRENDIZADO DE MÁQUINA	44
3	DESCRIÇÃO DO MODELO 3-PG	49
4	CONCLUSÕES	67
	REFERÊNCIAS	68
	CAPÍTULO II - USO DE REDES NEURAS ARTIFICIAIS NO MODELO 3-PG	85
1	INTRODUÇÃO	87
2	MATERIAL E MÉTODOS	91
2.1	Obtenção dos dados	91
2.2	Processamentos com o modelo 3-PG	93
2.3	Configuração e treinamento das Redes Neurais Artificiais	95
3	RESULTADOS	102
3.1	Processamentos com o modelo 3-PG	102
3.2	Configuração e treinamento das redes neurais artificiais	117
4	DISCUSSÃO	134
4.1	Processamento com o modelo 3-PG	134
4.2	Eficiência das redes neurais artificiais	140
5	CONCLUSÕES	149
	REFERÊNCIAS	150
	CAPÍTULO III - AS REDES NEURAS ARTIFICIAIS PODEM AUXILIAR NO PROCESSO DE PARAMETRIZAÇÃO DO MODELO 3-PG	159
1	INTRODUÇÃO	163
2	MATERIAL E MÉTODOS	166
2.1	Obtenção dos dados	166
2.2	Configuração e treinamento das Redes Neurais Artificiais	168

3	RESULTADOS	175
3.1	Treinamento com o banco de dados completo	175
3.2	Treinamento sem repetição (16 observações)	180
4	DISCUSSÃO	184
4.1	Eficiência das redes neurais artificiais com o banco de dados completo	184
4.2	Eficiência das redes neurais artificiais com o banco de dados sem repetição	189
5	SUGESTÕES PARA APLICAÇÃO OU TESTE DAS REDES NEURAIAS ARTIFICIAIS	193
6	CONCLUSÕES	195
	REFERÊNCIAS	196
	CONSIDERAÇÕES FINAIS	201

1 INTRODUÇÃO GERAL

Os plantios florestais no Brasil ocupavam, em 2020, uma área de 9.983.095 hectares. Desse total, 76% correspondiam a plantios com o gênero *Eucalyptus* (INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA - IBGE, 2020). Esses plantios fornecem matéria-prima para diversas finalidades, sendo possível utilizar uma árvore de eucalipto de forma quase integral (ACOSTA; MASTRANDREA; LIMA, 2008; CARSON; HAMMER, 2010; MYBURG *et al.*, 2014). Seus principais usos envolvem o suprimento de matéria-prima para a produção de carvão vegetal e celulose, além da lenha, madeira em tora para outras finalidades e a folha (IBGE, 2019).

Uma vez definido o objetivo do manejo, é necessário definir as atividades a serem implementadas em diferentes etapas ao longo do crescimento da floresta, em cada unidade de manejo. As principais decisões estão relacionadas a escolha do genótipo, espaçamento, plano de fertilização, regime, rotação e ciclo de corte, intensidade e ciclo de desbaste e volume e área de corte anual para atender a demanda (CAMPOS; LEITE, 2017). Para isso, é necessário conhecer a capacidade produtiva das áreas, e assim, realizar a prognose de forma condizente com as características do local.

Na etapa em que é realizada a projeção do crescimento e da produção florestal, para subsidiar o planejamento, na maioria das vezes, são utilizados modelos estatísticos que se baseiam em dados obtidos a campo e usam variáveis a nível do povoamento ou árvores individuais (CLUTTER *et al.*, 1983). As estratégias de aplicação e uso desses modelos variam conforme o objetivo do manejo ou do proprietário, e pode ser feito a partir da estratificação da floresta ou com o uso de modelos mais detalhados.

Quando a causa é variável preditora e o crescimento da floresta é o resultado da interação entre processos ecofisiológicos, o tipo de modelo utilizado é o modelo processual. Essa categoria de modelo contém diversas variáveis e parâmetros relacionados ao solo, planta e atmosfera, para determinar o carbono fixado pela floresta (THORNTON *et al.*, 2002). Uma vantagem relativa de usar esse tipo de modelagem é a possibilidade de se fazer simulações de diferentes cenários climáticos ou de fertilização, para entender efeitos de seca ou do aumento nas concentrações de CO₂ na atmosfera e identificar os elementos que restringem o

crescimento, além da possibilidade de uso em áreas onde não existem plantios (ALMEIDA *et al.*, 2004; BAESSO; RIBEIRO; SILVA, 2010; HENDERSON; PARAJULI; ABT, 2020; LU *et al.*, 2015; SUBEDI; FOX, 2016). Técnicas como modelos de efeito misto e aprendizado de máquina também podem promover esse tipo de análise, mas o modelo processual apresenta o diferencial da causalidade e da associação a uma base fisiológica bem representada.

Quando os modelos processuais são capazes de definir o crescimento das dimensões das árvores, eles se tornam aplicáveis também para fins de manejo florestal e não apenas para pesquisa (BATTAGLIA; O'GRADY; MENDHAM, 2007). O modelo 3-PG - *Physiological Principles Predicting Growth* (LANDSBERG; WARING, 1997) possui caráter processual, mas foi desenvolvido pensando em uma abordagem mais simples, como alternativa para unir a modelagem convencional com a modelagem processual (LANDSBERG; WARING; COOPS, 2003). Com menor quantidade de parâmetros em relação à maioria dos modelos processuais já desenvolvidos, como: FORCYTE (KIMMINS; SCOLLAR; FELLER, 1981), FOREST-BGC (RUNNING; COUGHLAN, 1988), MAESTRO (WANG; JARVIS, 1990), BIOMASS (MCMURTRIE; ROOK; KELLIHER, 1990), o 3-PG utiliza modificadores do crescimento, o que o torna menos complexo.

De modo geral, este modelo quantifica a radiação fotossinteticamente ativa absorvida utilizada pela árvore para fixar carbono. Em seguida, é descontada a fração de carbono utilizada na respiração para definir a produção primária líquida. A biomassa líquida é então distribuída entre os compartimentos da árvore, possibilitando o cálculo do volume e da produtividade da floresta (LANDSBERG; WARING, 1997; SANDS; LANDSBERG, 2002).

A aplicação de um modelo processual para o manejo se torna mais interessante à medida em que as incertezas sobre o clima vão aumentando. A possibilidade de entender como e quais os aspectos climáticos, edáficos ou fisiológicos afetam a produtividade e como o crescimento florestal responde às práticas de manejo em uma área, é também um atrativo importante para o emprego do modelo 3-PG.

Mudanças climáticas, em médio e longo prazo, podem afetar a produtividade de forma direta, ao modificar, por exemplo, a disponibilidade dos recursos hídricos, e de forma indireta pela mudança nas condições do ambiente, que podem se tornar favoráveis ao ataque de pragas e doenças (KEITH *et al.*, 2012) ou ocorrência de

incêndios e eventos climáticos extremos (POTTER *et al.*, 2003). Embora o modelo 3-PG não considere alguns destes efeitos, existe potencial para representar alterações fisiológicas causadas por doenças (PINKARD; MOHAMMED, 2005) e eventos climáticos.

Além disso, a crescente demanda por madeira, faz com que exista uma tendência de expansão de áreas plantadas para outras regiões do Brasil (CUNHA *et al.*, 2021), surgindo o desafio de manejar essas novas áreas da melhor forma, buscando atingir produtividades elevadas e sustentáveis, de acordo com as condições do local.

Diante do exposto, apesar do amplo uso do modelo 3-PG para diferentes finalidades, alguns aspectos do modelo podem ser melhorados. O primeiro se refere aos modelos utilizados para cálculo da altura total e do volume do povoamento, constituídos por relações potenciais simples, baseadas apenas nas variáveis D (diâmetro à 1,30 m de altura) e número de fustes por unidade de área, mas que geralmente é ignorado no modelo. O segundo aspecto é o processo de determinação dos parâmetros, que em alguns casos é feito de forma relativamente empírica, por meio da calibração (LANDSBERG; WARING; COOPS, 2003). Um processo que deve ser realizado de forma cautelosa, pois pode comprometer o realismo biológico do modelo (SANDS, 2004).

Uma forma de solucionar estas questões pode ser o emprego das redes neurais artificiais (RNA) para prever as variáveis D , altura total e volume do povoamento e prever os parâmetros que geram maior sensibilidade ao modelo e que são de maior variação entre as diferentes parametrizações disponíveis na literatura.

As redes neurais artificiais são constituídas por unidades de processamento simples, chamados neurônios artificiais. Esses neurônios são paralelamente distribuídos e conectados por pesos, definidos a partir de um algoritmo de aprendizado, capaz de mapear a relação funcional entre variáveis e representar relações não lineares (HAYKIN, 2009; SILVA; SPATTI; FLAUZINO, 2016). A possibilidade de inclusão de diferentes tipos de variáveis, como variáveis categóricas, necessidade de menor esforço amostral e a possibilidade de englobar maior número de variáveis de entrada de forma mais simples e flexível, sem a necessidade de atender a pressupostos estatísticos, tornam as redes neurais artificiais mais vantajosas em relação aos modelos alométricos, para o cálculo das

variáveis de interesse para o manejo florestal. O sucesso que tem sido obtido a partir do uso das redes neurais artificiais (BINOTI *et al.*, 2017; COSTA FILHO *et al.*, 2019; DIAMANTOPOULOU, 2005; LEITE *et al.*, 2011; MUSHAR *et al.*, 2020; ÖZÇELİK *et al.*, 2010; SCRINZI; MARZULLO; GALVAGNI, 2007; SILVA *et al.*, 2009) e outros métodos de inteligência artificial (BINOTI *et al.*, 2012; CHEN *et al.*, 2019; CORTE *et al.*, 2020; DUBE *et al.*, 2014; GLEASON; IM, 2012; SILVA, A. *et al.*, 2021; SILVA, J. *et al.*, 2021; TAVARES JÚNIOR *et al.*, 2020) na engenharia florestal, é base para reforçar a potencialidade do seu uso em um modelo de processos ou até mesmo de forma individual.

2 OBJETIVOS

Avaliar os possíveis ganhos em eficiência e flexibilização do modelo 3-PG com o uso das redes neurais artificiais.

Os objetivos específicos dessa pesquisa foram:

- a) Estimar a produtividade do eucalipto utilizando o modelo 3-PG já calibrado para algumas regiões do Brasil;
- b) Configurar e treinar redes neurais artificiais para substituir os modelos de regressão do modelo 3-PG e propor uma abordagem mista para a modelagem do crescimento, 3PG + RNA;
- c) Configurar e treinar redes neurais artificiais para predizer alguns dos parâmetros do 3-PG, de maior variabilidade e que geram maior sensibilidade ao modelo.

CAPÍTULO I - REVISÃO DE LITERATURA

1 MODELO 3-PG: ESTADO DA ARTE

Os efeitos dos fatores bióticos e abióticos no crescimento de povoamentos equiâneos são interpretados, em análises típicas de manejo florestal, por meio de parâmetros estruturais medidos na floresta, com os quais são geradas informações sobre a produção e a produtividade do povoamento, principalmente em volume (CAMPOS; LEITE, 2017; WEST, 2009). Essas informações auxiliam as tomadas de decisão sobre quando, como, quanto e onde extrair o recurso florestal, a partir de diferentes métodos, tradicionais e inovadores, usados nas pesquisas e no manejo realizado pelas empresas florestais, conforme o objetivo final (BETTINGER *et al.*, 2009; CAMPOS; LEITE, 2017).

O manejo florestal é uma das grandes áreas da engenharia florestal, junto a silvicultura, a ambiência e a tecnologia da madeira e de produtos florestais. Conforme Campos e Leite (2017), o manejo florestal é um misto de manejo propriamente dito e silvicultura.

Porém, diante das mudanças atuais e perspectivas para o futuro, principalmente sobre o clima, é indispensável que os engenheiros florestais entendam a fisiologia e como ela afeta o crescimento da floresta, pois quanto melhor é a compreensão de como um sistema funciona, melhores serão as previsões sobre o seu comportamento diante de certos eventos, como intempéries ou ações ligadas ao manejo (LANDSBERG; SANDS, 2011).

A forma como ocorre o crescimento e a nutrição das plantas é um assunto que já vem sendo estudado há muitos anos. Pesquisas como Blackman e Matthaei (1905), Hatch e Slack (1970), Ingen-Housz (1796), Niel (1932) e Wilson e Calvin (1955), fizeram parte de um período de significativa evolução no entendimento sobre como e quais elementos as plantas utilizam para sobreviver, conduzindo a resultados que permitiram a descrição dos mecanismos químicos e físicos da fotossíntese.

Inicialmente, as pesquisas voltadas à compreensão do processo de produção de biomassa pelas plantas, a partir da assimilação de carbono, se baseavam em espécies agrícolas e a maior parte sob condições controladas (DUNCAN *et al.*, 1967). Em 1947 D. J. Watson publicou um trabalho com dados coletados a campo

para diferentes cultivares agrícolas (beterraba, trigo, cevada e batata). Ao observar o comportamento da taxa de assimilação líquida (TAL) e da área foliar total dessas espécies, sazonalmente e entre anos, o autor observou que a área foliar foi mais sensível às mudanças dos fatores que afetam a produtividade do que a TAL. Verificou ainda, que ao atingirem valores máximos de área foliar, havia um aumento considerável da área média das folhas, mais que o aumento do número de folhas por planta. Dessa forma, Watson (1947) sugeriu que se utilizasse a relação entre área de folhas por área de solo ($m^2 m^{-2}$), denominado índice de área foliar (A_f), para avaliar o efeito, de forma mais eficiente, de fatores como clima, variações sazonais, espécies, variedades e outros sobre a produtividade de uma cultura. Este foi um avanço significativo, onde o conhecimento sobre a produtividade e a eficiência fotossintética foi ampliado, muitos autores passaram a utilizar o A_f em suas pesquisas (LOOMIS; WILLIAMS, 1963).

Novas questões foram surgindo a cada ano. Uma foi sobre a complexidade da superfície vegetada, em relação às características das folhas no dossel, como o sombreamento, inclinação, tamanho, curvatura, resposta ao vento, à luz e outros, além das diferenças internas no tecido foliar (LOOMIS; WILLIAMS, 1963). Estes autores observaram que a disposição das folhas, em cultivos agrícolas, estava entre os principais limitantes da produtividade sazonal total, junto a área foliar e ao suprimento de CO_2 .

Nessa mesma abordagem, Duncan *et al.* (1967) desenvolveram um modelo matemático para simular a fotossíntese das folhas, considerando a disposição destas, nas diferentes camadas do dossel, e a curva de resposta à luz de cada camada (taxa fotossintética individual da folha vs intensidade de luz). Outro modelo foi também proposto por Wit (1959).

A ideia de desenvolver modelos processuais começou, de fato, na década de 70 a partir de uma pesquisa publicada pelo físico John Monteith (LANDSBERG, 2003). Em seu trabalho, Monteith (1977) observou como as características climáticas, principalmente chuva e temperatura interferiam na produtividade de cultivos agrícolas na Grã-Bretanha. A produtividade das culturas foi interpretada pelo ponto de vista da termodinâmica, que representa o balanço energético do sistema. Trata-se da diferença entre a energia luminosa que entra no sistema e a energia produzida (carboidrato). Comparando diferentes culturas, o autor demonstrou que

existe uma relação linear entre a produtividade e a radiação solar absorvida pelas folhas, a qual pode ser usada como base na análise da eficiência produtiva.

Os princípios discutidos por Monteith (1977) são base para muitos modelos processuais, que também utilizam o cálculo da radiação incidente absorvida pelas folhas, o A_f e a eficiência do uso da luz. Alguns exemplos dos primeiros modelos processuais são descritos, de forma simplificada, na Tabela 1.

Tabela 1 - Alguns modelos processuais desenvolvidos e suas principais funções (as descrições apresentadas foram obtidas nas referências citadas para o modelo).

(Continua)

Modelo	Descrição
PT - Model (AGREN; AXELSSON, 1980)	Foi desenvolvido visando compreender o crescimento das floretas de coníferas. O modelo simula o fluxo de carbono entre 8 órgãos (quatro classes de idade das acículas, galhos, fuste, raízes finas e raízes grossas) totalizando 11 variáveis de estado com o fluxo de nitrogênio, balanço hídrico e carboidrato. Considera os processos de fotossíntese, crescimento, respiração (de manutenção e de crescimento) e perdas estruturais. Utiliza o passo de dia com médias diárias das variáveis climáticas (temperatura do ar - no período luminoso e escuro do dia, temperatura do solo, potencial hídrico do solo, status de nutrição do solo, radiação, umidade relativa, comprimento do dia e temperatura do ar diária), quando as informações não estão disponíveis, estas podem ser aproximadas por meio de funções analíticas. Considera a competição, a condutância estomática do dia, as diferenças na eficiência fotossintética por classe de idade, porém não considera os efeitos do sombreamento na copa.
FORCYTE - FORest nutrient CYcling Trend Evaluator (KIMMINS; SCOLLAR; FELLER, 1981)	Representa o ciclo de nutrientes e a produção de biomassa pelas árvores, orientado por uma função sigmoide (volume vs idade), ajustada por sítio. Essa função se modifica conforme a disponibilidade de nutrientes e representa, de forma implícita, os efeitos da disponibilidade hídrica e do clima. O modelo considera a produção de matéria orgânica através da perda de folhas, raízes e galhos ao longo do tempo, e também gera a mortalidade. O crescimento em biomassa depende de mudanças nos processos de decomposição, que tendem a variar aumentando ou reduzindo a disponibilidade de nutrientes, outras formas de disponibilidade de nutrientes também são consideradas como fertilização. O modelo também representa essa dinâmica de acordo com a intensidade de manejo em florestas equiâneas de curta rotação. Na maioria das vezes, a simulação é feita com o ciclo do nitrogênio, porém pode ser considerado o ciclo de qualquer outro nutriente, desde que se tenham as entradas necessárias. Uma das entradas do modelo são informações da composição química de alguns compartimentos de biomassa. A disponibilização de nutrientes é feita pela captura nas raízes ou pela redistribuição na árvore. O modelo considera o crescimento de sub-bosque como arbustos e ervas, esse crescimento também é dependente do sítio.

Tabela 1 - Alguns modelos processuais desenvolvidos e suas principais funções (as descrições apresentadas foram obtidas nas referências citadas para o modelo).

(Continuação)

Modelo	Descrição
<p>LINKAGES (PASTOR; POST, 1986)</p>	<p>Simula os processos de decomposição, evapotranspiração, balanço hídrico, captura de nutrientes, crescimento florestal e penetração da luz pelo dossel. É dividido em sub-rotinas para determinação de características do sítio e da dinâmica de crescimento da floresta (nascimento, crescimento e morte). Essas sub-rotinas são integradas por meio de outra sub-rotina chamada (Gmult), que calcula os modificadores do crescimento. Os modificadores limitam o crescimento ao serem multiplicados por valores ótimos. A forma como a luz é interceptada pelo dossel depende da biomassa foliar e pode variar de acordo com a espécie, por meio do uso de modificadores. As biomassas dos compartimentos são calculadas através de equações alométricas e o decréscimo do crescimento se dá a partir do multiplicador mais limitante, não de todos os multiplicadores. São usadas relações alométricas para prever as biomassas de folha e fuste. O modelo foi modificado ao longo do tempo para análises de produção potencial em diferentes cenários climáticos (DIJAK <i>et al.</i>, 2017).</p>
<p>FOREST-BGC (BioGeochemical Cycles) (RUNNING; COUGHLAN, 1988)</p>	<p>Esse modelo é dividido em dois submodelos, o primeiro em passos diários e o segundo em passos anuais. O balanço hídrico, as trocas gasosas realizadas pelo dossel e a partição da fotossíntese entre respiração e produção primária são de passos diários. A partição da biomassa acima e abaixo do solo, produção de serapilheira, ciclo do nitrogênio e processos de decomposição são simulados em passos anuais. Os dados meteorológicos são tratados como médias diárias. O dossel da floresta é representado como uma estrutura tridimensional com profundidade proporcional ao A_f, o modelo é sensível a essa variável. Ele foi desenvolvido buscando utilizar a ferramenta de sensoriamento remoto como principal fonte de informações, por isso o uso do A_f é interessante. Cada compartimento de biomassa (raiz, folha e fuste) possui uma dinâmica própria de desenvolvimento. O modelo também considera os processos de evaporação, transpiração, escoamento, respiração autotrófica e heterotrófica. Os modelos BIOME-BGC (THORNTON <i>et al.</i>, 2002) e BGC + + (HUNT; LAVIGNE; FRANKLIN, 1999) são derivados do FOREST-BGC. Outras aplicações e aprimoramentos podem ser vistos em Behera <i>et al.</i> (2019) e Du <i>et al.</i> (2018).</p>
<p>MAESTRO (WANG; JARVIS, 1990)</p>	<p>Apresenta mais detalhes em relação a copa das árvores para estimar a quantidade de radiação absorvida, taxa fotossintética, transpiração e respiração de cada árvore do povoamento. Para isso a floresta é simulada como um conjunto de árvores em uma matriz tridimensional, gerando informações individuais e para o povoamento total. A copa de cada árvore é descrita individualmente, considerando a posição das folhas no dossel, classificadas por idade e posição na copa, além de informações físicas e fisiológicas.</p>

Tabela 1 - Alguns modelos processuais desenvolvidos e suas principais funções (as descrições apresentadas foram obtidas nas referências citadas para o modelo).

(Continuação)

Modelo	Descrição
<p>MAESTRO (WANG; JARVIS, 1990)</p>	<p>Considera-se que o povoamento é composto por copas proporcionais ao redor do tronco e todas com a mesma forma geométrica. As copas são subdivididas em subvolumes, gerando um grid, os processos de fotossíntese e transpiração, são então calculados em função da soma ponderada das áreas de cada grid pelas quantidades de radiação absorvida por cada um. O modelo é composto por 7 submodelos e roda em passos horários. O modelo utiliza entradas de sítio, solo, folhas, parâmetros fisiológicos, coordenadas geográficas das árvores e clima. Algumas aplicações atuais do MAESTRA podem ser vistas em Binkley <i>et al.</i> (2010) e Le Maire <i>et al.</i> (2019).</p>
<p>BIOMASS (MCMURTRIE; ROOK; KELLIHER, 1990)</p>	<p>Simula a produtividade líquida anual total, transpiração e balanço hídrico. O processo da fotossíntese ocorre em função da arquitetura do dossel, onde é considerada a interceptação das radiações direta e difusa. Além disso, também é considerado o sombreamento das folhas no dossel, que muda de acordo com a posição no dossel (dividido em três camadas e mesma profundidade) e com o ângulo solar zenital. Cada uma dessas camadas possui um A_f. O processamento é realizado em passos diários e usa informações de clima, sítio, da cultura (dimensões da copa, estoque e A_f), concentração de nitrogênio nas folhas e parâmetros fisiológicos. Outros fluxos considerados no modelo de balanço hídrico são a transpiração, drenagem e escoamento. Este trabalho mostra apenas de fotossíntese da copa, porém os autores ressaltam que o BIOMASS possui disposições para incluir funções de respiração, alocar matéria seca para diferentes componentes da biomassa e estimar a queda da serapilheira.</p>
<p>NuCM - Nutrient Cycling Model (JOHNSON; LINDBERG, 1992)</p>	<p>Simula o crescimento da vegetação, queda de serapilheira e sua decomposição, processos biogeoquímicos do solo e roteamento de umidade. O foco principal desse modelo está em definir a disponibilidade e o fluxo de nutrientes na vegetação, a partir de fontes diferentes, como o solo e a atmosfera. Com isso, torna-se possível entender a sanidade e a produtividade da floresta, além de simular respostas em relação a práticas de manejo e mudanças sazonais. Entre os processos hidrológicos, considera-se a distribuição da precipitação pluviométrica através das camadas do dossel e do solo, sendo possível dividir o solo em até 10 camadas. Três processos são considerados no dossel: deposição, lixiviação e exsudação, responsáveis pelo acúmulo de componentes na superfície das folhas. Estes componentes produzem uma solução ao reagir com a água acumulada pela precipitação pluviométrica, que fornece captação direta de nutrientes pela folha, portanto depende do A_f. As entradas necessárias são informações de sítio, constantes de equilíbrio e coeficientes de taxas para diferentes processos. Como saídas o modelo possibilita gerar um diagrama de fluxo e reservatório de nutrientes, diagrama de transições anuais da vegetação e do solo florestal, processos fornecendo cátions base para a solução do solo, crescimento da vegetação e concentrações de nutrientes absorvidos, todos ao longo do tempo.</p>

Tabela 1 - Alguns modelos processuais desenvolvidos e suas principais funções (as descrições apresentadas foram obtidas nas referências citadas para o modelo).

(Conclusão)

Modelo	Descrição
NuCM - Nutrient Cycling Model (JOHNSON; LINDBERG, 1992)	O usuário pode selecionar os passos do modelo (diário, semanal ou mensal). O trabalho de Heijden <i>et al.</i> (2017) é o desenvolvimento do modelo NutsFor baseado também no modelo NuCM.
LaRS (AMTHOR, 1994)	Pode ser usado para estudar a resposta ao aumento da concentração de CO ₂ atmosférico em nível de dossel. Extrapolando as informações do nível foliar para todo o dossel, ecossistema e até a biosfera. São calculados os processos do dossel ligados ao fluxo de CO ₂ , energia e vapor de água, por unidade de área. Para quantificar essas trocas, o modelo considera informações mais detalhadas, como a capacidade da enzima rubisco, o potencial de transporte de elétron, capacidade de uso da triose-P, troca de CO ₂ , condutâncias atmosféricas e de folha, balanço de energia e temperatura do dossel, balanço de radiação de onda longa, troca de calor latente e fluxos de CO ₂ . São necessários 40 parâmetros para rodar o modelo. Neste trabalho o autor aborda esses princípios considerando o dossel como uma camada homogênea, porém o modelo foi aprimorado e possui aplicações como um modelo multicamadas tanto no dossel quanto no solo, conforme descrito por Hanson <i>et al.</i> (2004).
3-PG (LANDSBERG ; WARING, 1997)	Modelo processual de caráter híbrido que roda em passos mensais e baseado na eficiência do uso da luz. A eficiência quântica do dossel é calculada a partir de modificadores do crescimento, que representam os fatores do ambiente de forma mais simples, com valores entre 0 (muito restrito) e 1 (pouco restrito). Os modificadores considerados no modelo são: temperatura, fertilidade do solo, gás carbônico atmosférico, idade, dias com geada, déficit de pressão de vapor e água disponível no solo, também é possível utilizar o modificador dependente da salinidade do solo. Após o cálculo da eficiência quântica do dossel é calculada a produção primária bruta (PPB). A PPB é resultado da multiplicação da eficiência quântica do dossel pela radiação fotossinteticamente ativa absorvida utilizada. Em seguida é calculada a produção primária líquida (PPL) ao descontar a respiração da PPB, representada por um valor constante. A PPL é distribuída entre os compartimentos raiz, folha e fuste. Paralelo a isso, ocorrem os processos de balanço hídrico, mortalidade, produção de serapilheira e rotatividade de raízes. O diâmetro médio da floresta é calculado a partir da biomassa do fuste, o qual também pode ser utilizado para calcular o volume do povoamento, junto a densidade da madeira. Outra alternativa para o cálculo do volume é pelo uso de uma equação alométrica (em função do <i>D</i> e número de fustes por unidade de área) ajustada pelo usuário do modelo para a região analisada, o mesmo é feito para a altura total. A partir do volume do povoamento é calculada a produtividade no período correspondente. A possibilidade de calcular as variáveis de interesse para o manejo florestal, o tornou uma alternativa de vínculo entre modelo processual e modelo convencional. Com o passar dos anos o 3-PG foi atualizado para novas versões.

Fonte: Elaborada pela autora.

Como operam em diferentes escalas e representam diferentes processos com níveis de detalhamento distintos, os modelos processuais, como os citados na Tabela 1, podem ainda ser classificados em diferentes categorias. Por exemplo, de acordo com Landsberg *et al.* (2001), o MAESTRO é um modelo de dossel, o BIOMASS um modelo a nível de povoamento e o FOREST-BCG um modelo regional.

Os modelos processuais buscam representar, a partir de abstrações matemáticas, diferentes processos na interação solo-planta-atmosfera (THORNTON *et al.*, 2002) em diferentes escalas, sendo esses processos dinâmicos no tempo (FORRESTER; TANG, 2016). Isso faz com que existam diversas possibilidades para desenvolvimento de um modelo processual, de acordo com o objetivo do pesquisador, conforme exemplos da Tabela 1.

Nesse tipo de modelagem, os processos são representados e integrados para gerar o crescimento da floresta, que irá refletir o efeito da combinação entre os fluxos de água e carbono, com os processos biológicos da planta (THORNTON *et al.*, 2002). Essa dinâmica possibilita a simulação de cenários, que geram mudanças na troca de energia e massa entre uma floresta ou bioma e a atmosfera, permitindo entender aspectos como a importância da fisiologia e da física da superfície vegetada para a ciclagem de carbono regional e global, meteorologia da camada limítrofe do dossel e impactos das mudanças climáticas no ecossistema florestal (AMTHOR, 1994; LANDSBERG *et al.*, 2001).

A possibilidade de investigar a dinâmica no fluxo de energia, água, carbono e nutrientes na superfície vegetada (RUNNING; COUGHLAN, 1988) ou entender como algumas características e fenômenos (idade, práticas de manejo, clima, tempo desde a ocorrência de perturbações e estado nutricional das plantas) modificam a forma como a floresta absorve carbono (THORNTON *et al.*, 2002), pode melhorar a tomada de decisão sobre o uso dos recursos florestais, diante de diferentes cenários, e a busca pela sustentabilidade.

A flexibilidade dos modelos processuais também faz com que seja possível analisar como a tomada de decisão no manejo irá afetar as respostas biológicas da floresta. Esse tipo de análise, melhora a compreensão sobre como aumentar a produtividade, conhecer o potencial do sítio e os fatores limitantes ao crescimento, bem como o efeito de diferentes estratégias silviculturais (MCMURTRIE; ROOK; KELLIHER, 1990).

Porém, uma limitação inicial no uso dos modelos processuais, foi que a maior parte desses modelos focaram na compreensão do fenômeno, de cunho mais teórico, sem usos práticos no manejo florestal (LANDSBERG, 2003).

Para o manejo de florestas equiâneas, o uso de modelos de crescimento e de produção é bem consolidado na engenharia florestal. Tais modelos podem ser classificados em: modelos em nível de povoamento (ou de povoamento total), modelos de distribuição de diâmetros e modelos de árvores individuais (CLUTTER *et al.*, 1983). Nesses modelos, o efeito de fatores climáticos e edáficos é considerado de modo indireto, pelo índice de sítio (CAMPOS; LEITE, 2017). A construção e aplicação desses modelos é feita com dados obtidos a campo, geralmente provenientes de parcelas permanentes. Por isso, eles refletem práticas de manejo e clima de anos anteriores ao seu ajuste.

Para áreas não florestadas é necessário o uso de ferramentas que possibilitem prever crescimento potencial e isto, de certo modo, pode inviabilizar o emprego de modelos de regressão (DYE, 2001). Uma alternativa para realizar a previsão do crescimento e da produtividade em áreas sem presença de árvores é o emprego de métodos de aprendizado de máquina, como as redes neurais artificiais (ALCANTRA *et al.*, 2018; FREITAS *et al.*, 2020), outra, os modelos processuais.

A maior parte dos primeiros modelos processuais desenvolvidos até a década de 1990, apesar de fornecerem análises dinâmicas do crescimento florestal, são complexos para uso em rotinas de manejo florestal e exigem estimativas ou aproximações para grande quantidade de parâmetros e dados de entrada (BATTAGLIA; SANDS, 1997; LANDSBERG; WARING, 1997), alguns difíceis de serem obtidos (AMTHOR, 1994) e de obtenção economicamente inviável (LANDSBERG *et al.*, 2001). Ainda era necessário associar a biomassa produzida ao crescimento das dimensões das árvores e a sua alocação para cada compartimento, uma vez que, o maior interesse do manejador está no volume do fuste e não na biomassa total produzida (LANDSBERG; WARING, 1997).

Para torná-los mais adequados para uso no manejo florestal, os modelos processuais precisavam ser simplificados em termos de estrutura, dados necessários e saídas desejadas (COOPS; WARING; LANDSBERG, 2001). Essa simplificação ocorreu por meio do desenvolvimento de modelos intermediários entre os modelos de crescimento e produção e os modelos processuais. Nesses modelos, a produção de biomassa é proporcional à radiação fotossinteticamente ativa

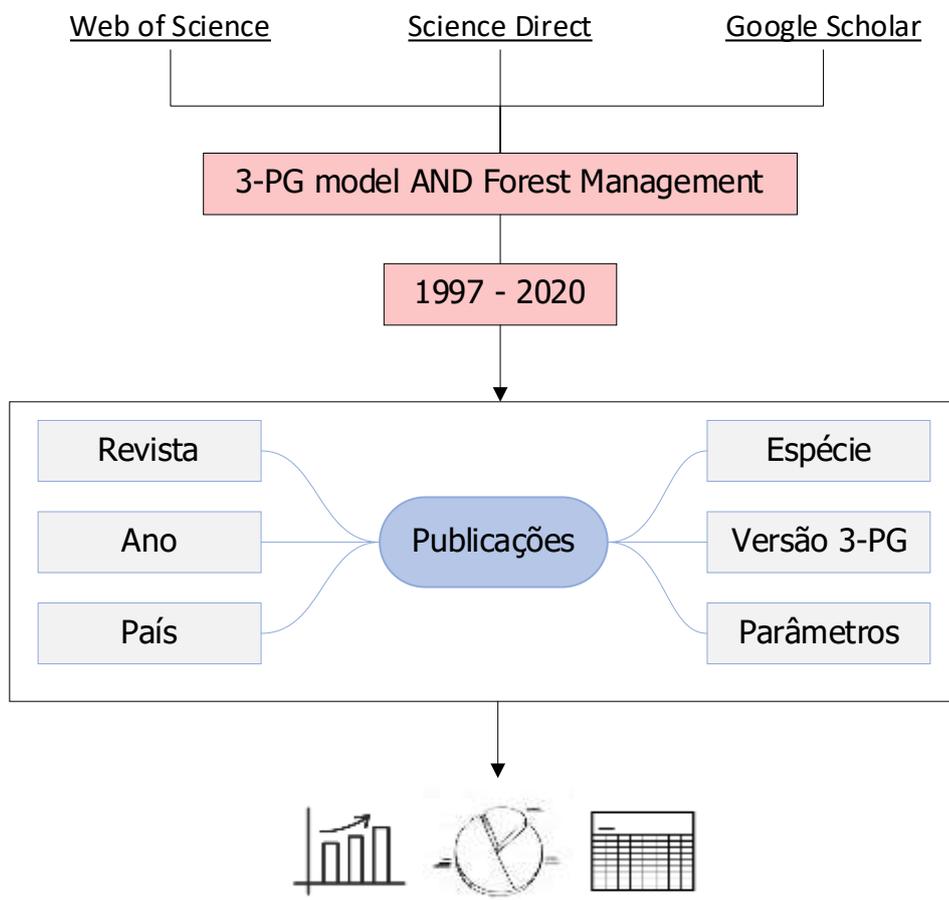
absorvida pelo dossel e alocada para os diferentes compartimentos da árvore com base na eficiência dessa produção, que é determinada de acordo com os fatores do ambiente. O modelo 3-PG faz parte desta categoria, outro exemplo é o modelo ProMod (BATTAGLIA; SANDS, 1997).

Desde 1997, quando foi publicada a pesquisa que apresentou e descreveu o modelo 3-PG (LANDSBERG; WARING, 1997), foram desenvolvidos diversos estudos, com finalidade de pesquisa, mais dirigida à silvicultura e ecologia (LEE *et al.*, 2020; MATHYS; COOPS; WARING, 2014; RODRÍGUEZ *et al.*, 2002; WHITEHEAD *et al.*, 2002) e, também, com aplicações em manejo florestal (ALMEIDA; LANDSBERG, 2003; PAUL *et al.*, 2007; PÉREZ-CRUZADO; MERINO; RODRÍGUEZ-SOALLEIRO, 2011; TICKLE; COOPS; HAFNER, 2001b).

Além do 3-PG na versão padrão, existem as versões 3-PGS (COOPS; WARING; LANDSBERG, 1998) e 3-PGmix (FORRESTER; TANG, 2016), que tratam do uso do 3-PG associado a dados de sensoriamento remoto e aplicado a florestas mistas, respectivamente.

Ao analisar as publicações com o modelo 3-PG e outras versões, até julho de 2020, observamos o comportamento dos valores dos parâmetros utilizados, de que forma foram atribuídos e aprimoramentos. Foram também coletadas informações sobre local, data, espécies e versão do modelo utilizada (Figura 1). Os parâmetros coletados nas pesquisas do Brasil também foram provenientes de teses e dissertações.

Figura 1 - Fluxograma com as bases utilizadas para pesquisa, termos chave, período contemplado, informações coletadas e análises da revisão, a partir da organização em Tabelas e construção de gráficos.



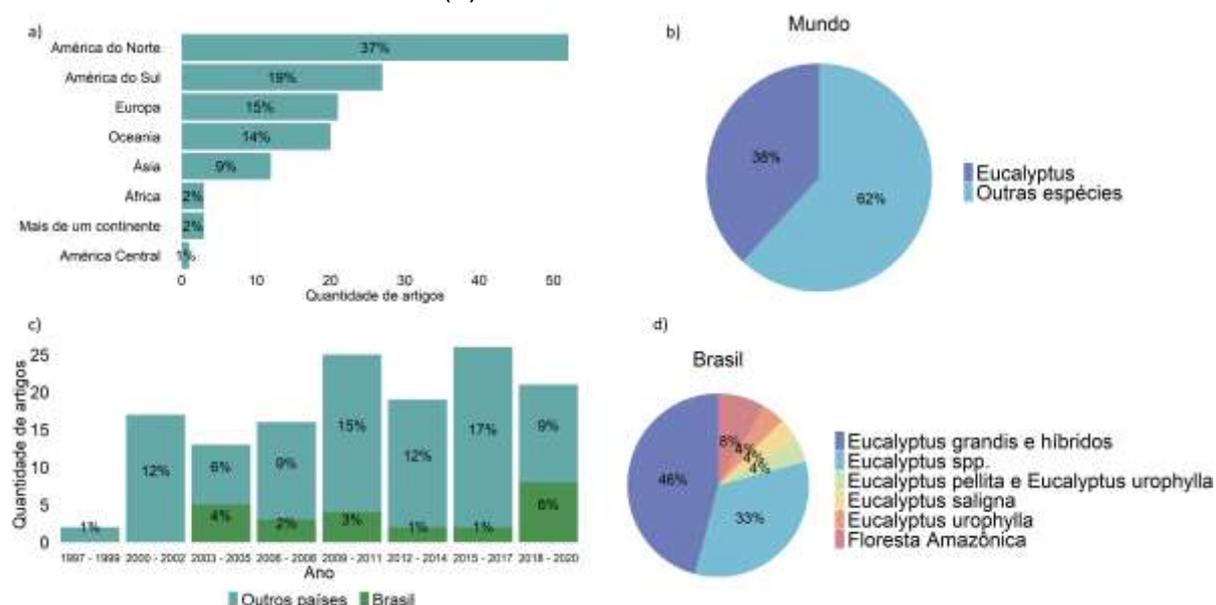
Fonte: Elaborada pela autora.

Abordamos trabalhos desenvolvidos em diferentes regiões do Brasil e do mundo, totalizando 139 artigos. Destes, a maior parte são da América do Norte com 40 publicações dos Estados Unidos, 9 do Canadá e 2 do México. A América do Sul possui a segunda maior quantidade de artigos publicados com 24 do Brasil e 3 do Chile. A Europa, Oceania, Ásia, África, América Central e pesquisas em mais de um continente, totalizaram 60 publicações, com 21 na Europa e 20 na Oceania (Figura 2).

Espécies do gênero *Eucalyptus* foram estudadas em 38% (53) das publicações; nas demais destacam-se as espécies coníferas. No Brasil, com exceção dos dois artigos da Floresta Amazônica, os demais foram para eucalipto, principalmente híbridos de *Eucalyptus grandis* x *Eucalyptus urophylla*, as outras publicações abordaram as espécies *E. urophylla*, *E. saligna* e *E. pellita*. (Figura 2).

A quantidade de publicações aumentou ao longo do tempo, com relativa queda entre os anos 2012 e 2014 e a maior quantidade registrada entre 2015 e 2017. No Brasil, as publicações registradas no levantamento iniciaram em 2003, com redução entre os anos 2012 e 2017, mas com aumento considerável nos últimos dois anos (Figura 2). A maior parte são da região sudeste do país, principalmente nos estados de Minas Gerias e Espírito Santo, os estados do Pará, Rio Grande do Sul e São Paulo têm uma publicação cada, Behling *et al.* (2011), Londero *et al.* (2015) e Lemos *et al.* (2018), respectivamente.

Figura 2 - Quantidade de artigos por região (a), percentual de pesquisas com espécies do gênero *Eucalyptus* em relação as demais (b), quantidade de pesquisas publicadas por ano no Brasil e no mundo (c) e espécies estudadas no Brasil (d).

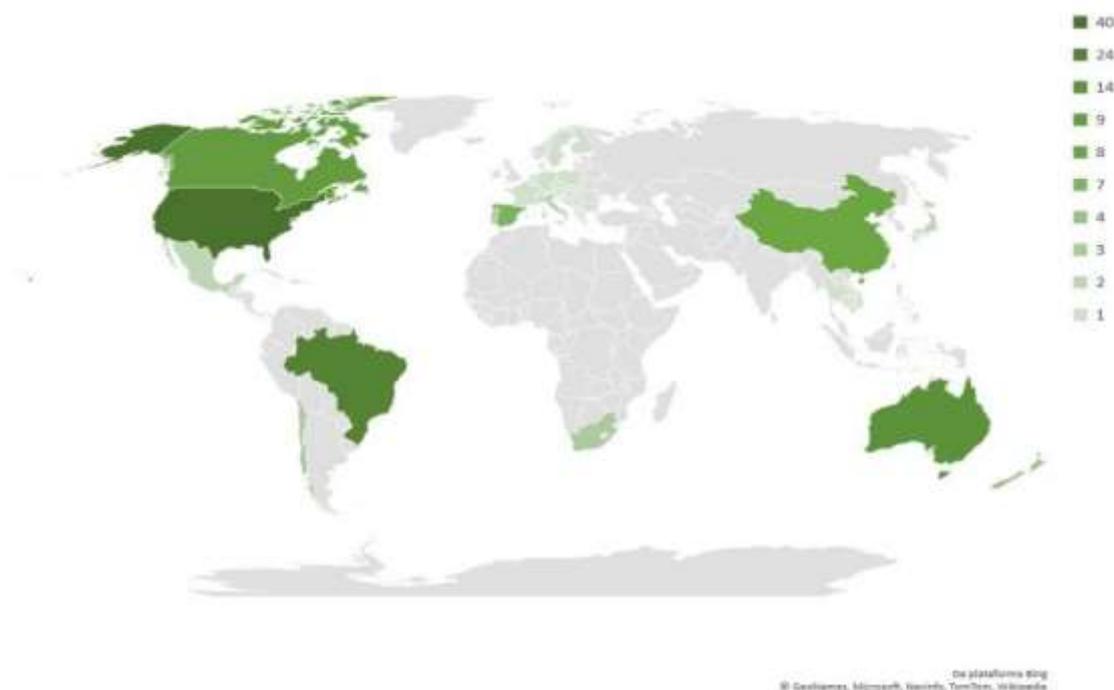


Fonte: Elaborada pela autora.

As regiões com maior número de publicações registradas são aquelas onde atuam pesquisadores pioneiros do 3-PG, que vêm realizando pesquisas com o modelo desde o seu desenvolvimento. O primeiro artigo foi publicado em 1997 pelos pesquisadores Joe J. Landsberg e Richard H. Waring, o primeiro teste foi feito em florestas da Austrália com espécies do gênero *Eucalyptus*, *Pinus*, *Acer* e *Populus*. Em 1998 foi publicado o artigo sobre o 3-PGS, junto com o pesquisador Nicholas C. Coops que realizou diversos estudos sobre esse modelo, principalmente em florestas nos Estados Unidos, além de novas abordagens do 3-PG nessa região ao

longo dos anos, o país em que registramos o maior número de publicações (40) (Figura 3).

Figura 3 - Quantidade de artigos encontrados por país.

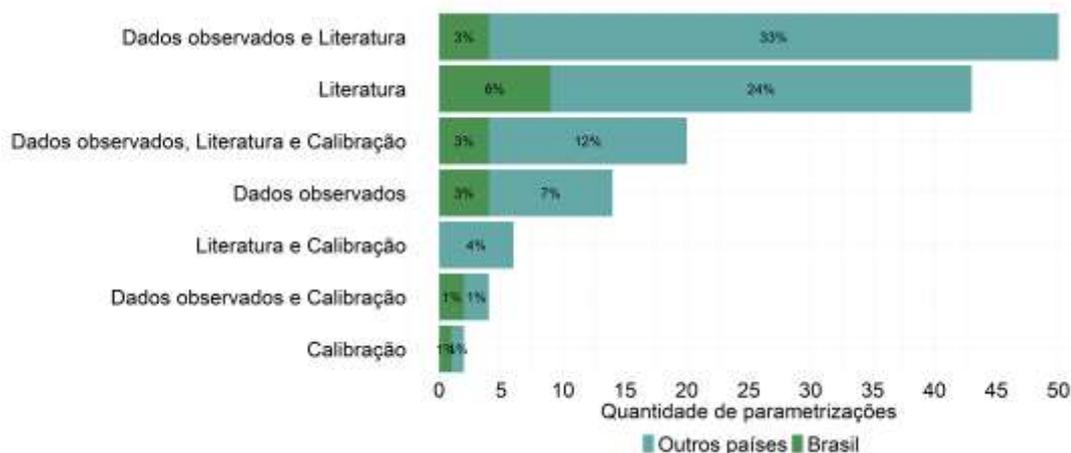


Fonte: Elaborada pela autora.

A região sudeste do Brasil compreende a maior parte dos plantios florestais do país, por isso as pesquisas estão concentradas nessa região. E o gênero *Eucalyptus* é o mais plantado no país, portanto grande parte das pesquisas são direcionadas a esses plantios, além das espécies encontradas em artigos há também uma tese que aplicou o 3-PG para as espécies *Eucalyptus dunnii* e *Eucalyptus benthamii* (KLIPPEL, 2015) e outros estudos para a teca (*Tectona grandis*) (BEHLING, 2009; PONTES, 2011). As publicações encontradas sobre a aplicação do modelo na Floresta Amazônica (FARIA *et al.*, 2020; WHITE *et al.*, 2006) demonstram diferentes oportunidades de uso do 3-PG.

A maior parte das pesquisas utilizaram dados observados e a literatura (36%) ou apenas a literatura (30%) para realizar a parametrização do modelo 3-PG. No Brasil, a maior parte optou pela literatura (Figura 4). Em geral, existe uma mistura entre as técnicas para uma mesma parametrização, sendo alguns valores obtidos a partir de dados observados, parte mantidos como valor padrão, alguns provenientes da literatura e outros são resultados do processo de calibração.

Figura 4 - Quantidade de artigos por estratégia de parametrização utilizada.



Fonte: Elaborada pela autora.

Com base em nossa revisão observamos algumas tendências nas pesquisas. Desde o início dos estudos, buscou-se compreender a sensibilidade das saídas do modelo em relação aos parâmetros sob diferentes condições climáticas e espécies florestais (ALMEIDA; LANDSBERG; SANDS, 2004; CAO *et al.*, 2019; COOPS; WARING, 2001; ESPREY; SANDS; SMITH, 2004; NAVARRO-CERRILLO *et al.*, 2016; RODRÍGUEZ-SUÁREZ *et al.*, 2010; SONG *et al.*, 2012, 2013; XIE; WANG; LEI, 2017; ZHAO *et al.*, 2009) e a partir de experimentos, dados medidos a campo e comparação entre as estimativas do modelo e a biomassa observada, foram encontrados valores mais apropriados para os parâmetros, disponibilizando uma gama de informações na literatura que facilitaram a parametrização do modelo por outros pesquisadores. Estudos mais aprofundados sobre a sensibilidade e incertezas das saídas em relação aos parâmetros de entrada ainda são necessários (GUPTA; SHARMA, 2019).

A estatística bayesiana tem sido uma técnica adotada por alguns pesquisadores para compreender as incertezas sobre os parâmetros (AUGUSTYNCZIK *et al.*, 2017; PATENAUDE *et al.*, 2008; TROTSIUK *et al.*, 2020; XENAKIS; RAY; MENCUCCINI, 2008) ou o método de variância global (SONG *et al.*, 2012). Além disso, o estudo de Song *et al.* (2013) observou que a sensibilidade dos parâmetros muda substancialmente ao longo do tempo e que as características do sítio interferem na sensibilidade de alguns parâmetros, por isso é necessário isolar esses efeitos para compreender melhor a sensibilidade do modelo em si.

Para a parametrização do modelo 3-PG, o processo de calibração tem sido uma estratégia muito utilizada, trata-se de rodar o modelo sucessivamente comparando suas saídas com os valores observados. A partir dessa comparação alguns parâmetros são alterados manualmente e o modelo é rodado novamente até ser atingido um bom ajuste entre valores simulados e observados (LANDSBERG; WARING; COOPS, 2003). Esse processo iterativo busca otimizar o valor dos parâmetros, quanto mais dados observados disponíveis, mais precisa tende a ser a calibração, de preferência dados de séries temporais para capturar a variação das informações, porém a calibração também pode ser utilizada para reproduzir o comportamento de um pequeno conjunto de dados (LANDSBERG *et al.*, 2001; LANDSBERG; WARING; COOPS, 2003). Os dados experimentais são interessantes nesses casos, pois podem fornecer informações de crescimento em diferentes condições. A descrição do método de calibração do modelo 3-PG pode ser vista em Landsberg, Waring e Coops (2003).

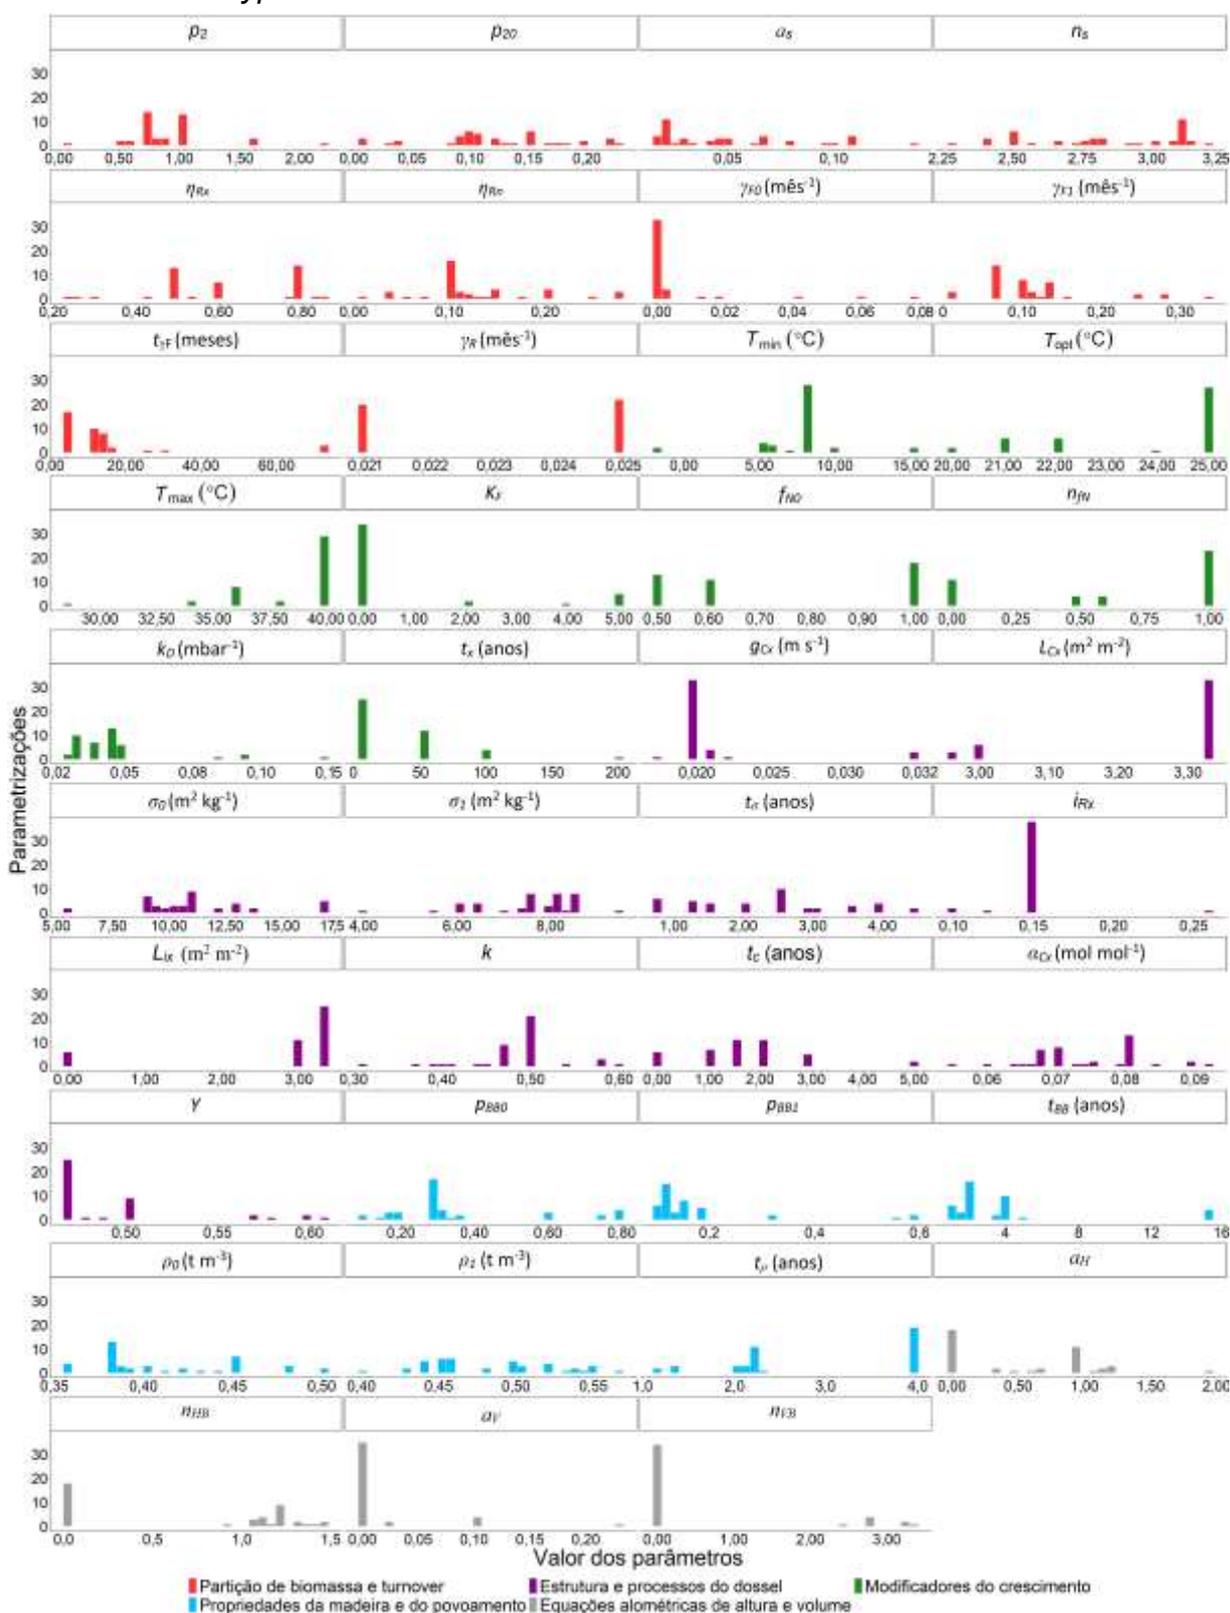
Como exemplo, Stape, Ryan e Binkley (2004) calibraram o modelo 3-PG a partir de dados experimentais de irrigação e fertilização em parcelas de *Eucalyptus grandis* x *Eucalyptus urophylla* no nordeste do Brasil. Em seguida o modelo foi validado com dados independentes de 40 pares de parcelas (controle e fertilizadas) monitoradas por dois anos. O modelo foi comparado com um modelo de crescimento e de produção ajustado para a região ($Volume = f(idade, sítio, área\ basal)$). O modelo 3-PG apresentou vantagem em relação ao modelo de regressão quando se trata de captar variações climáticas interanuais para simular a resposta do *Eucalyptus* a mudanças na fertilidade e clima. A calibração foi importante para que o modelo pudesse absorver as mudanças no padrão de alocação de carbono pela floresta de acordo com a quantidade de água e nutrientes disponíveis. É importante destacar que essa técnica requer muito cuidado, conhecimento sobre o papel de cada parâmetro no modelo e checar o realismo biológico (SANDS, 2004).

Pensando sobre o processo de calibração, em que são feitas alterações no valor de determinados parâmetros, seguido da comparação sucessiva entre valores simulados pelo modelo e valores observados, até haver uma proximidade entre esses dados. O treinamento supervisionado de uma rede neural artificial realiza o mesmo processo, a partir de um algoritmo de aprendizado, onde os pesos são atualizados em função do erro ao final de uma iteração. Esse erro vem da comparação entre dados observados e os dados preditos pela RNA. Isto indica que

a partir de variáveis relacionadas com o parâmetro, como dados climáticos e edáficos ou valores de outros parâmetros relacionados, pode ser possível prever um parâmetro usando a RNA. Além disso, a RNA permite acrescentar variáveis categóricas, o que não seria factível na calibração usual. A vantagem é que a rede é capaz de extrair informações das variáveis de entrada para prever a saída de forma otimizada, eliminando a necessidade da calibração manual e, ao mesmo tempo, simplifica e resulta em maior flexibilidade e consistência, além de menor custo na obtenção de dados para calibrar o modelo 3-PG.

Ao agrupar os parâmetros usados pelas pesquisas com eucalipto no Brasil, sem considerar aqueles utilizados como padrão em todas as parametrizações, observamos que maiores variações se encontram nos parâmetros relativos à partição de biomassa e *turnover*, estrutura e processos do dossel, equações alométricas de altura e de volume e propriedades da madeira e do povoamento. Todas as parametrizações registradas mantiveram os parâmetros fatores de conversão como padrão e os parâmetros do submodelo de mortalidade e auto-desbaste apresentaram mínima variação, com a maior parte também como valor padrão. Os parâmetros usados para o cálculo dos modificadores do crescimento variaram de forma moderada (Figura 5).

Figura 5 - Número de parametrizações do modelo 3-PG, obtidos no levantamento, em relação aos valores dos parâmetros usados para espécies do gênero *Eucalyptus* no Brasil.



* A descrição de cada parâmetro encontra-se na Tabela 3.

Fonte: Elaborada pela autora.

A alocação da biomassa está muito associada a questões como idade, genótipo/espécie, fertilidade do solo e estresse (ALMEIDA; LANDSBERG; SANDS, 2004; FEIKEMA *et al.*, 2010; LANDSBERG; WARING, 1997). São características muito específicas da espécie e do sítio, assim como as propriedades da madeira e do povoamento e os parâmetros das relações alométricas, portanto, conforme o levantamento realizado, isso pode explicar porque raramente os parâmetros ligados a esses fatores são usados como padrão (Figura 5), o mesmo ocorreu em relação aos processos do dossel.

Landsberg e Waring (1997) afirmaram que a alocação da biomassa seria um dos maiores obstáculos para a simulação dos padrões de crescimento, visto que a taxa de alocação varia com o tempo e condições ambientais. Na parametrização realizada por Almeida, Landsberg e Sands (2004), utilizando dados experimentais de clones de *Eucalyptus grandis*, as principais diferenças encontradas por clone foram na alocação de biomassa e condutância estomática.

Na Figura 5 é possível observar que alguns dos parâmetros usados nos cálculos dos modificadores do crescimento não variaram muito, o que pode ser explicado pela localização dos estudos. A maior parte são de regiões relativamente similares, no sudeste do país, e por se tratarem de espécies do mesmo gênero. Dessa forma, nas temperaturas mínima, ótima e máxima prevaleceram os valores 8°C, 25°C e 40°C, com valores menores em estudos no sul do país. Os parâmetros relacionados a água no solo, resposta estomática ao DPV e fertilidade apresentaram maior variação em relação aos demais parâmetros dos modificadores.

A fertilidade é uma parte muito importante do modelo, pois afeta a eficiência quântica do dossel e a alocação de biomassa para a raiz (SANDS; LANDSBERG, 2002), o primeiro compartimento calculado pelo modelo, qualquer mudança nesse parâmetro impacta consideravelmente as estimativas. Dessa forma, muitos estudos buscaram modificar essa parte do modelo ou testar valores a partir de dados experimentais com fertilização para encontrar estimativas mais precisas de fertilidade (ALMEIDA *et al.*, 2010; BORGES, 2012; COOPS; WULDER; WARING, 2012; GONZALEZ-BENECKE *et al.*, 2014; LANDSBERG *et al.*, 2001; LEMOS, 2012; SUBEDI; FOX, 2016; SUBEDI; FOX; WYNNE, 2015; VEGA-NIEVA *et al.*, 2013).

O submodelo de balanço hídrico também foi modificado em alguns estudos, pois a sua resolução mensal não era eficiente para captar as mudanças ao longo do

tempo. Desde os primeiros estudos essa necessidade foi apontada pelos pesquisadores, porém alterar a resolução temporal do submodelo de balanço hídrico esbarrava em desafios como a obtenção de dados precisos sobre variabilidade vertical e horizontal dos solos e incertezas na distribuição das raízes e umidade do solo (ALMEIDA; LANDSBERG; SANDS, 2004). Porém, os trabalhos desenvolvidos por Feikema *et al.* (2010) e Rascon (2012) modificaram o submodelo de balanço hídrico para passos diários e Silva *et al.* (2013) modificaram o submodelo para passos horários.

O DPV interfere na condutância estomática, portanto pode afetar a produtividade. Almeida e Landsberg (2003) avaliaram valores de radiação e DPV medidos por estações meteorológicas automáticas da empresa Aracruz Celulose S.A. As radiações global, fotossinteticamente ativa (RFA) e líquida foram comparadas com predições feitas por modelos matemáticos. O mesmo foi feito para o DPV medidos durante o dia e o DPV 24 hs em relação a valores estimados a partir das temperaturas mínima e máxima. Os autores observaram que o DPV foi responsável pela redução em 28% da produtividade final e regiões mais próximas do litoral apresentaram menores DPV em relação a regiões mais afastadas do litoral. Foi também observado que as diferentes características de massa de ar das regiões tropicais e subtropicais geram efeitos distintos na radiação, o que mostra a necessidade de refinar o modelo para uso nessas regiões. O valor de DPV durante o dia foi mais eficiente para calcular a transpiração e modelar crescimento, porém variou significativamente entre sítios.

Em outro estudo, no estado do Espírito Santo, Almeida *et al.* (2010) criaram uma versão GIS do 3-PG associando-o a ferramenta ArcGIS para detectar e quantificar os efeitos da seca no crescimento de plantios do híbrido *E. grandis x E. urophylla*, intensamente manejados. Novamente o DPV esteve entre os fatores que mais restringiram o crescimento na região, junto com a quantidade de água disponível e a fertilidade do solo.

Como o Brasil possui diferentes regiões climáticas, solo e relevo, a parametrização deve considerar as condições do local e tipo de manejo, atentando sempre à sensibilidade dos parâmetros e a relação entre eles.

Analisando a variação média dos parâmetros coletados (Tabela 2) observamos que os processos do dossel apresentaram variação principalmente nos parâmetros área foliar na idade madura (σ_l) e eficiência quântica máxima do dossel

(α_{Cx}). A maior parte dos parâmetros ligados aos modificadores do crescimento apresentaram variações acima de 10%, as maiores foram para os parâmetros valor de f_N quando $FR = 0$ (f_{N0}), temperatura ótima (T_{opt}) e idade máxima (t_x). O mesmo ocorreu com os parâmetros da partição de biomassa e *turnover*, exceto o parâmetro da taxa de turnover de raiz (γ_R). Nos parâmetros ligados às propriedades da madeira e do povoamento, apenas a densidade da madeira em idade madura (ρ_x) obteve baixa variação, o restante apresentou variações acima de 14%. Na categoria dos parâmetros da mortalidade, apenas a idade em que a taxa de mortalidade é média (t_{YN}) apresentou maior variação, a biomassa média de fuste, a cada 1000 árvores, variou 3,81% e nos demais foram usados valores padrão (Tabela 2).

Tabela 2 – Análise da variação dos parâmetros utilizados para eucalipto no Brasil em relação ao valor padrão, com a média dos valores usados e a variação média percentual em relação ao valor padrão, média dos valores associados aos parâmetros com valor padrão igual a zero e parâmetros utilizados como padrão, de acordo com o levantamento realizado.

(Continua)				
Categoria	Símbolo do parâmetro*	Valor padrão	Média dos valores usados	Variação média (%)
Estrutura e processos do dossel	g_{Cx} ($m\ s^{-1}$)	0,02	0,021	4,79
	L_{Cx} ($m^2\ m^{-2}$)	3,33	3,256	-2,21
	i_{Rx}	0,15	0,150	-0,32
	k	0,5	0,485	-2,95
	Y	0,47	0,494	5,12
	α_{Cx} ($mol\ mol^{-1}$)	0,06	0,074	23,85
	σ_0 ($m^2\ Kg^{-1}$)	11	11,236	2,15
Estrutura e processos do dossel	σ_1 ($m^2\ Kg^{-1}$)	4	7,558	88,96
	t_σ (anos)	2,5	2,324	-7,03
Modificadores do crescimento	c_θ	0,7	0,621	-11,25
	n_θ	9	7,595	-15,61
	k_D ($mbar^{-1}$)	0,05	0,047	-6,30
	f_{N0}	1	0,740	-25,95
	T_{max} ($^{\circ}C$)	40	38,587	-3,53
	T_{min} ($^{\circ}C$)	8,5	7,506	-11,69
	T_{opt} ($^{\circ}C$)	16	23,737	48,36
t_x (anos)	50	33,833	-32,33	

Tabela 2 – Análise da variação dos parâmetros utilizados para eucalipto no Brasil em relação ao valor padrão, com a média dos valores usados e a variação média percentual em relação ao valor padrão, média dos valores associados aos parâmetros com valor padrão igual a zero e parâmetros utilizados como padrão, de acordo com o levantamento realizado.

(Continuação)

Categoria	Símbolo do parâmetro*	Valor padrão	Média dos valores usados	Variação média (%)
Mortalidade e auto-desbaste	t_{YN}	2	1,429	-28,57
	$w_{Sx}1000$ (Kg árvore ⁻¹)	300	288,571	-3,81
Partição de biomassa e turnover	n_s	2,4	2,840	18,32
	a_s	0,095	0,049	-51,27
	p_2	1	0,887	-11,27
	p_{20}	0,15	0,121	-19,51
	η_{Rn}	0,25	0,127	-49,15
	η_{Rx}	0,8	0,621	-22,39
	t_{yF} (meses)	12	14,255	18,79
	γ_{F0} (mês ⁻¹)	0,001	0,006	485,64
	γ_{F1} (mês ⁻¹)	0,027	0,112	274,21
	γ_R (mês ⁻¹)	0,015	0,020	1,19
Propriedades da madeira e do povoamento	ρ_{BB0}	0,75	0,362	-51,79
	ρ_{BB1}	0,15	0,172	14,59
	t_{BB} (anos)	2	3,681	84,06
	t_p (anos)	4	2,905	-27,38
	ρ_0 (t m ⁻³)	0,5	0,410	-17,92
	ρ_1 (t m ⁻³)	0,5	0,484	-3,11
Média dos parâmetros com valor padrão igual a zero				
Categoria	Parâmetro	Valor médio		
Equações alométricas de altura e de volume	a_H	0,922		
	n_{HB}	1,187		
	n_{HN}	0,00		
	a_V	0,099		
	n_{VB}	2,908		
	n_{VN}	0,00		
Estrutura e processos do dossel	L_{ix} (m ² m ⁻²)	2,768		
	t_c (anos)	1,683		
Modificadores do crescimento	k_F	0,786		
	n_{FN}	0,652		
Parâmetros usados como padrão				
Categoria	Parâmetro	Valor		
Estrutura e processos do dossel	g_B (m s ⁻¹)	0,20		
	g_{Cn} (m s ⁻¹)	0,00		

Tabela 2 – Análise da variação dos parâmetros utilizados para eucalipto no Brasil em relação ao valor padrão, com a média dos valores usados e a variação média percentual em relação ao valor padrão, média dos valores associados aos parâmetros com valor padrão igual a zero e parâmetros utilizados como padrão, de acordo com o levantamento realizado.

		(Conclusão)
Categoria	Parâmetro	Valor
Modificadores do crescimento	f_{Cg700}	0,70
	f_{Ca700}	1,40
	n_{age}	4,00
	r_{age}	0,95
	m_0	0,00
Mortalidade e auto-desbaste	m_R	0,20
	m_S	0,20
	m_F	0,00
	n_{yN}	1,00
	n_N	1,50
	γ_{N0}	0,00
	γ_{N1}	0,00
Equações alométricas de altura e de volume	n_{HN}	0,00
	n_{VN}	0,00
Fatores de conversão	g_{DM_mol} (g mol ⁻¹)	24,00
	$molPAR_MJ$ (mol MJ ⁻¹)	2,30
	Q_a (W m ⁻²)	-90,00
	Q_b	0,80

* A descrição de cada parâmetro encontra-se na Tabela 3.

Fonte: Elaborada pela autora.

As informações obtidas na literatura, mostraram o quanto o 3-PG é flexível, sensível às mudanças dos parâmetros e capaz de representar os processos do crescimento florestal de forma mais simples. Essas características tornam esse tipo de modelo uma ferramenta útil para entender os impactos das mudanças climáticas. Como os processos representados nesses modelos dependem das condições ambientais, eles são os mais relevantes para compreender o crescimento e composição atuais e futuros da floresta (FONTES *et al.*, 2010).

A atenção sobre as mudanças climáticas está aumentando, e grande parte dos trabalhos mais recentes, que usaram o 3-PG, abordaram esse tema. Com objetivos de entender os impactos de diferentes cenários das mudanças climáticas na produtividade florestal (ADHIKARI; WHITE, 2016; ALMEIDA *et al.*, 2009; AUGUSTYNCZIK *et al.*, 2017; BAESSO, 2011; BAESSO; RIBEIRO; SILVA 2010;

CAO *et al.*, 2019; COOPS; WARING, 2001; NÖLTE; MEILBY; YOUSEFPOUR, 2018; XIE; WANG; LEI, 2020).

Além disso, por ser um modelo sensível ao clima, outros estudos foram desenvolvidos para prever a distribuição de espécies diante de diferentes condições ou mudanças climáticas (COOPS; WARING, 2011a, 2011b; COOPS; WARING; SCHROEDER, 2009; LU *et al.*, 2015) e estudar o impacto de eventos climáticos extremos (SUBRAMANIAN *et al.*, 2019; TROTSIUK *et al.*, 2020).

Alguns dos primeiros estudos com o 3-PG, como Almeida e Landsberg (2003) e Hanson *et al.* (2004), ressaltavam lacunas, muitas vezes associadas a qualidade dos dados mensuráveis, seja em relação ao avanço na tecnologia, disponibilidade de dados, ou controle e calibração de aparelhos como fonte de informação. As técnicas de sensoriamento remoto, por exemplo, são capazes de gerar informações sobre variabilidades espaciais que influenciam a produtividade das florestas em amplas paisagens, como a declividade, que auxilia na correção dos elementos climáticos temperatura e radiação, é também possível identificar distúrbios ambientais e gerar estimativas extrapoladas em nível local, regional ou nacional (TICKLE; COOPS; HAFNER, 2001a). A disponibilidade de novos sensores podem orientar melhor o uso de modelos processuais através de diferentes condições de solo e clima (LANDSBERG; WARING, 1997; WARING; COOPS; LANDSBERG, 2010). Atualmente, novas tecnologias estão sendo testadas com resultados satisfatórios, esse fator, associado às preocupações sobre o clima, podem ter contribuído para o aumento no número de pesquisas com o modelo 3-PG nos últimos anos.

Recentemente foi publicado um estudo de revisão por Gupta e Sharma (2019), em que foram abordados os principais estudos, até o ano 2017, sobre o 3-PG padrão e sobre as versões 3-PGS e 3-PG_{mix}. A partir deste estudo, os autores ressaltaram os locais onde as pesquisas foram desenvolvidas, espécies estudadas, principais contribuições na área e novos desafios.

Em geral, o direcionamento dos estudos com o 3-PG foram para abordagens sobre o clima, com base em séries históricas, cenários futuros e extremos climáticos. Houve também estudos voltados a compreensão da sensibilidade e incertezas sobre os parâmetros, além de aprimoramentos do modelo ou desenvolvimento de novas versões. São estratégias que podem melhorar a precisão das estimativas do

crescimento das florestas e atender a diferentes objetivos no planejamento e no manejo florestal.

Tabela 3 - Categorias, descrições e símbolos dos parâmetros do modelo 3-PG.

(Continua)		
Categoria	Descrição	Símbolo*
Equações alométricas de altura e volume	Constante na relação de altura do fuste	a_H
	Potência do D na relação de altura do fuste	n_{HB}
	Potência do estoque na relação de altura do fuste	n_{HN}
	Constante na relação de volume do fuste	a_V
	Potência do D na relação de volume do fuste	n_{VB}
	Potência do estoque na relação de volume do fuste	n_{VN}
Estrutura e processos do dossel	Condutância mínima do dossel ($m\ s^{-1}$)	g_{Cn}
	Condutância máxima do dossel ($m\ s^{-1}$)	g_{Cx}
	A_f para a máxima condutância do dossel ($m^2\ m^{-2}$)	L_{Cx}
	Condutância da camada limítrofe do dossel ($m\ s^{-1}$)	g_B
	Interceptação máxima de chuva pelo dossel	i_{Rx}
	A_f para a interceptação máxima de chuva ($m^2\ m^{-2}$)	L_{ix}
	Coefficiente de extinção para absorção da radiação fotossinteticamente ativa (RFA) pelo dossel	k
	Idade na cobertura total do dossel (anos)	t_c
	Razão PPL/PPB	Y
	Área foliar específica na idade 0 ($m^2\ kg^{-1}$)	σ_0
	Área foliar específica para povoamento maduro ($m^2\ kg^{-1}$)	σ_1
	Idade na qual $\sigma = (\sigma_0 + \sigma_1)/2$ (anos)	t_σ
	Eficiência quântica máxima do dossel ($mol\ mol^{-1}$)	a_{Cx}
Fatores de conversão	Intercépto da relação entre a radiação líquida e a radiação solar ($W\ m^{-2}$)	Q_a
	Inclinação da relação entre a radiação líquida e a radiação solar	Q_b
	Peso molecular da matéria seca ($g\ mol^{-1}$)	-
	Conversão da radiação solar para RFA ($mol\ MJ^{-1}$)	-
Modificadores do crescimento	Temperatura mínima para crescimento ($^{\circ}C$)	T_{min}
	Temperatura máxima para crescimento ($^{\circ}C$)	T_{max}
	Temperatura ótima de crescimento ($^{\circ}C$)	T_{opt}
	Número de dias de produção perdidos para cada dia de geada	k_F
	Resposta estomática ao déficit de pressão de vapor (DPV) ($mbar^{-1}$)	k_D
	Déficit da taxa de umidade em que $f_\theta = 0,5$	c_θ
	Potência do déficit de razão de umidade em f_θ	n_θ
	Idade máxima do povoamento (anos)	t_x
	Potência da idade relativa em f_{age}	n_{age}
	Idade relativa em que $f_{age} = 0,5$	r_{age}
	Valor de m quando $FR = 0$	m_0
	Valor de f_N quando $FR = 0$	f_{N0}
	Potência de $(1 - FR)$ em f_N	n_{fN}
Eficiência quântica a 700 ppm	f_{Ca700}	
Condutância do dossel a 700 ppm	f_{Cq700}	

Tabela 3 - Categorias, descrições e símbolos dos parâmetros do modelo 3-PG.

		(Conclusão)
Categoria	Descrição	Símbolo*
Mortalidade e auto-desbaste	Máxima biomassa de fuste por árvore para um $N = 1000$ árvores ha^{-1}	W_{Sx1000}
	Potência na lei de auto-desbaste	n_N
	Fração de biomassa de folha perdida por árvore morta	m_F
	Fração de biomassa de raiz perdida por árvore morta	m_R
	Fração de biomassa de fuste perdida por árvore morta	m_S
	Taxa de mortalidade de mudas em $t = 0$	γ_{N0}
	Taxa de mortalidade para povoamento maduro	γ_{N1}
	Idade na qual $\gamma_N = (\gamma_{N0} + \gamma_{N1})/2$ (anos)	$t_{\gamma N}$
Parâmetro de forma da função de resposta a mortalidade	$n_{\gamma N}$	
Partição de biomassa e turnover	Taxa de serapilheira em $t = 0$ ($mês^{-1}$)	γ_{F0}
	Taxa de serapilheira para povoamento maduro ($mês^{-1}$)	γ_{F1}
	Idade na qual $\gamma_F = (\gamma_{F0} + \gamma_{F1})/2$ (meses)	$t_{\gamma F}$
	Constante na relação entre a biomassa média de fuste e o D	a_s
	Potência na relação entre a biomassa média de fuste e o D	n_s
	Razão de partição folha/fuste para um $D = 2$ cm	p_2
	Razão de partição folha/fuste para um $D = 20$ cm	p_{20}
	Fração máxima da PPL alocada para raízes	η_{Rx}
Fração mínima da PPL alocada para raízes	η_{Rn}	
Taxa mensal de <i>turnover</i> de raiz ($mês^{-1}$)	γ_R	
Propriedades da madeira e do povoamento	Fração galho e casca para árvores jovens	ρ_{BB0}
	Fração galho e casca para árvores maduras	ρ_{BB1}
	Idade na qual $p_{BB} = (p_{BB0} + p_{BB1})/2$ (anos)	t_{BB}
	Densidade básica da madeira para árvores jovens ($t\ m^{-3}$)	ρ_0
	Densidade básica da madeira para árvores maduras ($t\ m^{-3}$)	ρ_1
Idade na qual $\rho = (\rho_0 + \rho_1)/2$ (anos)	t_ρ	

* Todos os símbolos do modelo 3-PG foram padronizados, em toda a tese, conforme Sands (2010).

Fonte: Elaborada pela autora.

2 APRENDIZADO DE MÁQUINA

As técnicas de aprendizado de máquina envolvem métodos de inteligência artificial (IA) para realizar determinadas tarefas (MITCHELL, 1997). São muitas as possibilidades de usos, e um exemplo muito comum na área florestal é o mapeamento da relação funcional entre variáveis. Essas técnicas são utilizadas para extrair informações de banco de dados e armazená-las matematicamente, como resultado de um processo de aprendizagem, que varia conforme o método adotado, e foi inspirado na forma como o cérebro humano aprende (EL NAQA; LI; MURPHY, 2015).

São muitas as opções existentes na literatura e que contribuem em diversas áreas da ciência, com alta capacidade para modelagem e resolução de problemas. Entre as técnicas de aprendizado de máquina, as redes neurais artificiais (RNA) estão entre as mais utilizadas na engenharia florestal. Os principais benefícios do seu uso envolvem ganhos em exatidão, maior capacidade de generalização, associação entre variáveis de diferentes tipos, adaptabilidade e capacidade de representar relações complexas e não lineares de forma mais flexível (HAYKIN, 2009). Além da RNA, também são encontradas pesquisas com outras técnicas de aprendizado de máquina na engenharia florestal, como a Máquina de Vetor de suporte (MVS), a neuro-fuzzy e os autômatos celulares.

Na área florestal, esse assunto já é estudado há muitos anos, em 1990 um estudo publicado por Kourtz (1990) discutiu sobre os benefícios da IA para o manejo florestal. Em seu trabalho, Kourtz (1990) focou no uso de sistemas especialistas, uma subcategoria da IA, e também abordou a robótica, a visão computacional, o reconhecimento de padrões, o processamento de linguagem natural e as redes neurais como técnicas potenciais para uso no manejo florestal.

McRoberts, Schmoltd e Rauscher (1991) discutiram sobre como o uso da IA poderia melhorar o processo científico e suas potenciais aplicações na engenharia florestal. Os autores argumentaram sobre o uso das redes neurais, máquina de vetor de suporte, sistemas de consultoria, gestão do conhecimento e simulação qualitativa. A RNA foi apontada pelos autores como uma ferramenta adequada para a modelagem do crescimento e da produção florestal, devido a sua capacidade de descrever o comportamento da relação de forma implícita e estimar os pesos simultaneamente, bem como a capacidade de adaptação da rede ao ser treinada

novamente com um novo conjunto de dados, mais específicos do sítio. Além disso, a RNA poderia também ser aplicada em problemas de classificação de padrões, para selecionar combinação entre espécie e sítio, diagnóstico de doenças, seleção de tratos silviculturais e análise de riscos.

Ainda no final da década de 1990 as aplicações com a RNA já eram diversas, como o desenvolvimento de mapas e classificação de terras, modelagem do crescimento e da produção florestal, análise e modelagem de dados espaciais, modelagem sobre a dinâmica de doenças de plantas e pesquisas sobre mudanças climáticas (PENG; WEN, 1999).

A partir de então, o número de pesquisas cresceu e o uso dessas técnicas se mostrou cada dia mais promissor, para muitas áreas da engenharia florestal, diferentes objetivos e com resultados e conclusões que reforçavam as vantagens do seu uso.

Os usos são muito variados. Alguns exemplos na mensuração florestal foram trabalhos desenvolvidos com as redes neurais artificiais para modelagem em nível de árvore individual (ASHRAF *et al.*, 2013; CASTRO *et al.*, 2013; LIAO; NOGAMI; IMANAGA, 1998), com o uso da RNA e da neuro-fuzzy (VIEIRA *et al.*, 2018) e aplicações também em florestas nativas para modelagem de diâmetro e altura total (HAMIDI *et al.*, 2021; REIS *et al.*, 2016; TAVARES JÚNIOR *et al.*, 2020), para modelagem da mortalidade e sobrevivência (BAYAT *et al.*, 2019; HASENAUER; MERKL, 1997; ROCHA *et al.*, 2018) e para classificação da estrutura vertical (KWON *et al.*, 2017).

Na predição de volume individual de árvores, diversas pesquisas foram realizadas para eucalipto (BINOTI; BINOTI; LEITE, 2014; DANTAS *et al.*, 2020; MIGUEL *et al.*, 2016; MUSHAR *et al.*, 2020; SILVA *et al.*, 2009) e outras espécies (CORDEIRO *et al.*, 2015; ÖZÇELIK *et al.*, 2010; SOCHA; NETZEL; CYWICKA, 2020), inclusive para modelar o crescimento em diâmetro ao longo do fuste em plantios de teca (LEITE *et al.*, 2011), de eucalipto (AZEVEDO *et al.*, 2020) e para diferentes espécies (SOCHA; NETZEL; CYWICKA, 2020). A modelagem do volume com a RNA também foi desenvolvida a partir de dados espaciais (CORTE *et al.*, 2020; LEITE *et al.*, 2020; NISKA *et al.*, 2010; SILVA, A. *et al.*, 2021).

Predições da altura total foram feitas com o uso da RNA em florestas equiâneas (BINOTI, M.; BINOTI; LEITE, 2013; BINOTI *et al.*, 2017; COSTA FILHO *et*

al., 2019; ERCANLI, 2020) e em florestas inequidistantes (BAYAT *et al.*, 2020; DIAMANTOPOULOU, 2012).

Alguns estudos mostraram ainda, que além dos ganhos em acurácia na modelagem, o emprego das técnicas de aprendizado de máquina possibilitam a redução do esforço amostral mantendo a precisão dos resultados (BINOTI, D.; BINOTI; LEITE, 2013, BINOTI *et al.*, 2014a; TAVARES JÚNIOR *et al.*, 2019).

Em povoamentos de eucalipto submetidos a desbastes o uso de autômatos celulares se mostrou eficiente em projetar a distribuição diamétrica (BINOTI *et al.*, 2012), assim como a RNA (BINOTI *et al.*, 2014b; SCRINZI; MARZULLO; GALVAGNI, 2007). Estudos sobre a prognose do crescimento e da produção florestal em nível de povoamento foram realizados para diferentes regiões do Brasil com a RNA (ALCANTRA *et al.*, 2018; BINOTI *et al.*, 2015) e outras técnicas de aprendizado de máquina (SILVA, J. *et al.*, 2021). Estudos sobre a modelagem da produtividade com base em aspectos silviculturais e com o uso de variáveis biofísicas também foram realizados (DOLÁCIO *et al.*, 2020; FREITAS *et al.*, 2020).

Existem muitas outras aplicações interessantes que foram desenvolvidas em mais de 30 anos de pesquisas na área florestal, como o uso da RNA para prognose do preço do carvão em Minas Gerais (COELHO JUNIOR *et al.*, 2013), estimativas do índice de área foliar (ERCANLI *et al.*, 2018), modelagem da biomassa acima do solo (DOMINGUES *et al.*, 2020; DUBE *et al.*, 2014; GARCÍA-GUTIÉRREZ *et al.*, 2015; NANDY *et al.*, 2017; VAHEDI, 2016), fluxo de carbono em plantios florestais (WEN *et al.*, 2014) e até mesmo para realizar projeções climáticas (ASHRAF *et al.*, 2015).

Grande parte das pesquisas mostram comparações das técnicas de aprendizado de máquina com modelos de regressão, pois é a técnica tradicionalmente utilizada para modelagem florestal. Porém, o objetivo não é a substituição da regressão, mas complementar o conjunto de técnicas para pesquisas e aplicações na área, incentivando o seu uso nas situações apropriadas.

Com base nessas e em outras experiências, é possível perceber que as redes neurais artificiais são utilizadas em muitas áreas da engenharia florestal, para diferentes espécies e em outras partes do mundo. Diferentes configurações e alternativas para combinação entre variáveis já foram definidas, com diferentes tipos de redes. Estas soluções ajudaram a construir uma base teórica e prática consistente para orientar o uso das redes neurais artificiais, sem restrições e que inspiram novas pesquisas. Computacionalmente não se tem dificuldades para treinar

e aplicar uma rede neural, pois existe uma gama muito grande de *softwares* disponíveis.

Detalhes sobre o desenvolvimento e funcionamento dessas técnicas são muito bem explicados e discutidos na literatura. Livros como os de Burkov (2019), Haykin (1999, 2009), Mitchell (1997) e Silva, Spatti e Flauzino (2016) são alguns exemplos relevantes para estudo.

Ao revisar a literatura, até o momento (2021), foram encontrados dois trabalhos relacionando o uso de modelo processual e RNA. Shoemaker e Cropper (2010) usaram redes neurais artificiais para prever os valores do índice de área foliar em plantios de pinus, que em seguida foram inseridos como entrada em um modelo processual (SPM-2) para quantificar troca líquida de carbono no ecossistema. Os autores ressaltaram que o uso da RNA melhorou significativamente as previsões de A_f em relação aos modelos de regressão múltipla. Nesse trabalho os autores usaram uma RNA do tipo *Multilayer Perceptron*, com duas camadas intermediárias, treinada com o algoritmo de aprendizado *Backpropagation*.

Ashraf *et al.* (2015) desenvolveram um modelo de crescimento e de produção florestal para prever incrementos em área basal e em volume individual de árvores a partir do clima atual ou em cenários futuros de mudanças climáticas. Para a construção do modelo de RNA os autores usaram dados históricos de parcelas permanentes, para representar o clima atual, e usaram um modelo processual (JABOWA-3) para projetar o crescimento das árvores em função dos cenários de mudanças climáticas. Os autores testaram redes com uma camada intermediária, e a rede de melhor desempenho correspondeu a 13 variáveis de entrada, 8 neurônios na camada intermediária e uma saída, para incremento em área basal e em volume. As variáveis de entrada corresponderam a dados de inventário florestal, radiação solar incidente, graus-dia e índices de fertilidade e de umidade do solo. As redes apresentaram bom desempenho para prever as duas variáveis, tanto em condições de clima atual quanto em projeções de mudanças climáticas.

Apesar do pequeno número de estudos com essa abordagem, a maior parte dos trabalhos com RNA envolvem aproximações de funções, o que corresponde justamente a parte que desejamos avaliar no modelo processual. Nessa parte, são usadas regressões simples e que não envolvem todas as variáveis necessárias para gerar previsões mais acuradas, visando principalmente o seu uso para manejo florestal. Este fato, aliado ao processo de determinação de parâmetros de um

modelo processual, foi o que motivaram a avaliação das possibilidades de uso dessas técnicas e possíveis ganhos com o uso do aprendizado de máquina junto ao modelo processual. No nosso caso, optamos pelo modelo 3-PG por ser o mais comumente utilizado.

3 DESCRIÇÃO DO MODELO 3-PG

A sigla 3-PG significa *Physiological Principles Predicting Growth* (Princípios Fisiológicos para Predizer o Crescimento), trata-se de um modelo processual que calcula e distribui a biomassa (matéria seca) de uma floresta entre os compartimentos raiz, folha e fuste por hectare (LANDSBERG; WARING, 1997). O resultado da simulação do crescimento da floresta é proveniente das mudanças no padrão de alocação e na quantidade de biomassa produzida pelas árvores em resposta aos elementos e fatores climáticos, idade, estratégias de manejo e estágio reprodutivo da planta (ALMEIDA; SANDS, 2016; LANDSBERG; SANDS, 2011).

As condições do ambiente em que uma floresta se desenvolve variam continuamente, fazendo com que seja necessário a representação dos processos de forma dinâmica no tempo e no espaço. O modelo 3-PG roda em passos mensais, por isso as informações de clima devem ser fornecidas nessa escala, outras informações de entrada do modelo são referentes a sítio, dados para inicialização, parâmetros e eventos silviculturais (SANDS, 2004) (Tabela 4).

Tabela 4 - Dados de entrada para o 3-PG.

(Continua)

Dados de entrada	Informações
Clima	<ul style="list-style-type: none"> • <u>Médias mensais:</u> <ul style="list-style-type: none"> ○ Temperaturas (mínima e máxima) ○ Radiação solar total diária ○ Déficit de pressão de vapor (pode ser calculado em função da temperatura) • <u>Total mensal:</u> <ul style="list-style-type: none"> ○ Precipitação pluviométrica ○ Dias com geada
Sítio	<ul style="list-style-type: none"> • Latitude • Classe de solo • Taxa de fertilidade • Máximo de água disponível no solo • Mínimo de água disponível no solo
Inicialização	<ul style="list-style-type: none"> • Mês e ano de plantio • Estoque • Quantidade inicial de água disponível no solo • Idade final do plantio • Gás carbônico atmosférico (CO₂) • Biomassa inicial dos compartimentos: <ul style="list-style-type: none"> ○ Biomassa por compartimento na idade inicial, ○ Biomassa total na idade inicial ou ○ Biomassa das mudas no plantio

Tabela 4 - Dados de entrada para o 3-PG.

(Conclusão)

Dados de entrada	Informações
Parâmetros	<ul style="list-style-type: none"> • São 63 parâmetros referentes a: <ul style="list-style-type: none"> ○ Partição de biomassa e rotatividade de raízes ○ Modificadores do crescimento ○ Mortalidade e auto-desbaste ○ Estrutura e processos do dossel ○ Propriedades da madeira e do povoamento ○ Fatores de conversão
Eventos silviculturais (opcional)	<ul style="list-style-type: none"> • Fertilidade • Irrigação • Desbaste • Desrama

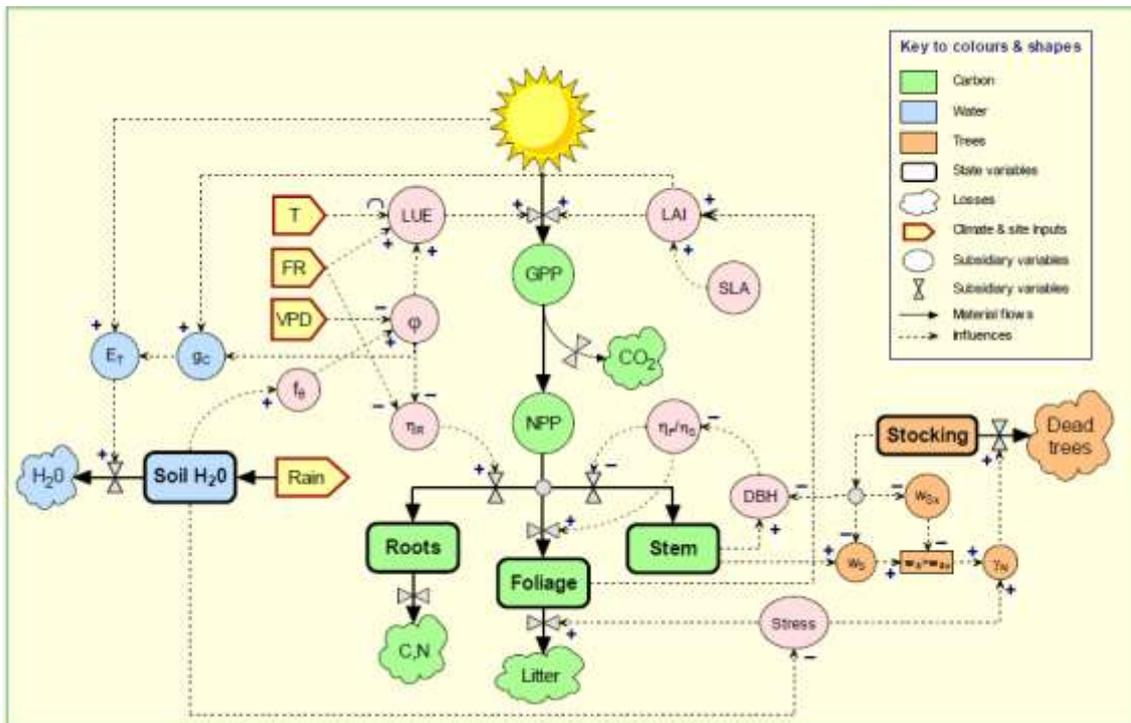
Fonte: Elaborado pela autora.

Todas essas informações são utilizadas em uma sequência de cálculos, codificados originalmente para interface em planilha do software *Excel*, na linguagem *Visual Basic for Applications* (VBA) (SANDS, 2004) e foi recentemente implementado em linguagem R pelo pacote r3PG, mais detalhes podem ser encontrados no site <https://cran.r-project.org/web/packages/r3PG/vignettes/r3PG-ReferenceManual.html> (TROTTSIUK; HARTIG; FORRESTER, 2020).

O *download* do modelo pode ser realizado pelo site <https://3pg.forestry.ubc.ca/software/> onde também se encontram informações sobre as versões 3-PGS e 3-PGmix, além de referências das principais pesquisas com o modelo e materiais de um curso prático.

É possível realizar diferentes tipos de processamento com o 3-PG, para um ou múltiplos sítios, de forma simultânea ou sequencial, e análise de sensibilidade do modelo (SANDS, 2004). O processamento é baseado no princípio da eficiência do uso da luz, resultante da interação entre os diferentes fatores do ambiente, que orienta a quantidade de biomassa a ser produzida e a sua alocação (FEIKEMA *et al.*, 2010). O 3-PG é composto por cinco submodelos: produção de biomassa, balanço hídrico do solo, mortalidade, alocação de biomassa e cálculos dendrométricos (Figura 6).

Figura 6 - Estrutura básica do modelo 3-PG. Os símbolos usados representam a produção primária bruta (GPP), produção primária líquida (NPP), taxa de fertilidade do solo (FR), temperatura (T), déficit de pressão de vapor (VPD), evapotranspiração (ET), condutância do dossel (g_c), biomassa do caule incluindo galhos e casca (W_S), biomassa máxima do fuste por árvore para 1000 árvores por ha (w_{Sx}), taxa de mortalidade (γ_N), índice de área foliar (LAI), área foliar específica (SLA), eficiência de uso da luz (LUE), modificador fisiológico da condutância do dossel (ϕ), modificador da água do solo (f_θ), fração de NPP alocada às raízes (η_R) e proporção da fração de NPP alocada para as folhas em relação ao fuste (η_F / η_S).



Fonte: Sands (2004).

A partir da radiação solar global (R_s) ($\text{MJ m}^{-2} \text{ dia}^{-1}$), o modelo estima a radiação fotossinteticamente ativa (RFA), aproximadamente 50% de R_s (1) e a radiação fotossinteticamente ativa que foi absorvida pelo dossel (RFAA), considerando a atenuação da luz ao atravessá-lo e o índice de área foliar (A_f), de acordo com a lei de Beer (2) (Figura 7 a).

$$RFA = R_s 0,5 \quad (1)$$

$$RFAA = RFA(1 - e^{-kA_f}) \quad (2)$$

em que: k = Coeficiente de extinção da luz para absorção de RFA pelo dossel.

A proporção de RFAA utilizada para a produção primária bruta (PPB) depende das condições do ambiente, incorporadas ao modelo como modificadores do crescimento (f_i), que assumem valores entre 0 e 1, quanto mais próximo de 1 menor é a restrição do fator ao crescimento (Figura 7a). Os fatores considerados são: temperatura do ar (3), idade (4), fertilidade do solo (5), geada (6), água disponível no solo (7), déficit de pressão de vapor (8) e concentração de gás carbônico na atmosfera (CO₂) (9).

$$f_T(T_a) = \left(\frac{T_a - T_{\min}}{T_{opt} - T_{\min}} \right) \left(\frac{T_{\max} - T_a}{T_{\max} - T_{opt}} \right)^{\frac{T_{\max} - T_{opt}}{T_{opt} - T_{\min}}} \quad (3)$$

em que: f_T = modificador dependente da temperatura; T_a ; T_{\min} ; T_{\max} e T_{opt} = temperaturas média, mínima, máxima e ótima (°C).

$$f_{age}(t) = \frac{1}{1 + \left[\frac{(t/t_x)}{r_{age}} \right]^{n_{age}}} \quad (4)$$

em que: f_{age} = modificador dependente da idade; t e t_x = idades atual e máxima (anos); r_{age} = idade relativa em que $f_{age} = 0,5$; n_{age} = potência da idade relativa.

$$f_N(FR) = 1 - (1 - f_{N0})(1 - FR)^{n_{FN}} \quad (5)$$

em que: f_N = modificador dependente da nutrição do solo; FR = taxa de fertilidade; f_{N0} = valor de f_N quando $FR = 0$; n_{FN} = potência de $(1 - FR)$ em f_N .

$$f_F(d_F) = 1 - k_F \left(\frac{d_F}{30} \right) \quad (6)$$

em que: f_F = modificador dependente da geada; d_F = média mensal do número de dias com geada; k_F = número de dias de produção perdidos para cada dia de geada.

$$f_{\theta}(\theta_s) = \frac{1}{1 + \left[\frac{1 - (\theta_{sn} / \theta_{sx})}{c_{\theta}} \right]^{n_{\theta}}} \quad (7)$$

em que: f_{θ} = modificador dependente da água disponível no solo; θ_s = quantidade de água disponível no solo (mm); θ_{sn} e θ_{sx} = quantidades mínima e máxima de água disponível no solo (mm); c_{θ} = taxa do déficit de umidade que corresponde a $f_{\theta} = 0,5$; n_{θ} = potência do déficit da taxa de umidade em f_{θ} .

$$f_D(DPV) = e^{-k_D DPV} \quad (8)$$

em que: f_D = modificador dependente do déficit de pressão de vapor; DPV = déficit de pressão de vapor (mbar⁻¹); k_D = resposta estomática ao DPV (mbar⁻¹).

$$\begin{aligned} f_{C_a}(C_a) &= \frac{f_{C_{ax}} C_a}{350(f_{C_{ax}} - 1) + C_a} & f_{C_g}(C_a) &= \frac{f_{C_{g0}}}{1 + (f_{C_{g0}} - 1) C_a / 350} \\ f_{C_{ax}} &= \frac{f_{C_{ax700}}}{2 - f_{C_{ax700}}} & f_{C_{g0}} &= \frac{f_{g_{x700}}}{2f_{g_{x700}} - 1} \end{aligned} \quad (9)$$

em que: f_{C_a} e f_{C_g} = modificadores dependentes do efeito da concentração de CO₂ sobre a eficiência quântica do dossel e sobre a condutância do dossel; C_a = concentração atmosférica de CO₂ (ppm); $f_{C_{ax}}$ = valor do modificador da eficiência quântica do dossel quando C_a é máximo; $f_{C_{ax700}}$ = valor do modificador da eficiência quântica do dossel quando $C_a = 700$ ppm; $f_{C_{g0}}$ = valor do modificador da condutância do dossel quando $C_a = 0$; $f_{C_{g700}}$ = valor do modificador da condutância do dossel quando $C_a = 700$ ppm.

Os modificadores dependentes da idade, água no solo e déficit de pressão de vapor, compõem o modificador fisiológico da condutância do dossel (φ), pois afetam a fotossíntese diretamente, utilizando o menor valor entre f_D e f_{θ} , aquele que for mais limitante (10). Em seguida, os modificadores são multiplicados pela

eficiência quântica máxima do dossel (α_{Cx}) (mol mol⁻¹) para calcular a eficiência quântica do dossel (α_C) (mol mol⁻¹), que simboliza a quantidade de CO₂ fixado por energia radiante absorvida, após descontar o efeito dos modificadores do crescimento (11). O produto entre α_C e RFAA equivale à produção primária bruta (PPB) (Mg ha⁻¹) (12), que ao descontar a respiração, definida por um valor constante (Y), gera a produção primária líquida (PPL) (Mg ha⁻¹) (13 e 14) (Figura 7 a).

$$\varphi = f_{age} \min \{f_D, f_\theta\} \quad (10)$$

$$\alpha_C = \alpha_{Cx} f_T f_N f_F f_C \alpha \varphi \quad (11)$$

$$PPB = \alpha_C RFAA \quad (12)$$

$$PPL = PPBY \quad (13)$$

A PPL também pode ser escrita da seguinte forma:

$$PPL = 0,552 \alpha_C Y (1 - e^{-k_A r / \zeta}) \zeta \bar{Q} \Delta t \quad (14)$$

em que: 0,552 converte a radiação solar em RFA e a produção de biomassa de g m⁻² para Mg ha⁻¹; ζ = fração do solo coberta pelo dossel; \bar{Q} = média diária da radiação solar acima do dossel no período Δt .

Ao obter a produção total em determinado período, é feita a alocação da biomassa entre os compartimentos raiz, folha e fuste, por meio do cálculo de proporções das biomassas a serem alocadas para cada compartimento (Figura 7a). O processo de alocação se inicia pelas raízes, definido em função da fertilidade do solo (FR) e do modificador fisiológico (φ) (15) e (16), respectivamente. O modelo aumenta a quantidade de biomassa alocada para as raízes quanto mais restritas forem as condições hídricas e de nutrição do solo.

$$m = m_0 + (1 - m_0) FR \quad (15)$$

$$\eta_R = \frac{\eta_{Rx} \eta_{Rn}}{\eta_{Rn} + (\eta_{Rx} - \eta_{Rn}) m \varphi} \quad (16)$$

em que: m = efeito da fertilidade na taxa de alocação para as raízes; m_0 = valor de m quando a fertilidade do solo é muito baixa ($FR = 0$); η_R = proporção da biomassa a ser alocada para as raízes; η_{Rn} e η_{Rx} = proporções mínima e máxima de η_R .

Em seguida o modelo calcula a alocação da biomassa para a parte aérea (fuste e folhas) a partir da fração de alocação folha/fuste (p_{FS}) de acordo com o diâmetro médio à 1,30 m de altura (D) (17), essa fração é então usada para calcular as proporções a serem alocadas para fuste e folhas (18) (Figura 7 a).

$$n_p = \frac{\ln(p_{20}/p_2)}{\ln(20/2)}; \quad a_p = \frac{p_2}{n_p}; \quad p_{FS} = a_p D^{n_p} \quad (17)$$

$$\eta_S = \frac{1-\eta_R}{1+p_{FS}}; \quad \eta_F = p_{FS}\eta_S \quad (18)$$

em que: n_p e a_p = parâmetros na função alométrica do p_{FS} ; $p_{20} = p_{FS}$ para árvores com $D = 20$ cm; $p_2 = p_{FS}$ para árvores com $D = 2$ cm; η_S = proporção de biomassa a ser alocada para o fuste; η_F = proporção de biomassa a ser alocada para as folhas; \ln = logaritmo neperiano.

O total alocado para cada compartimento é obtido após descontar as perdas de biomassa devido à queda das folhas (serapilheira) (19), rotatividade de raízes e mortalidade. A rotatividade de raízes é definida por uma taxa constante (γ_R) e a mortalidade pode ser calculada de forma dependente da densidade, pela lei do auto-desbaste (20, 21 e 22), ou independente da densidade (23) (Figura 7 c).

$$\gamma_F(t) = \frac{\gamma_{F1}\gamma_{F0}}{\gamma_{F0} + (\gamma_{F1} - \gamma_{F0})e^{-(t/t_{\gamma F})\ln(1+\gamma_{F1}/\gamma_{F0})}} \quad (19)$$

em que: $\gamma_F(t)$ = taxa de serapilheira na idade t ; γ_{F0} e γ_{F1} = taxas de serapilheira em idades jovem e adulta; $t_{\gamma F}$ = idade na qual a taxa de serapilheira é igual a $\frac{1}{2}(\gamma_{F0} + \gamma_{F1})$ (meses).

$$w_{Sx} = w_{Sx1000} (1000 / N)^{n_N} \quad (20)$$

$$W_{Sx}^+ = W_S - m_s (N - N^+) \frac{W_S}{N} \quad (21)$$

$$\frac{W_S^+}{N^+} \leq w_{Sx1000} (1000 / N^+)^{n_N} 10^{-3} \quad (22)$$

em que: w_{Sx} = biomassa máxima permitida para o fuste (kg árvore^{-1}); w_{Sx1000} = valor de w_{Sx} para 1000 árvores por hectare (kg árvore^{-1}); N = número de fustes por hectare; n_N = potência na lei de auto-desbaste; W_{Sx}^+ = biomassa do fuste após auto-desbaste; W_S = biomassa de fuste; m_s = fração de biomassa de fuste perdida por árvore morta; N^+ = número de fustes após o auto-desbaste.

$$\begin{aligned} \gamma_N &= \gamma_{N1} + (\gamma_{N0} - \gamma_{N1}) e^{-\ln(2)(t/t_{\gamma N})^{n_{\gamma N}}} \\ \Delta N &= -\gamma_N N \Delta t \end{aligned} \quad (23)$$

em que: γ_N = taxa de mortalidade; γ_{N0} e γ_{N1} = taxas de mortalidade em idades jovem e adulta; $t_{\gamma N}$ = idade na qual a mortalidade é igual a $1/2(\gamma_{N0} + \gamma_{N1})$ (meses); $n_{\gamma N}$ = potência de forma; ΔN = número de árvores mortas; $N \Delta t$ = número de árvores no período t .

Dessa forma, o balanço de carbono em cada compartimento, no período Δt , será dado por (24), (25) e (26).

$$\Delta W_F = \eta_F PPL - \gamma_F W_F \Delta t - m_F (W_F / N) \Delta N \quad (24)$$

$$\Delta W_R = \eta_R PPL - \gamma_R W_R \Delta t - m_R (W_R / N) \Delta N \quad (25)$$

$$\Delta W_S = \eta_S PPL - m_S (W_S / N) \Delta N \quad (26)$$

em que: ΔW_F ; ΔW_R e ΔW_S = biomassas de folha, raiz e fuste produzidas no período Δt (Mg ha^{-1}); W_F ; W_R e W_S = biomassas de folha, raiz e fuste acumuladas até o

período t (Mg ha^{-1}); m_F ; m_R e m_S = frações de folha, raiz e fuste perdidas por cada árvore morta.

O submodelo de cálculos dendrométricos considera as variáveis D e número de árvores por unidade de área (N) para calcular a área basal (G), altura total (H) e volume do povoamento sem casca (V_S). O D é calculado a partir da biomassa média de fuste (27) seguido pelos cálculos de área basal (28), altura total (29) e volume do povoamento. O volume pode ser calculado em função da densidade básica da madeira (30) ou por um modelo alométrico em função do D e do número de fustes por ha (31), e por fim gera-se o incremento médio anual e o incremento corrente mensal (I_m e I_{cm}) (32 e 33) (Figura 7 a).

$$D = \left(\frac{w_s}{a_s} \right)^{n_s} \quad (27)$$

$$G = \pi \left(\frac{D}{200} \right)^2 N \quad (28)$$

$$H = a_H D^{n_{HB}} N^{n_{HN}} + \varepsilon \quad (29)$$

$$V_s = \frac{W_s (1 - p_{BB})}{\rho} \quad (30)$$

$$V_s = a_V D^{n_{VB}} N^{n_{VN}} + \varepsilon \quad (31)$$

$$I_m = \frac{V_s}{t_i} \quad (32)$$

$$I_{cm} = V_{s(i)} - V_{s(i-1)} \quad (33)$$

em que: D = diâmetro médio à 1,30 m (cm); w_s = biomassa média de fuste (kg árvore^{-1}); a_s e n_s = parâmetros da relação alométrica do D ; p_{BB} = fração de biomassa alocada para galho e casca; W_s = biomassa de fuste (Mg ha^{-1}); ρ = densidade básica da madeira (t m^{-3}); a_H ; n_{HB} e n_{HN} = parâmetros da relação alométrica da altura; a_V ; n_{VB} e n_{VN} = parâmetros da relação alométrica do volume; I_m = Incremento médio anual ($\text{m}^3 \text{ ha}^{-1} \text{ ano}$); V_s = volume do povoamento sem casca ($\text{m}^3 \text{ ha}^{-1}$); I_{cm} = incremento corrente mensal ($\text{m}^3 \text{ ha}^{-1} \text{ mês}^{-1}$); $V_{s(i)}$ = volume no período atual ($\text{m}^3 \text{ ha}^{-1}$);

$V_{S(i-1)}$ = volume no período anterior ($\text{m}^3 \text{ha}^{-1}$); t_i = idade do povoamento no período i (anos); ε = erro aleatório.

O balanço de água no solo é calculado pela diferença entre a precipitação pluviométrica mais irrigação, quando houver, e evapotranspiração (34). A precipitação pluviométrica considera a quantidade de chuva interceptada pelo dossel, que varia em função do A_f (35), e a evapotranspiração é calculada pela equação de Penman-Monteith (36) que depende da condutância do dossel (37) e também varia conforme o A_f (Figura 7 b).

$$\Delta\theta_s = (1 - i_R)R_p + R_i - ET \quad (34)$$

$$i_R = i_{Rx} \min\{1, A_f / L_{ix}\} \quad (35)$$

$$ET = \frac{g_C(\varepsilon(R_n - G) + \lambda\rho_{ar}D_u g_B)}{(\varepsilon + 1)g_C + g_B} \quad (36)$$

$$g_C = g_{Cx} \varphi \min\{1, A_f / L_{Cx}\} \quad (37)$$

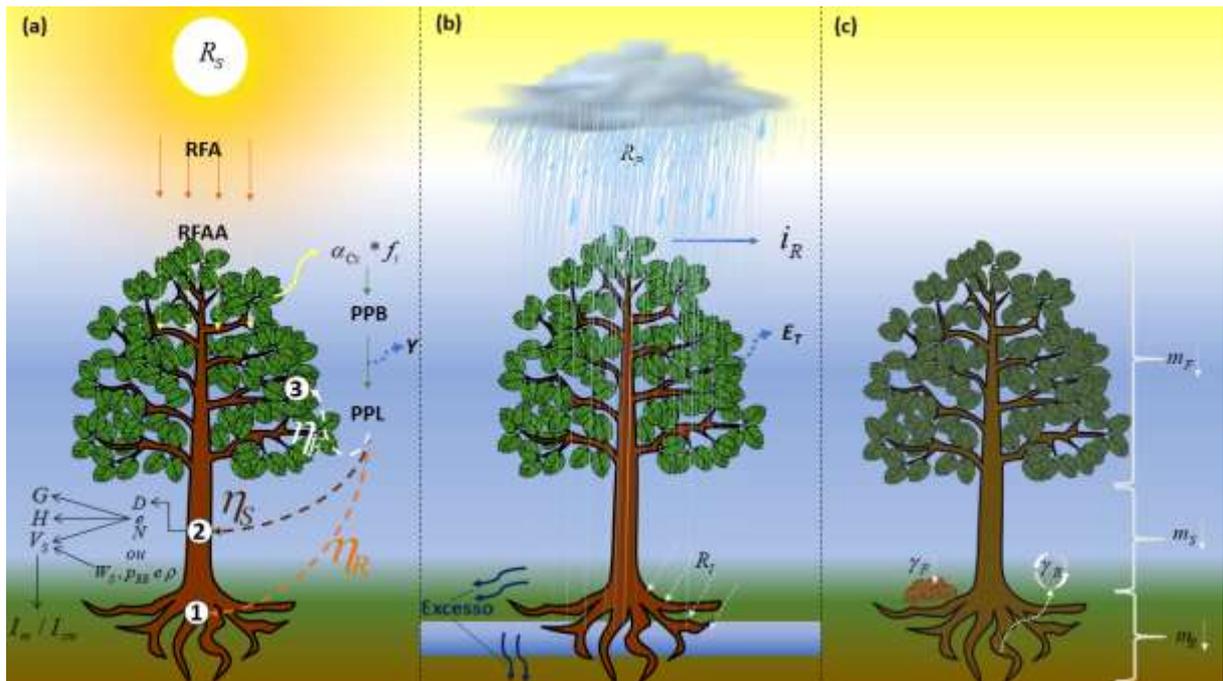
em que: i_R = fração da chuva interceptada pelo dossel e evaporada pelo dossel; i_{Rx} = fração máxima da chuva interceptada pelo dossel; L_{ix} = índice de área foliar na qual a interceptação da chuva é máxima; $\Delta\theta_s$ = balanço de água no solo; R_p = precipitação pluviométrica (mm m^{-1}); R_i = irrigação (mm m^{-1}); ET = evapotranspiração (mm m^{-1}); g_C = condutância do dossel (m s^{-1}); g_{Cx} = condutância máxima do dossel (m s^{-1}); L_{Cx} = índice de área foliar correspondente à condutância máxima do dossel; ε = é a taxa adimensional de mudança da pressão de vapor saturado em relação a inclinação da curva de pressão de vapor saturado dividido pela constante psicrométrica; R_n = radiação líquida; G = fluxo de calor do solo (é muito pequeno em relação à R_n para uma escala mensal, por isso é negligenciado); λ = calor latente de vaporização (J kg^{-1}); ρ_{ar} = densidade do ar (kg m^{-3}); D_u = déficit de umidade específica do ar do dossel ($\text{g de H}_2\text{O (g de ar)}^{-1}$); g_B = condutância na camada limítrofe do dossel (m s^{-1}).

As variáveis área foliar específica (σ), fração de biomassa para galhos e casca (p_{BB}), taxa de mortalidade independente da densidade (citada acima) e densidade básica da madeira (ρ) são calculadas por uma mesma função, em que se considera apenas a variação em função da idade, dada por (38).

$$f(t; f_0; f_1; t_f; n) = f_1 + (f_0 - f_1)e^{-(\ln 2)(t/t_f)^n} \quad (38)$$

em que: f_0 e f_1 = variável em idades jovem e adulta; t_f = idade na qual a variável é igual a $1/2(f_0 + f_1)$ (meses); t = idade (meses); n = potência de forma.

Figura 7 - Resumo do modelo 3-PG com a representação dos cinco submodelos: produção e alocação de biomassa (1 – raízes, 2 – fuste e 3 – folhas) e cálculos dendrométricos (a); balanço de água no solo (b) e mortalidade (junto com a produção de serapilheira e rotatividade de raízes) (c).



Nota: Todos os símbolos do modelo 3-PG foram padronizados, em toda a tese, conforme Sands (2010).

Fonte: Elaborada pela autora.

O período total de processamento é definido pelo usuário do modelo e as saídas são mensais e/ou anuais, saídas em idades específicas também podem ser definidas e o usuário pode selecionar as saídas de interesse entre informações sobre atributos do sítio e de manejo, fatores climáticos, atributos do povoamento, atributos do dossel, compartimentos de biomassa, modificadores do crescimento,

produção e alocação de biomassa e mortalidade. Mais detalhes podem ser encontrados em Landsberg e Sands (2011), Landsberg e Waring (1997), Sands (2004) e Sands e Landsberg (2002), ou no site informado inicialmente.

Em resumo, o modelo 3-PG, na sua versão padrão, simula o crescimento da floresta a partir da radiação absorvida pelas folhas, de acordo com o tamanho do sistema fotossintético (índice de área foliar) e com as condições do ambiente, que determinam a eficiência com que essa radiação será utilizada. Paralelo a isso, é feito o balanço de água no solo e a cada período são descontadas as biomassas de folha, fuste e raízes devido à mortalidade, serapilheira e a rotatividade de raízes.

Por fim, o modelo também estima as variáveis dendrométricas D médio, altura total, área basal, volume do povoamento, I_m e I_{cm} . O efeito de atividades silviculturais é opcional. Pode-se dizer que o modelo “enxerga” a floresta como um conjunto de unidades homogêneas, sem considerar subdivisões na profundidade de copa, partindo sempre de uma árvore média e extrapolando para todo o estoque sobrevivente.

Para melhor compreensão sobre o funcionamento do modelo 3-PG, um exemplo numérico simples foi desenvolvido (Figura 8). A configuração inicial encontra-se na Tabela 5, foi considerada a parametrização de Borges (2009) (Tabela 6).

Tabela 5 – Dados de inicialização usados para a explicação do funcionamento do modelo 3-PG.

Dados para inicialização			
Idade inicial (anos)	0,25	Quantidade mínima de água no solo (mm)	0
Idade final (anos)	7*	Quantidade máxima de água no solo (mm)	150
Estoque inicial (árvores ha ⁻¹)	1111	Quantidade inicial de água no solo (mm)	150
Biomassa inicial de folhas (Mg ha ⁻¹)	0,168	Classe de solo	SL
Biomassa inicial de raízes (Mg ha ⁻¹)	0,106	Taxa de fertilidade	0,8
Biomassa inicial de fustes (Mg ha ⁻¹)	0,099	CO ₂ atmosférico (ppm)	350

* O exemplo numérico refere-se apenas ao primeiro *loop* do modelo, de 0,25 a 0,33 anos.

SL = *Sandy Loam* (Areno-siltoso)

Fonte: Elaborada pela autora.

Considere que o plantio foi realizado em janeiro. Como o modelo foi inicializado aos 3 meses (0,25 anos), os dados climáticos desse período são do mês de abril (destacado em vermelho no quadro de dados climáticos do fluxograma).

Para o mês de abril, já foi fornecido ao modelo os valores de biomassa dos compartimentos raiz, folha e fuste. Então, o primeiro *loop* do modelo usa essas informações para chegar às biomassas da próxima idade (4 meses – 0,33 anos) no mês de maio, destacado em vermelho no quadro com os dados climáticos. Ou seja, os resultados destacados no fluxograma são referentes a idade de 0,33 anos.

Iniciando o raciocínio a partir da figura do sol, que representa a radiação solar global (R_s), temos o cálculo da radiação fotossinteticamente ativa absorvida (RFAA). A RFAA depende da cobertura do dossel e da fração de radiação solar interceptada. Observe que a cobertura do dossel depende da idade anterior (0,25 anos) em relação a idade de fechamento do dossel (2 anos). A cobertura do dossel (0,13) é usada no cálculo da fração de radiação solar interceptada pelo dossel, junto com o índice de área foliar (A_f), conforme a lei de Beer (0,584). O produto entre a R_s , no mês de maio (multiplicado pelos 31 dias do mês), a cobertura do dossel e a fração de radiação solar interceptada gera a RFAA ($42,5 \text{ MJ m}^{-2}$). A_f é calculada em função da área foliar específica (σ) e da biomassa foliar, que no primeiro *loop* é a biomassa inicial de folhas. A área foliar específica depende da idade e de um limite mínimo e máximo dessa variável.

Em seguida, para calcular a produção primária bruta (PBB), a RFAA é multiplicada pela eficiência quântica do dossel (α_c). Para encontrar α_c , é necessário realizar o cálculo dos modificadores do crescimento (f_i). Esses cálculos dependem dos dados climáticos do mês de maio, da taxa de fertilidade informada inicialmente ($FR = 0,8$), das quantidades de água disponível no solo (ASW), do período anterior, nesse caso a quantidade inicial (150 mm), e também da quantidade máxima de ASW e da concentração de CO_2 na atmosfera (350 ppm). Ao multiplicar os modificadores pela eficiência quântica máxima do dossel ($\alpha_{c_x} = 0,08 \text{ mol mol}^{-1}$) é encontrado α_c no período atual, de acordo com as condições do ambiente (0,053 mols de carbono por mol de RFA absorvida). Enfim, PBB é calculado pelo produto entre α_c , convertido para g de C por MJ de RFA absorvida ($2,925 \text{ g MJ}^{-1}$) e RFAA, totalizando $1,243 \text{ Mg ha}^{-1}$. Repare que o produto é dividido por 100 para converter g m^{-2} em Mg ha^{-1} .

Ao descontar a respiração, chega-se a produção primária líquida (PPL). No caso do 3-PG, considera-se um valor constante, Borges (2009) adotou 0,5, totalizando $0,622 \text{ Mg ha}^{-1}$. A PPL é alocada primeiramente para as raízes e depende do modificador fisiológico (ϕ) e da FR (representada por m). É também necessário

informar um intervalo máximo e mínimo de biomassa a ser alocada para as raízes. Já a biomassa alocada para a parte aérea, depende do tamanho da árvore (diâmetro médio a 1,30 m de altura - D), que depende da biomassa média de fuste (kg árvore^{-1}). Para encontrar o valor da fração de biomassa entre folhas e fuste (p_{FS}) aos 0,33 anos, é usado o D médio do período anterior (1,62 cm), no caso do primeiro *loop*, é usada a biomassa inicial de fuste e o estoque inicial informado para encontrar D aos 0,25 anos. No cálculo da p_{FS} , utiliza-se uma relação exponencial simples, em que os parâmetros a_p e n_p são calculados em função das frações folha/fuste (p_{FS}) para árvores com $D = 20$ cm e $D = 2$ cm. A p_{FS} (2,05) é então usada no cálculo da fração de biomassa a ser alocada para o fuste (0,28). O restante é alocado para as folhas (0,57).

Ao multiplicar essas frações por PPL, chega-se à biomassa de cada compartimento. Porém, observe que foram descontadas as perdas de biomassa de raízes por *turnover* e de biomassa de folhas pela produção de serapilheira. Em casos onde ocorre mortalidade, são também subtraídas uma proporção de biomassa perdida em cada compartimento. A soma entre a biomassa final produzida, no período atual, e a biomassa do período anterior, nesse caso as biomassas iniciais, gera o valor atualizado das biomassas de raiz, fuste e folhas na idade de 0,33 anos.

O submodelo de mortalidade não foi representado no fluxograma, mas o valor de N , usado no cálculo da biomassa média de fuste, a partir do segundo período de processamento (0,33 anos), está sujeito à taxa de mortalidade, para esses dados o valor de N foi constante até os 7 anos. Essa biomassa média de fuste ($0,25 \text{ kg árvore}^{-1}$) é usada para calcular o D médio aos 0,33 anos, que em sequência é utilizado como variável independente no cálculo da área basal, altura total e volume. Para o cálculo do volume, existe a opção de fornecer parâmetros de uma relação alométrica em função de D ou é feito o cálculo a partir da densidade básica da madeira, descontando a fração de galhos e casca. Sands (2004) recomenda que se dê preferência ao modelo alométrico em relação ao cálculo com o uso da densidade básica da madeira, pois esta não considera efeitos do sítio, apenas da idade.

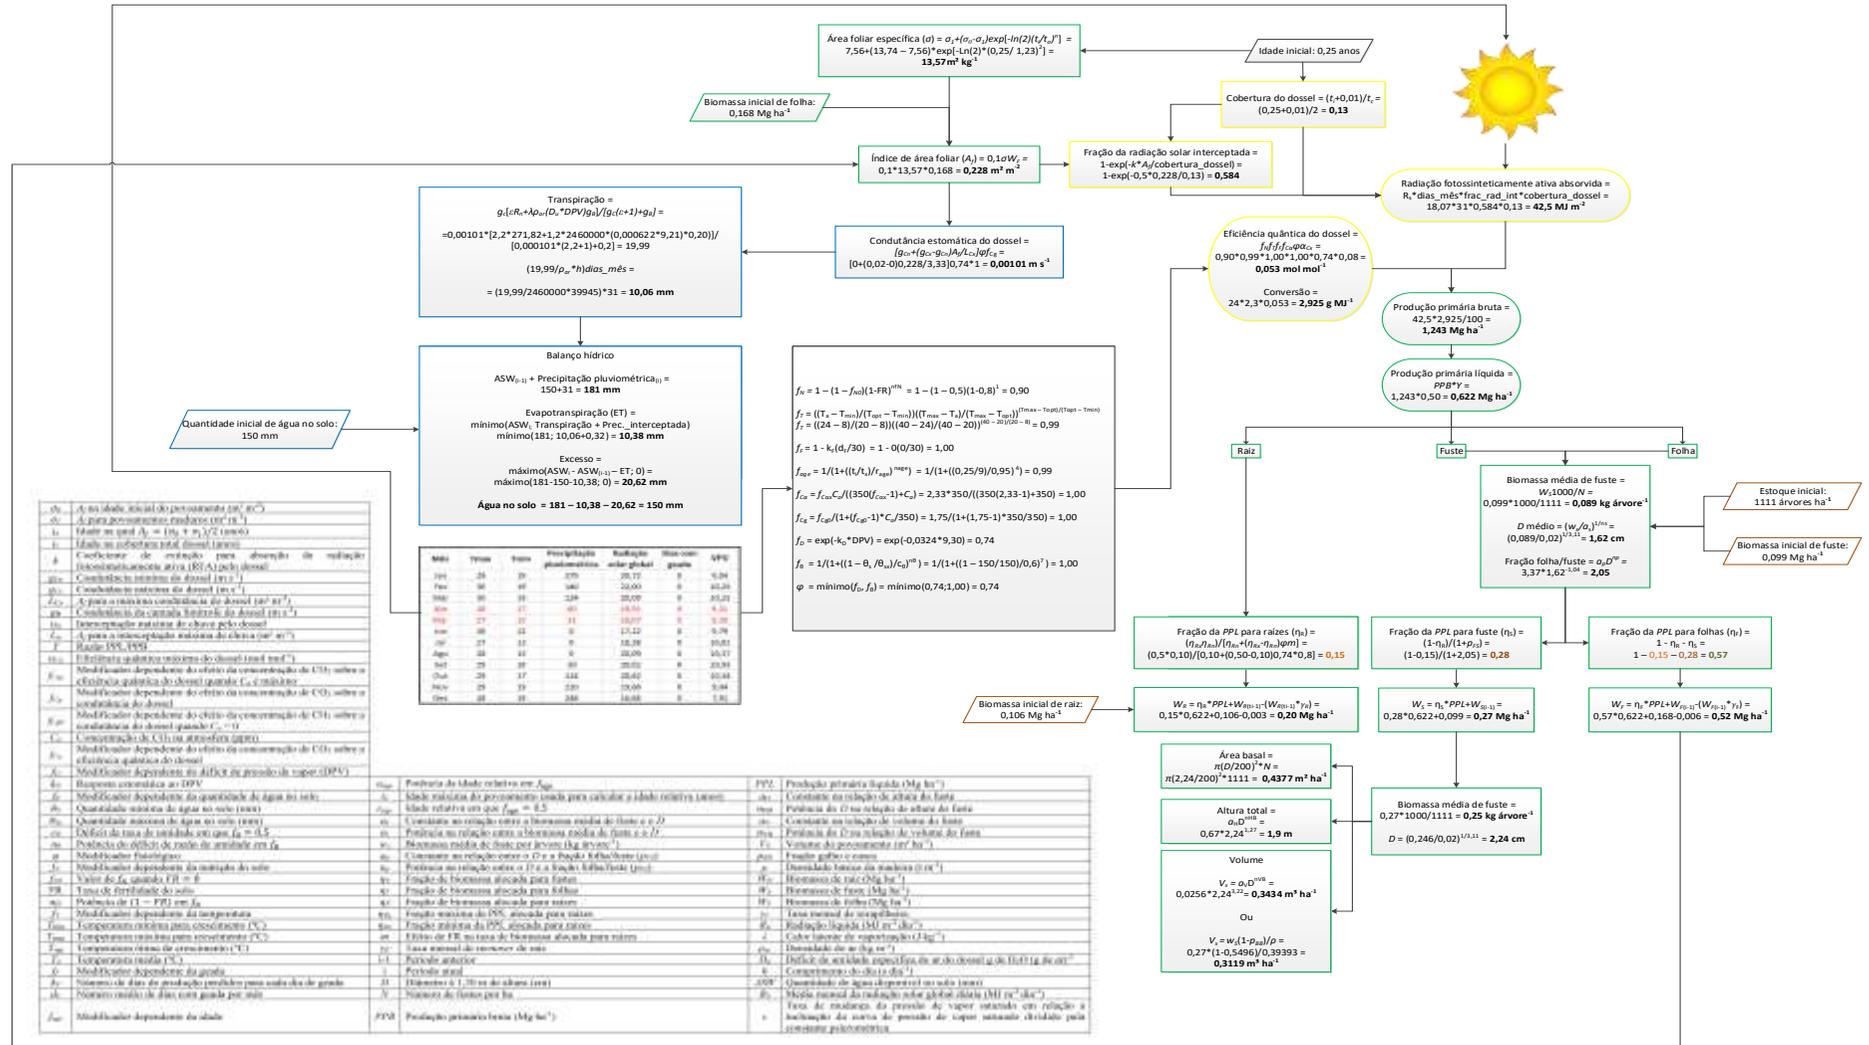
A biomassa de folha produzida ($0,52 \text{ Mg ha}^{-1}$) é usada no cálculo do A_f aos 0,33 anos, que será usado na relação de Beer para gerar a fração de R_s interceptada no próximo período.

Para realizar o balanço hídrico é necessário descontar a quantidade de água perdida por transpiração e por evaporação. O cálculo da transpiração depende da

condutância estomática do dossel, calculada em função do A_f (do período anterior – $0,228 \text{ m}^2 \text{ m}^{-2}$), do valor do A_f para a máxima condutância do dossel ($3,33 \text{ m}^2 \text{ m}^{-2}$), do intervalo mínimo e máximo para a condutância do dossel e dos modificadores fisiológico e da condutância do dossel. A transpiração é então calculada conforme a equação de Penman-Monteith.

A quantidade de água, já presente no solo, no caso do primeiro *loop* a quantidade inicial de água disponível no solo, é somada a quantidade de chuva do mês de maio. A evapotranspiração considera o mínimo valor entre a quantidade de água disponível no solo e a soma da transpiração com a quantidade de chuva interceptada pelo dossel. O total de água disponível no solo (181 mm) menos a quantidade de água presente no período anterior, menos a perda por evapotranspiração não pode ultrapassar o valor máximo de água disponível no solo, informado inicialmente. Caso isso aconteça, a quantidade acima do máximo será considerada como excesso, perdido por escoamento superficial ou por percolação profunda. A quantidade final de água no solo aos 0,33 anos, será então a diferença entre o total nesse período (181 mm), menos a evapotranspiração (10,38 mm), menos o excesso (20,62 mm). Esse valor (150 mm) será a referência no próximo período, para o cálculo do f_{θ} , e é o que será somado à precipitação pluviométrica do próximo mês. Caso ocorra irrigação, deve-se adicioná-la junto a precipitação pluviométrica.

Figura 8 – Fluxograma com exemplo numérico simples do funcionamento do modelo 3-PG (loop inicial: 0,25 a 0,33 anos). Alguns cálculos não foram apresentados explicitamente e o submodelo de mortalidade não está representado.



Fonte: Elaborada pela autora.

Tabela 6 – Parâmetros usados no exemplo numérico do 3-PG, por Borges (2009).
(Continua)

Parâmetro	Símbolo*	Unidade	Valor
Biomassa inicial de folhas	W_F	Mg ha ⁻¹	0,168
Biomassa inicial de fuste (galho + casca + lenho)	W_S	Mg ha ⁻¹	0,099
Biomassa inicial de raízes	W_R	Mg ha ⁻¹	0,106
Partição folha/fuste para $D = 2$ cm	p_2	-	1,64
Partição folha/fuste para $D = 20$ cm	p_{20}	-	0,15
Constante da relação biomassa de fuste vs D	a_S	-	0,02
Potência da relação biomassa de fuste vs D	n_S	-	3,11
Fração máxima de PPL para raízes	η_{Rx}	-	0,5
Fração mínima de PPL para raízes	η_{Rn}	-	0,1
Máxima taxa de serapilheira	γ_{F1}	mês ⁻¹	0,07
Mínima taxa de serapilheira	γ_{F0}	mês ⁻¹	0,001
Idade na qual a taxa de serapilheira tem valor médio	t_{yF}	meses	4
Taxa média de <i>turnover</i> de raiz	γ_R	mês ⁻¹	0,025
Temperatura mínima de crescimento	T_{min}	°C	8
Temperatura ótima de crescimento	T_{opt}	°C	20
Temperatura máxima de crescimento	T_{max}	°C	40
Dias de produção perdidos a cada dia com geada	k_F	dias	0
Taxa de déficit de umidade para $f_\theta = 0,5$	c_θ	-	0,7
Potência da taxa de déficit de umidade	n_θ	-	9
Fator de enriquecimento da assimilação a 700 ppm	f_{Ca700}	-	1,4
Fator de enriquecimento da condutância do dossel a 700 ppm	f_{Cg700}	-	0,7
Valor de m quando FR = 0	m_0	-	0
Valor de f_N quando FR = 0	f_{N0}	-	0,5
Potência de (1-FR) em f_N	n_{fN}	-	1
Idade máxima do povoamento	t_x	anos	9
Potência da idade relativa em f_{age}	n_{age}	-	4
Idade relativa para $f_{age} = 0,5$	r_{age}	-	0,95
Taxa de mortalidade para idade madura	γ_{N1}	ano ⁻¹	0
Taxa de mortalidade de mudas (t = 0)	γ_{N0}	ano ⁻¹	0
Idade na qual a taxa de mortalidade tem valor médio	t_{yN}	anos	2
Forma da resposta a mortalidade	n_{yN}	-	1
Biomassa de fuste máxima por árvore para 1000 árvores ha ⁻¹	W_{Sx1000}	kg árvore ⁻¹	300
Potência da regra de auto-desbaste	n_N	-	1,5
Fração média de biomassa de folha perdida por árvore morta	m_F	-	0
Fração média de biomassa de raiz perdida por árvore morta	m_R	-	0,2
Fração média de biomassa de fuste perdida por árvore morta	m_S	-	0,2
Área foliar específica na idade 0	σ_0	m ² kg ⁻¹	13,74
Área foliar específica para árvores maduras	σ_1	m ² kg ⁻¹	7,56
Idade na qual a área foliar específica = $(\sigma_0 + \sigma_1)/2$	t_σ	anos	1,23
Coeficiente de extinção da RFA absorvida pelo dossel	k	-	0,5
Idade de fechamento do dossel	t_c	anos	2

Tabela 6 – Parâmetros usados no exemplo numérico do 3-PG, por Borges (2009).
(Conclusão)

Parâmetro	Símbolo*	Unidade	Valor
Proporção máxima da chuva evaporada do dossel	i_{Rx}	-	0,15
A_r para a máxima interceptação da chuva	L_{ix}	-	3,33
Eficiência quântica máxima do dossel	α_{Cx}	mol mol ⁻¹	0,08
Razão PPL/PPB	Y	-	0,5
Condutância mínima do dossel	g_{Cn}	m s ⁻¹	0
Condutância máxima do dossel	g_{Cx}	m s ⁻¹	0,02
A_r para a máxima condutância do dossel	L_{Cx}	-	3,33
Define resposta estomática ao DPV	k_D	mBar ⁻¹	0,0324
Condutância na camada limítrofe do dossel	g_B	m s ⁻¹	0,2
Fração de galho e casca na idade 0	ρ_{BB0}	-	0,59
Fração de galho e casca em idade madura	ρ_{BB1}	-	0,19
Idade na qual $\rho_{BB} = (\rho_{BB0} + \rho_{BB1})/2$	t_{BB}	anos	2,17
Densidade básica mínima da madeira (para árvores jovens)	ρ_0	t m ⁻³	0,382
Densidade básica máxima da madeira (para árvores maduras)	ρ_1	t m ⁻³	0,505
Idade na qual a densidade básica da madeira = $(\rho_0 + \rho_1)/2$	t_ρ	anos	2,264
Constante na relação de altura do fuste	a_H	-	0,67
Potência do D na relação de altura do fuste	n_{HB}	-	1,27
Potência do estoque na relação de altura do fuste	n_{HN}	-	0
Constante na relação de volume do fuste	a_V	-	0,0256
Potência do D na relação de volume do fuste	n_{VB}	-	3,22
Potência do estoque na relação de volume do fuste	n_{VN}	-	0
Intercepto da relação entre radiação líquida vs radiação solar	Q_a	W m ⁻²	-90
Inclinação da relação entre radiação líquida vs radiação solar	Q_b	-	0,8
Peso molecular da matéria seca	-	g mol ⁻¹	24
Fator de conversão da radiação solar para RFA	-	mol MJ ⁻¹	2,3

* Todos os símbolos do modelo 3-PG foram padronizados, em toda a tese, conforme Sands (2010).

Fonte: Elaborada pela autora, baseado em Borges (2009).

4 CONCLUSÕES

O aumento no número de pesquisas com o uso de modelos processuais, para diferentes objetivos, mostra oportunidades de inovação para melhor compreender e representar a dinâmica do crescimento florestal, principalmente frente às mudanças do clima. Dessa forma, a adição de redes neurais artificiais pode contribuir para melhorar o desempenho de um modelo processual, com ganhos em flexibilidade e em detalhes, sem que o nível de complexidade seja muito elevado. Além disso, esta técnica pode gerar uma aplicação mais adequada do modelo em manejo florestal.

REFERÊNCIAS

- ACOSTA, M. S.; MASTRANDREA, C.; LIMA, J. T. Wood technologies and uses of eucalyptus wood from fast grown plantation for solid products. *In: INTERNATIONAL CONVENTION OF SOCIETY OF WOOD SCIENCE AND TECHNOLOGY*, 51., 2008, Concepción. **Proceedings** [...]. Concepción: Society of Wood Science and Technology, 2008. p. 1-12.
- ADHIKARI, A.; WHITE, J. D. Climate change impacts on regenerating shrubland productivity. **Ecological Modelling**, Amsterdam, v. 337, p. 211-220, 2016.
- AGREN, G. I.; AXELSSON, B. PT: a tree growth model. **Ecological Bulletins**, Lund, n. 32, p. 525-536, 1980.
- ALCANTRA, A. E. M. de; SANTOS, A. C. de A.; MAYRA, L. M. da S.; BINOTI, D. H. B. Use of artificial neural networks to assess yield projection and average production of eucalyptus stands. **African Journal of Agricultural Research**, Nairobi, v. 13, n. 42, p. 2285-2297, 2018.
- ALMEIDA, A. C.; BRUCE, J.; SIGGINS, A.; LERICHE, A.; BATTAGLIA, M. Use of a spatial process-based model to quantify forest plantation productivity and water use efficiency under climate change scenarios. *In: WORLD IMACS CONGRESS AND MODSIM09 INTERNATIONAL CONGRESS ON MODELLING AND SIMULATION: INTERFACING MODELLING AND SIMULATION WITH MATHEMATICAL AND COMPUTATIONAL SCIENCES*, 18., 2009, Cairns. **Proceedings** [...]. Cairns: Australian National University, 2009. p. 1816-1822.
- ALMEIDA, A. C.; LANDSBERG, J. J. Evaluating methods of estimating global radiation and vapor pressure deficit using a dense network of automatic weather stations in coastal Brazil. **Agricultural and Forest Meteorology**, London, v. 118, n. 3/4, p. 237-250, 2003.
- ALMEIDA, A. C.; LANDSBERG, J. J.; SANDS, P. J. Parameterisation of 3-PG model for fast-growing *Eucalyptus grandis* plantations. **Forest Ecology and Management**, Amsterdam, v. 193, n. 1/2, p. 179-195, 2004.
- ALMEIDA, A. C.; LANDSBERG, J.; SANDS, P. J.; AMBROGI, M. S.; FONSECA, S.; BARDDAL, S. M.; BERTOLUCCI, F. L. Needs and opportunities for using a process-based productivity model as a practical tool in Eucalyptus plantations. **Forest Ecology and Management**, Amsterdam, v. 193, n. 1/2, p. 167-177, 2004.
- ALMEIDA, A. C.; SANDS, P. J. Improving the ability of 3-PG to model the water balance of forest plantations in contrasting environments. **Ecohydrology**, Warszawa, v. 9, n. 4, p. 610-630, 2016.
- ALMEIDA, A. C.; SIGGINS, A.; BATISTA, T. R.; BEADLE, C.; FONSECA, S.; LOOS, R. Mapping the effect of spatial and temporal variation in climate and soils on Eucalyptus plantation production with 3-PG, a process-based growth model. **Forest Ecology and Management**, Amsterdam, v. 259, n. 9, p. 1730-1740, 2010.

AMTHOR, J. S. Scaling CO₂-photosynthesis relationships from the leaf to the canopy. **Photosynthesis Research**, *Dordrecht*, v. 39, n. 3, p. 321-350, 1994.

ASHRAF, I. M.; ZHAO, Z.; BOURQUE, C. P. A.; MACLEAN, D. A.; MENG, F. R. Integrating biophysical controls in forest growth and yield predictions with artificial intelligence technology. **Canadian Journal of Forest Research**, Ottawa, v. 43, n. 12, p. 1162-1171, 2013.

ASHRAF, M. I.; MENG, F. R.; BOURQUE, C. P. A.; MACLEAN, D. A. A novel modelling approach for predicting forest growth and yield under climate change. **PLoS ONE**, San Francisco, v. 10, n. 7, p. 1-18, 2015.

AUGUSTYNICZIK, A. L. D.; HARTIG, F.; MINUNNO, F.; KAHLE, H. P.; DIACONU, D.; HANEWINKEL, M.; YOUSEFPOUR, R. Productivity of *Fagus sylvatica* under climate change: a Bayesian analysis of risk and uncertainty using the model 3-PG. **Forest Ecology and Management**, Amsterdam, v. 401, p. 192-206, 2017.

AZEVEDO, G. B. de; TOMIAZZI, H. V.; AZEVEDO, G. T. de O. S.; TEODORO, L. P. R.; TEODORO, P. E.; SOUZA, M. T. P. de; BATISTA, T. S.; EUFRADE-JUNIOR, H. de J.; GUERRA, S. P. S. Multi-volume modeling of Eucalyptus trees using regression and artificial neural networks. **PLoS ONE**, San Francisco, v. 15, n. 9, p. 1-17, Sept. 2020.

BAESSO, R. C. E. **Efeito do CO₂ na eficiência quântica do eucalipto e sua utilização na modelagem de seu crescimento pelo 3-PG**. 2011. 130 f. Tese (Doutorado em Meteorologia Agrícola) - Universidade Federal de Viçosa, Viçosa, MG, 2011.

BAESSO, R. C. E.; RIBEIRO, A.; SILVA, M. P. Impacto das mudanças climáticas na produtividade do eucalipto na região norte do Espírito Santo e sul da Bahia. **Ciência Florestal**, Santa Maria, v. 20, n. 2, p. 335-344, 2010.

BATTAGLIA, M.; O'GRADY, A.; MENDHAM, D. Process-based models in Eucalyptus plantation management: reality and perspectives. **Boletim Informativo CIDEU**, Huelva, v. 3, p. 189-205, 2007.

BATTAGLIA, M.; SANDS, P. Modelling site productivity of *Eucalyptus globulus* in response to climatic and site factors. **Australian Journal of Plant Physiology**, Melbourne, v. 24, p. 831-850, 1997.

BAYAT, M.; BETTINGER, P.; HEIDARI, S.; KHALYANI, A. H.; JOURGHOLAMI, M.; HAMIDI, S. K. Estimation of tree heights in an uneven-aged, mixed forest in northern Iran using artificial intelligence and empirical models. **Forests**, Basel, v. 11, n. 3, p. 324-323, 2020.

BAYAT, M.; GHORBANPOUR, M.; ZARE, R.; JAAFARI, A. Application of artificial neural networks for predicting tree survival and mortality in the Hyrcanian forest of Iran. **Computers and Electronics in Agriculture**, New York, v. 164, p. 104929, July 2019.

BEHERA, S. K.; TRIPATHI, P.; BEHERA, M. D.; TULI, R. Modeling net primary productivity of tropical deciduous forests in North India using bio-geochemical model. **Biodiversity and Conservation**, London, v. 28, n. 8, p. 2105-2121, 2019.

BEHLING, M. **Nutrição, partição de biomassa e crescimento de povoamentos de teca em Tangará da Serra-MT**. 2009. 156 p. Tese (Doutorado em Solos e Nutrição de Plantas) - Departamento de Solos, Universidade Federal de Viçosa, Viçosa, MG, 2009.

BEHLING, M.; PIKETTY, M. G.; MORELLO, T. F.; BOUILLET, J. P.; LACLAU, J. P.; MESQUITA NETO, F. Eucalyptus plantations and the steel industry in Amazonia: a contribution from the 3-pg model. **Bois et Forêts des Tropiques**, Paris, v. 65, n. 309, p. 37-49, 2011.

BETTINGER, P.; BOSTON, K.; SIRY, J.; GREBNER, D. **Forest management and planning**. 2nd ed. New York: Academic, 2009. 360 p.

BINKLEY, D.; STAPE, J. L.; BAUERLE, W. L.; RYAN, M. G. Explaining growth of individual trees: light interception and efficiency of light use by Eucalyptus at four sites in Brazil. **Forest Ecology and Management**, Amsterdam, v. 259, n. 9, p. 1704-1713, 2010.

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

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

BINOTI, D. H. B.; DUARTE, P. J.; SILVA, M. L. M. da; SILVA, G. F. da; LEITE, H. G.; MENDONÇA, A. R. de; ANDRADE, V. C. L. de; VEGA, A. E. D. Estimation of height eucalyptus trees with neuroevolution of augmenting topologies (NEAT). **Revista Árvore**, Viçosa, MG, v. 41, n. 3, p. 1-8, 2017.

BINOTI, D. H. B.; LEITE, H. G.; SILVA, A.; SANTOS, A. C. de A. Modeling the diameter distribution of thinned Eucalyptus stands using a cellular automata. **Revista Árvore**, Viçosa, MG, v. 36, n. 5, p. 931-939, 2012.

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

BINOTI, M. L. M. da S.; BINOTI, D. H. B.; LEITE, H. G.; GARCIA, S. L. R.; FERREIRA, M. Z.; RODE, R.; SILVA, A. A. L. da. Redes neurais artificiais para estimação do volume de árvores. **Revista Árvore**, Viçosa, MG, v. 38, n. 2, p. 283-288, 2014a.

BINOTI, M. L. M. da S.; BINOTI, D. H. B.; LEITE, H. G.; SILVA, A. A. L. da;

PONTES, C. Utilização de redes neurais artificiais para a projeção da distribuição diamétrica de povoamento equiâneos. **Revista Árvore**, Viçosa, MG, v. 38, n. 4, p. 747-754, 2014b.

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

BLACKMAN, F. F.; MATTHAEI, G. L. Experimental researches in vegetable assimilation and respiration: IV., a quantitative study of carbon-dioxide assimilation and leaf-temperature in natural illumination. **Proceedings of the Royal Society of London. Series B, Containing Papers of a Biological Character**, London, v. 76, n. 511, p. 402-460, 1905.

BORGES, J. S. **Modulador edáfico para uso em modelo ecofisiológico e produtividade potencial de povoamentos de eucalipto**. 2012. 70 p. Tese (Doutorado em Solos e Nutrição de Plantas) - Departamento de Solos, Universidade Federal de Viçosa, Viçosa, MG, 2012.

BORGES, J. S. **Parametrização, calibração e validação do modelo 3-PG para eucalipto na região do cerrado de Minas Gerais**. 2009. 77 p. Dissertação (Mestrado em Solos e Nutrição de Plantas) - Departamento de Solos, Universidade Federal de Viçosa, Viçosa, MG, 2009.

BURKOV, A. **The hundred pages machine learning book**. Quebec: Andriy Burkov, 2019. 160 p.

CAMPOS, J. C. C.; LEITE, H. G. **Mensuração florestal: perguntas e respostas**. 5. ed. Viçosa, MG: Editora UFV, 2017. 636 p.

CAO, L.; SHEN, X.; LIU, K.; WU, X. Estimation of forest structural parameters using UAV-LiDAR data and a process-based model in ginkgo planted forests. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, New York, v. 12, n. 11, p. 4175-4190, 2019.

CARSON, C. F.; HAMMER, K. A. Chemistry and bioactivity of essential oils. **Lipids and Essential Oils as Antimicrobial Agents**, London, v. 25, n. 2, p. 203-238, 2010.

CASTRO, R. V. O.; SOARES, C. P. B.; LEITE, H. G.; SOUZA, A. L. de; NOGUEIRA, G. S.; MARTINS, B. F. Individual growth model for eucalyptus stands in Brazil using artificial neural network. **ISRN Forestry**, London, v. 2013, p. 1-12, 2013.

CHEN, Y.; WU, B.; CHEN, D.; QI, Y. Using machine learning to assess site suitability for afforestation with particular species. **Forests**, Basel, v. 10, n. 9, p. 1-22, 2019.

CLUTTER, J. L.; FORTSON, J. C.; PIENAAR, L. V.; BRISTER, G. H.; BAILEY, R. L. **Timber management: a quantitative approach**. New York: J. Wiley, 1983. 333 p.

COELHO JUNIOR, L. M.; REZENDE, J. L. P. de; BATISTA, A. L. F.; MENDONÇA, A. R. de; LACERDA, W. S. Use of artificial neural networks for prognosis of charcoal

prices in Minas Gerais. **Cerne**, Lavras, v. 19, n. 2, p. 281-288, 2013.

COOPS, N. C.; WARING, R. H. Assessing forest growth across southwestern Oregon under a range of current and future global change scenarios using a process model, 3-PG. **Global Change Biology**, Oxford, v. 7, n. 1, p. 15-29, 2001.

COOPS, N. C.; WARING, R. H. Estimating the vulnerability of fifteen tree species under changing climate in Northwest North America. **Ecological Modelling**, Amsterdam, v. 222, n. 13, p. 2119-2129, 2011a.

COOPS, N. C.; WARING, R. H. A process-based approach to estimate lodgepole pine (*Pinus contorta* Dougl.) distribution in the Pacific Northwest under climate change. **Climatic Change**, Dordrecht, v. 105, n. 1, p. 313-328, 2011b.

COOPS, N. C.; WARING, R. H.; LANDSBERG, J. J. Assessing forest productivity in Australia and New Zealand using a physiologically-based model driven with averaged monthly weather data and satellite-derived estimates of canopy photosynthetic capacity. **Forest Ecology and Management**, Amsterdam, v. 104, n. 1/3, p. 113-127, 1998.

COOPS, N. C.; WARING, R. H.; LANDSBERG, J. J. Estimation of potential forest productivity across the Oregon transect using satellite data and monthly weather records. **International Journal of Remote Sensing**, Basingstoke, v. 22, n. 18, p. 3797-3812, 2001.

COOPS, N. C.; WARING, R. H.; SCHROEDER, T. A. Combining a generic process-based productivity model and a statistical classification method to predict the presence and absence of tree species in the Pacific Northwest, U.S.A. **Ecological Modelling**, Amsterdam, v. 220, n. 15, p. 1787-1796, 2009.

COOPS, N. C.; WULDER, M. A.; WARING, R. H. Modeling lodgepole and jack pine vulnerability to mountain pine beetle expansion into the western Canadian boreal forest. **Forest Ecology and Management**, Amsterdam, v. 274, p. 161-171, 2012.

CORDEIRO, M. A.; PEREIRA, N. N. de J.; BINOTI, D. H. B.; BINOTI, M. L. M. da S.; LEITE, H. G. Estimativa do volume de *Acacia mangium* utilizando técnicas de redes neurais artificiais e máquinas vetor de suporte. **Pesquisa Florestal Brasileira**, Colombo, v. 35, n. 83, p. 255, 2015.

CORTE, A. P. D.; SOUZA, D. V.; REX, F. E.; SANQUETTA, C. R.; MOHAN, M.; SILVA, C. A.; ZAMBRANO, A. M. A.; PRATA, G.; ALMEIDA, D. R. A. de; TRAUTENMÜLLER, J. W.; KLAUBERG, C.; MORAES, A. de; SANQUETTA, M. N.; WILKINSON, B.; BROADBENT, E. N. Forest inventory with high-density UAV-Lidar: machine learning approaches for predicting individual tree attributes. **Computers and Electronics in Agriculture**, New York, v. 179, p. 1-14, Apr. 2020.

COSTA FILHO, S. V. S. da; ARCE, J. E.; MONTAÑO, R. N. R.; PELISSARI, A. L. Configuração de algoritmos de aprendizado de máquina na modelagem florestal: um estudo de caso na modelagem da relação hipsométrica. **Ciência Florestal**, Santa Maria, v. 29, n. 4, p. 1501, 2019.

CUNHA, T. Q. G. da; SANTOS, A. C.; NOVAES, E.; HANSTED, A. L. S.; YAMAJI, F. M.; SETTE JUNIOR, C. R. Eucalyptus expansion in Brazil: energy yield in new forest frontiers. **Biomass and Bioenergy**, Oxford, v. 144, p. 1-8, Nov. 2021.

DANTAS, D.; CALEGARIO, N.; ACERBI JÚNIOR, F. W.; CARVALHO, S. de P. C.; ISAAC JÚNIOR, M. A.; MELO, E. de A. Multilevel nonlinear mixed-effects model and machine learning for predicting the volume of Eucalyptus spp. trees. **Cerne**, Lavras, v. 26, n. 1, p. 48-57, 2020.

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

DIAMANTOPOULOU, M. J. Assessing a reliable modeling approach of features of trees through neural network models for sustainable forests. **Sustainable Computing: Informatics and Systems**, Oxford, v. 2, n. 4, p. 190-197, 2012.

DIJAK, W. D.; HANBERRY, B. B.; FRASER, J. S.; HE, H. S.; WANG, W. J.; THOMPSON, F. R. Revision and application of the LINKAGES model to simulate forest growth in central hardwood landscapes in response to climate change. **Landscape Ecology**, Dordrecht, v. 32, n. 7, p. 1365-1384, 2017.

DOLÁCIO, C. J. F.; OLIVEIRA, R. S.; NAKAJIMA, N. Y.; TAVARES JÚNIOR, I. da S.; ROCHA, J. E. C.; EBLING, A. A.; GAMA, M. A. P. Integration of principal component analysis and artificial neural network to modeling productive capacity of eucalypt stands from biophysical attributes. **Forest Ecology and Management**, Amsterdam, v. 460, p. 117862, Dec. 2020.

DOMINGUES, G. F.; SOARES, V. P.; LEITE, H. G.; FERRAZ, A. S.; RIBEIRO, C. A. A. S.; LORENZON, A. S.; MARCATTI, G. E.; TEIXEIRA, T. R.; CASTRO, N. L. M. de; MOTA, P. H. S.; SOUZA, G. S. A. de; MENEZES, S. J. M. da C. de; SANTOS, A. R. dos; AMARAL, C. H. do. Artificial neural networks on integrated multispectral and SAR data for high-performance prediction of eucalyptus biomass. **Computers and Electronics in Agriculture**, New York, v. 168, p. 105089, Jan. 2020.

DU, H.; ZHOU, G.; MAO, F.; LI, X. Estimating and analyzing the spatiotemporal pattern of aboveground carbon in bamboo forest by combining remote sensing data and improved BIOME-BGC Model. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, New York, v. 11, n. 7, p. 2282-2295, 2018.

DUBE, T.; MUTANGA, O.; ELHADI, A.; ISMAIL, R. Intra-and-inter species biomass prediction in a plantation forest: testing the utility of high spatial resolution spaceborne multispectral rapideye sensor and advanced machine learning algorithms. **Sensors**, Berna, v. 14, n. 8, p. 15348-15370, 2014.

DUNCAN, W. G.; LOOMIS, R. S.; WILLIAMS, W. A.; HANAU, R. A model for simulating photosynthesis in plant communities. **Hilgardia**, Berkeley, v. 38, n. 4, p. 181-205, 1967.

DYE, P. J. Modelling growth and water use in four pinus patula stands with the 3-pg model. **Southern African Forestry Journal**, Pretoria, v. 191, n. 1, p. 53-63, 2001.

EL NAQA, I.; LI, R.; MURPHY, M. J. **Machine learning in radiation oncology: theory and applications**. New York: Springer, 2015. 336 p.

ERCANLI, İ. Innovative deep learning artificial intelligence applications for predicting relationships between individual tree height and diameter at breast height. **Forest Ecosystems**, London, v. 7, n. 1, 2020. Disponível em: <https://forestecosyst.springeropen.com/articles/10.1186/s40663-020-00226-3>. Acesso em: 10 mar. 2020.

ERCANLI, İ.; GÜNLÜ, A.; SENYURT, M.; KELES, S. Artificial neural network models predicting the leaf area index: a case study in pure even-aged Crimean pine forests from Turkey İlker. **Forest Ecosystems**, London, v. 5, n. 29, Sept. 2018. Disponível em: <https://forestecosyst.springeropen.com/articles/10.1186/s40663-018-0149-8#citeas>. Acesso em: 10 mar. 2020.

ESPREY, L. J.; SANDS, P. J.; SMITH, C. W. Understanding 3-PG using a sensitivity analysis. **Forest Ecology and Management**, Amsterdam, v. 193, n. 1/2, p. 235-250, 2004.

FARIA, B. de; MARANO, G.; PIPONIOT, C.; SILVA, C. A.; DANTAS, V. de L.; RATTIS, L.; RECH, A. R.; COLLALTI, A. Model-based estimation of Amazonian recovery time following drought and fire. **Forests**, Basel, v. 12, n. 1, p. 1-25, July 2020.

FEIKEMA, P. M.; MORRIS, J. D.; BEVERLY, C. R.; COLLOPY, J. J.; BAKER, T. G.; LANE, P. N. J. Validation of plantation transpiration in south-eastern Australia estimated using the 3PG+ forest growth model. **Forest Ecology and Management**, Amsterdam, v. 260, n. 5, p. 663-678, 2010.

FONTES, L.; BONTEMPS, J. D.; BUGMANN, H.; OIJEN, V. van; GRACIA, C.; KRAMER, K.; LINDNER, M.; RÖTZER, T.; SKOVSGAARD, J. P. Models for supporting forest management in a changing environment. **Forest Systems**, Berlin, v. 3, n. 4, p. 8, 2010.

FORRESTER, D. I.; TANG, X. Analysing the spatial and temporal dynamics of species interactions in mixed-species forests and the effects of stand density using the 3-PG model. **Ecological Modelling**, Amsterdam, v. 319, p. 233-254, 2016.

FREITAS, E. C. S. de; PAIVA, H. N. de; NEVES, J. C. L.; MARCATTI, G. E.; LEITE, H. G. Modeling of eucalyptus productivity with artificial neural networks. **Industrial Crops and Products**, London, v. 146, p. 112149, Jan. 2020.

GARCÍA-GUTIÉRREZ, J.; MARTÍNEZ-ÁLVEREZ, F.; TRONCOSO, A.; RIQUELME, J. C. A comparison of machine learning regression techniques for LiDAR-derived estimation of forest variables. **Neurocomputing**, New York, v. 167, p. 24-31, 2015.

GLEASON, C. J.; IM, J. Forest biomass estimation from airborne LiDAR data using machine learning approaches. **Remote Sensing of Environment**, Amsterdam, v. 125, p. 80-91, 2012.

GONZALEZ-BENECKE, C. A.; JOKELA, E. J.; CROPPER, W. P.; BRACHO, R.; LEDUC, D. J. Parameterization of the 3-PG model for *Pinus elliottii* stands using alternative methods to estimate fertility rating, biomass partitioning and canopy closure. **Forest Ecology and Management**, Amsterdam, v. 327, p. 55-75, 2014.

GUPTA, R.; SHARMA, L. K. The process-based forest growth model 3-PG for use in forest management: a review. **Ecological Modelling**, Amsterdam, v. 397, p. 55-73, Jan. 2019.

HAMIDI, S. K.; WEISKITTEL, A.; BAYAT, M.; FALLAH, A. Development of individual tree growth and yield model across multiple contrasting species using nonparametric and parametric methods in the Hyrcanian forests of northern Iran. **European Journal of Forest Research**, Georgetown, v. 140, n. 2, p. 421-434, 2021.

HANSON, P. J.; AMTHOR, J. S.; WULLSCHLEGER, S. D.; WILSON, K. B.; GRANT, R. F. Oak forest carbon and water simulations: model intercomparisons and evaluations against independent data. **Ecological Monographs**, Lawrence, v. 74, n. 3, p. 443-489, 2004.

HASENAUER, H.; MERKL, D. Forest tree mortality simulation in uneven-aged stands using connectionist networks. *In: EANN'97, INT'L CONFERENCE ON ENGINEERING APPLICATION OF NEURAL NETWORKS*, 1., 1997, Stockholm. **Proceedings** [...]. Stockholm: EANN, 1997.

HATCH, M. D.; SLACK, C. R. Photosynthetic CO₂-fixation pathways. **Annual Review of Plant Physiology**, Palo Alto, v. 21, n. 1, p. 141-162, 1970.

HAYKIN, S. **Neural networks: a comprehensive foundation**. 2nd ed. Ottawa: Prentice Hall, 1999. 842 p.

HAYKIN, S. **Neural networks and learning machines**. 3rd ed. Ottawa: Prentice Hall, 2009. 936 p.

HEIJDEN, G. van der; BELYAZID, S.; DAMBRINE, E.; RANGER, J.; LEGOUT, A. NutsFor a process-oriented model to simulate nutrient and isotope tracer cycling in forest ecosystems. **Environmental Modelling and Software**, Oxford, v. 95, p. 365-380, 2017.

HENDERSON, J. D.; PARAJULI, R.; ABT, R. C. Biological and market responses of pine forests in the US Southeast to carbon fertilization. **Ecological Economics**, Amsterdam, v. 169, p. 106491, Aug. 2020.

HUNT, E. R.; LAVIGNE, M. B.; FRANKLIN, S. E. Factors controlling the decline of net primary production with stand age for balsam fir in Newfoundland assessed using an ecosystem simulation model. **Ecological Modelling**, Amsterdam, v. 122, n. 3, p. 151-164, 1999.

INGEN-HOUSZ, J. **An essay on the food of plants and the renovation of soils:** additional appendix to the outlines of the fifteenth chapter of the general report from the board of agriculture on the subyecy of manures. London: [s. n.], 1796.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Produção da extração vegetal e da silvicultura 2019.** Rio de Janeiro: IBGE, 2019.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Produção da extração vegetal e silvicultura 2019.** Rio de Janeiro: IBGE, 2020.

JOHNSON, D. W.; LINDBERG, S. E. **Atmospheric deposition and forest nutrient cyclin:** a synthesis of the integrated forest study. New York: Springer, 1992. 707 p.

KEITH, H.; GORSEL, E. van; JACOBSEN, K. L.; CLEUGH, H. A. Agricultural and forest meteorology dynamics of carbon exchange in a Eucalyptus forest in response to interacting disturbance factors. **Agricultural and Forest Meteorology**, Amsterdam, v. 153, p. 67-81, 2012.

KIMMINS, J. P.; SCOLLAR, K. A.; FELLER, M. C. FORCYTE: a computer simulation approach to evaluating the effect of whole tree harvesting on nutrient budgets and future forest productivity. **Mittelung Forstliche Bunderversuchsanst**, Wien, n. 140, p. 189-205, 1981.

KLIPPEL, V. H. **Modelagem ecofisiológica de cultivos de eucalipto em regiões subtropicais do Brasil.** 2015. 89 p. Tese (Doutorado em Meteorologia Agrícola) - Universidade Federal de Viçosa, Viçosa, MG, 2015.

KOURTZ, P. Artificial intelligence: a new tool for forest management. **Canadian Journal of Forest Research**, Ottawa, v. 20, p. 428-437, 1990.

KWON, S. K.; JUNG, H. S.; BAEK, W. K.; KIM, D. Classification of forest vertical structure in South Korea from aerial orthophoto and lidar data using an artificial neural network. **Applied Sciences**, Berna, v. 7, n. 10, p. 1046, 2017.

LANDSBERG, J. Physiology in forest models: history and the future. **FBMIS**, Oxford, v. 1, p. 49-63, Jan. 2003.

LANDSBERG, J. J.; JOHNSON, K. H.; ALBAUGH, T. J.; ALLEN, H. L.; MCKEAND, S. E. Applying 3-PG, a simple process-based model designed to produce practical results from Loblolly Pine experiments. **Forest Science**, Bethesda, v. 47, n. 1, p. 43-51, 2001.

LANDSBERG, J. J.; SANDS, P. J. **Physiological ecology of forest production:** principles, processes and models. Amsterdam: Elsevier; Academic, 2011.

LANDSBERG, J. J.; WARING, R. H. A generalised model of forest productivity using simplified concepts of radiation-use efficiency, carbon balance and partitioning. **Forest Ecology and Management**, Amsterdam, v. 95, n. 3, p. 209-228, 1997.

LANDSBERG, J. J.; WARING, R. H.; COOPS, N. C. Performance of the forest productivity model 3-PG applied to a wide range of forest types. **Forest Ecology and Management**, Amsterdam, v. 172, n. 2/3, p. 199-214, 2003.

LE MAIRE, G.; GUILLEMOT, J.; CAMPOE, O. C.; STAPE, J. L.; LACLAU, J. P.; NOUVELLON, Y. Light absorption, light use efficiency and productivity of 16 contrasted genotypes of several Eucalyptus species along a 6-year rotation in Brazil. **Forest Ecology and Management**, Amsterdam, v. 449, p. 117-443, 2019.

LEE, S. C.; BLACK, T. A.; JASSAL, R. S.; CHRISTEN, A.; MEYER, G.; NESIC, Z. Long-term impact of nitrogen fertilization on carbon and water fluxes in a Douglas-fir stand in the Pacific Northwest. **Forest Ecology and Management**, Amsterdam, v. 455, p. 117645, July 2020.

LEITE, H. G.; SILVA, M. L. M. da; BINOTI, D. H. B.; FARDIN, L.; TAKIZAWA, F. H. Estimation of inside-bark diameter and heartwood diameter for *Tectona grandis* Linn. trees using artificial neural networks. **European Journal of Forest Research**, Georgetown, v. 130, n. 2, p. 263-269, 2011.

LEITE, R. V.; AMARAL, C. H. do; PIRES, R. de P.; SILVA, C. A.; SOARES, C. P. B.; MACEDO, R. P.; SILVA, A. A. L. da; BROADBENT, E. N.; MOHAN, M.; LEITE, H. G. Estimating stem volume in eucalyptus plantations using airborne LiDAR: a comparison of area- and individual tree-based approaches. **Remote Sensing**, Basel, v. 12, n. 9, p. 1513, 2020.

LEMOS, C. C. Z. de. **Aprimoramentos, teste e uso do modelo 3-PG em plantios clonais de Eucalyptus no nordeste do estado de São Paulo**. 2012. 175 p. Tese (Doutorado em Recursos Florestais) - Universidade de São Paulo, Escola Superior de Agricultura "Luiz de Queiroz", Piracicaba, 2012.

LEMOS, C. C. Z. de; HAKAMADA, R. E.; CARRERO, O.; ALVARES, C. A.; STAPE, J. L. Estimaco, zoneamento e anlise de sensibilidade da produtividade florestal de Eucalyptus no Nordeste do Estado de So Paulo atravs do modelo 3-PG. **Scientia Forestalis**, Piracicaba, v. 46, n. 119, p. 459-471, 2018.

LIAO, W.; NOGAMI, K.; IMANAGA, M. An application of neurogenetic algorithm system to individual tree growth model. **Journal of Forest Research**, Ottawa, v. 3, n. 2, p. 79-84, 1998.

LONDERO, E. K.; SCHUMACHER, M. V.; SZYMCZAK, D. A.; ARAJO, E. F. Calibrao do modelo 3-PG para *Eucalyptus saligna* Smith NA regio de Guaba - RS. **Ciencia Florestal**, Santa Maria, v. 25, n. 2, p. 293-305, 2015.

LOOMIS, R. S.; WILLIAMS, W. A. Maximum crop productivity: an estimate. **Crop Science**, Madison, v. 3, n. 1, p. 67-72, 1963.

LU, Y.; COOPS, N. C.; WANG, T.; WANG, G. A process-based approach to estimate Chinese fir (*Cunninghamia lanceolata*) distribution and productivity in Southern China under climate change. **Forests**, Basel, v. 6, n. 2, p. 360-379, 2015.

- MATHYS, A.; COOPS, N. C.; WARING, R. H. Soil water availability effects on the distribution of 20 tree species in western North America. **Forest Ecology and Management**, Amsterdam, v. 313, p. 144-152, 2014.
- MCMURTRIE, R. E.; ROOK, D. A.; KELLIHER, F. M. Modelling the yield of *Pinus radiata* on a site limited by water and nitrogen. **Forest Ecology and Management**, Amsterdam, v. 30, p. 381-413, 1990.
- MCROBERTS, R. E.; SCHMOLDT, D. L.; RAUSCHER, H. M. Enhancing the scientific process with artificial intelligence: forest science applications. **AI Applications**, New York, v. 5, n. 2, p. 5-26, 1991.
- MIGUEL, E. P.; MOTA, F.; TEO, S. J.; GERONI, R. Artificial intelligence tools in predicting the volume of trees within a forest stand. **African Journal of Agricultural Research**, Nairobi, v. 11, n. 21, p. 1914-1923, 2016.
- MITCHELL, T. M. **Machine learning**. New York: McGraw-Hill Education, 1997. 414 p.
- MONTEITH, J. L. Climate and the efficiency of crop production in Britain. **Philosophical Transactions of the Royal Society of London: B, Biological Sciences**, London, v. 281, n. 980, p. 277-294, 1977.
- MUSHAR, S. H. M.; AHMAD, S. S. S.; KAMIN, F.; SHARI, N. H. Z. Machine learning approach for estimating tree volume. **Journal of Physics: Conference Series**, Moscow, v. 1502, n. 1, 2020. Disponível em: <https://iopscience.iop.org/article/10.1088/1742-6596/1502/1/012039>. Acesso em: 10 mar. 2021.
- MYBURG, A. A.; GRATTAPAGLIA, D.; TUSKAN, G. A.; HELLSTEN, U.; HAYNES, R. D.; GRIMWOOD, J.; JENKINS, J.; LINDQUIST, E.; TICE, H.; BAUER, D.; GOODSTEIN, D. M.; DUBCHAK, I.; POLIAKOV, A.; MIZRCHI, E.; KULLAN, A. R. K. The genome of *Eucalyptus grandis*. **Nature**, London, v. 510, n. 7505, p. 356-362, 2014.
- NANDY, S.; WATHAN, T.; KUSHWAHA, S. P. S.; KUMAR, A. S.; DADHWAL, V. K. Neural network-based modelling for forest biomass assessment. **Carbon Management**, London, v. 8, n. 4, p. 305-317, 2017.
- NAVARRO-CERRILLO, R. M.; DAVILA, J. B.; MINGUEZ, J. C. S.; XENAKIS, G.; SÁNCHEZ-SALGUEIRO, R.; HERNÁNDEZ-CLEMENTE, R. Growth decline assessment in *Pinus sylvestris* L. and *Pinus nigra* Arnold. forests by using 3-PG model. **Forest Systems**, Berlin, v. 25, n. 3, May 2016. Disponível em: <https://revistas.inia.es/index.php/fs/article/view/8610>. Acesso em: 10 mar. 2020.
- NIEL, C. B. van. On the morphology and physiology of the purple and green sulphur bacteria. **Archiv für Mikrobiologie**, Berlin, v. 3, n. 1, p. 1-112, 1932.
- NISKA, H.; SKON, J. P.; PACKALEN, P.; TOKOLA, T.; MALTAMO, M.; KOLEHMAINEN, M. Neural networks for the prediction of species-specific plot

volumes using airborne laser scanning and aerial photographs. **IEEE Transactions on Geoscience and Remote Sensing**, New York, v. 48, n. 3, pt. 1, p. 1076-1085, 2010.

NÖLTE, A.; MEILBY, H.; YOUSEFPOUR, R. Multi-purpose forest management in the tropics: incorporating values of carbon, biodiversity and timber in managing *Tectona grandis* (teak) plantations in Costa Rica. **Forest Ecology and Management**, Amsterdam, v. 422, p. 345-357, Feb. 2018.

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

PASTOR, J.; POST, W. M. Influence of climate, soil moisture, and succession on forest carbon and nitrogen cycles. **Biogeochemistry**, Dordrecht, v. 2, n. 1, p. 3-27, 1986.

PATENAUDE, G.; MILNE, R.; OIJEN, M. van; ROWLAND, C. S. Integrating remote sensing datasets into ecological modelling: a Bayesian approach. **International Journal of Remote Sensing**, Basingstoke, v. 29, n. 5, p. 1295-1315, 2008.

PAUL, K. I.; BOOTH, T. H.; JOVANOVIĆ, T.; SANDS, P. J. Calibration of the forest growth model 3-PG to eucalypt plantations growing in low rainfall regions of Australia. **Forest Ecology and Management**, Amsterdam, v. 243, n. 2/3, p. 237-247, 2007.

PENG, C.; WEN, X. **Recent applications of artificial neural networks in forest resource management: an overview**. Palo Alto: American Association for Artificial Intelligence, 1999. (Technical Report WS-99-07).

PÉREZ-CRUZADO, C.; MERINO, A.; RODRÍGUEZ-SOALLEIRO, R. A management tool for estimating bioenergy production and carbon sequestration in *Eucalyptus globulus* and *Eucalyptus nitens* grown as short rotation woody crops in north-west Spain. **Biomass and Bioenergy**, Oxford, v. 35, n. 7, p. 2839-2851, 2011.

PINKARD, E. A.; MOHAMMED, C. L. Photosynthesis of *Eucalyptus globulus* with *Mycosphaerella* leaf disease. **New Phytologist**, Cambridge, v. 170, n. 1, p. 119-127, 2005.

PONTES, M. da S. **Parametrização do modelo 3-PG para Teca (*Tectona grandis* L.f.) e dos sistemas Ferti-UFV e Nutri-UFV para subsidiar o seu manejo nutricional**. 2011. 79 p. Dissertação (Mestrado em Solos e Nutrição de Plantas) - Universidade Federal de Viçosa, Viçosa, MG, 2011.

POTTER, C.; TAN, P. N.; STEINBACH, M.; KLOOSTER, S.; KUMAR, V.; MYNENI, R.; GENOVESE, V. Major disturbance events in terrestrial ecosystems detected using global satellite data sets. **Global Change Biology**, Oxford, v. 9, n. 7, p. 1005-1021, 2003.

RASCON, N. J. L. **Modelagem ecofisiológica do desenvolvimento do eucalipto na Amazônia**. 2012. 93 f. Dissertação (Mestrado em Meteorologia Agrícola) - Universidade Federal de Viçosa, Viçosa, MG, 2012.

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

ROCHA, S. J. S. S. da; TORRES, C. M. M. E.; JACOVINE, L. A. G.; LEITE, H. G.; GELCER, E. M.; NEVES, K. M.; SCHETTINI, B. L. S.; VILLANOVA, P. H.; SILVA, L. F. da; REIS, L. P.; ZANUNCIO, J. C. Artificial neural networks: modeling tree survival and mortality in the Atlantic Forest biome in Brazil. **Science of the Total Environment**, Amsterdam, v. 645, p. 655-661, 2018.

RODRÍGUEZ, R.; ESPINOSA, M.; REAL, P.; INZUNZA, J. Analysis of productivity of radiata pine plantations under different silvicultural regimes using the 3-PG process-based model. **Australian Forestry**, Queen Victoria, v. 65, n. 3, p. 165-172, 2002.

RODRÍGUEZ-SUÁREZ, J. A.; SOTO, B.; IGLESIAS, M. L.; DIAZ-FIERROS, F. Application of the 3PG forest growth model to a Eucalyptus globulus plantation in Northwest Spain. **European Journal of Forest Research**, Georgetown, v. 129, n. 4, p. 573-583, 2010.

RUNNING, S. W.; COUGHLAN, J. C. A general model of forest ecosystem processes for regional applications I. hydrologic balance, canopy gas exchange and primary production processes. **Ecological Modelling**, Amsterdam, v. 42, p. 125-154, 1988.

SANDS, P. **Adaptation of 3-PG to novel species**: guidelines for data collection and parameter assignment. Hobart: CSIRO, 2004. (Technical report, 141).

SANDS, P. J. **3PG PJS user manual**. Taroona: [s. n.], 2010. 27 p.

SANDS, P. J.; LANDSBERG, J. J. Parameterisation of 3-PG for plantation grown Eucalyptus globulus. **Forest Ecology and Management**, Amsterdam, v. 163, n. 1/3, p. 273-292, 2002.

SCRINZI, G.; MARZULLO, L.; GALVAGNI, D. Development of a neural network model to update forest distribution data for managed alpine stands. **Ecological Modelling**, Amsterdam, v. 206, n. 3/4, p. 331-346, 2007.

SHOEMAKER, D. A.; CROPPER, W. P. Application of remote sensing, an artificial neural network leaf area model, and a process-based simulation model to estimate carbon storage in Florida slash pine plantations. **Journal of Forestry Research**, London, v. 21, n. 2, p. 171-176, 2010.

SILVA, A. K. V. da; BORGES, M. V. V.; BATISTA, T. S.; SILVA JUNIOR, C. A. da; FURUYA, D. E. G.; OSCO, L. P.; TEODORO, L. P. R.; BAIO, F. H. R.; RAMOS, A. P.

M.; GONÇALVES, W. N.; MARCATO JUNIOR, J.; TEODORO, P. E.; PISTORI, H. Predicting eucalyptus diameter at breast height and total height with uav-based spectral indices and machine learning. **Forests**, Basel, v. 12, n. 5, p. 1-13, 2021.

SILVA, I. N. da; SPATTI, D. H.; FLAUZINO, R. A. **Redes neurais artificiais para engenharia e ciências aplicadas**: fundamentos teóricos e aspectos práticos. 2. ed. São Paulo: Artliber, 2016. 431 p.

SILVA, J. P. M.; SILVA, M. L. M. da; MENDONÇA, A. R. de; SILVA, G. F. de; BARROS JUNIOR, A. A. de; SILVA, E. F. da; AGUIAR, M. O.; SANTOS, J. S.; RODRIGUES, N. M. M. Prognosis of forest production using machine learning techniques. **Information Processing in Agriculture**, Beijing, 2021. *In press*.

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

SILVA, W. C. M.; RIBEIRO, A.; NEVES, J. C. L.; BARROS, N. F. de; LEITE, F. P. Water balance model and eucalyptus growth simulation in the rio doce basin, Brazil. **Acta Scientiarum**. Agronomy, Maringá, v. 35, n. 4, p. 403-412, 2013.

SOCHA, J.; NETZEL, P.; CYWICKA, D. Stem taper approximation by artificial neural network and a regression set models. **Forests**, Basel, v. 11, n. 1, p. 1-14, 2020.

SONG, X.; BRYAN, B. A.; ALMEIDA, A. C.; PAUL, K. Time-dependent sensitivity of a process-based ecological model. **Ecological Modelling**, Amsterdam, v. 265, p. 114-123, 2013.

SONG, X.; BRYAN, B. A.; PAUL, K.; ZHAO, G. Variance-based sensitivity analysis of a forest growth model. **Ecological Modelling**, Amsterdam, v. 247, p. 135-143, 2012.

STAPE, J. L.; RYAN, M. G.; BINKLEY, D. Testing the 3-PG process-based model to simulate Eucalyptus growth with an objective approach to the soil fertility rating parameter. **Forest Ecology and Management**, Amsterdam, v. 193, p. 219, 2004.

SUBEDI, S.; FOX, T. R. Modeling repeated fertilizer response and one-time midrotation fertilizer response in loblolly pine plantations using FR in the 3-PG process model. **Forest Ecology and Management**, Amsterdam, v. 380, p. 90-99, 2016.

SUBEDI, S.; FOX, T. R.; WYNNE, R. H. Determination of fertility rating (FR) in the 3-PG model for loblolly pine plantations in the southeastern United States based on site index. **Forests**, Basel, v. 6, n. 9, p. 3002-3027, 2015.

SUBRAMANIAN, N.; NILSSON, U.; MOSSBERG, M.; BERGH, J. Impacts of climate change, weather extremes and alternative strategies in managed forests. **Ecoscience**, Sainte-Foy, v. 26, n. 1, p. 53-70, 2019.

TAVARES JÚNIOR, I. da S.; ROCHA, J. L. C. da; EBLING, A. A.; CHAVES, A. de S.;

ZANUNCIO, J. C.; FARIAS, A. A.; LEITE, H. G. Artificial neural networks and linear regression reduce sample intensity to predict the commercial volume of eucalyptus clones. **Forests**, Basel, v. 10, p. 2-16, 2019.

TAVARES JÚNIOR, I. da S.; TORRES, C. M. M. E.; LEITE, H. G.; CASTRO, N. L. M. de; SOARES, C. P. B.; CASTRO, R. V. O.; FARIAS, A. A. Machine learning: modeling increment in diameter of individual trees on Atlantic Forest fragments. **Ecological Indicators**, London, v. 117, p. 106685, Feb. 2020.

THORNTON, P. E.; LAW, B. E.; GHOLZ, H. L.; CLARK, K. L.; FALGE, E.; ELLSWORTH, D. S.; SPARKS, J. P. Modeling and measuring the effects of disturbance history and climate on carbon and water budgets in evergreen needleleaf forests. **Agricultural and Forest Meteorology**, Amsterdam, v. 113, n. 1/4, p. 185-222, 2002.

TICKLE, P. K.; COOPS, N. C.; HAFNER, S. D. Assessing forest productivity at local scales across a native eucalypt forest using a process model, 3PG-SPATIAL. **Forest Ecology and Management**, Amsterdam, v. 152, n. 1/3, p. 275-291, 2001a.

TICKLE, P. K.; COOPS, N. C.; HAFNER, S. D. Comparison of a forest process model (3-PG) with growth and yield models to predict productivity at Bago State Forest, NSW. **Australian Forestry**, Queen Victoria, v. 64, n. 2, p. 111-122, 2001b.

TROTSIUK, V.; HARTIG, F.; FORRESTER, D. I. r3PG - an R package for simulating forest growth using the 3-PG process-based model. **Methods in Ecology and Evolution**, London, v. 11, n. 11, p. 1470-1475, Aug. 2020.

TROTSIUK, V.; KARTIG, F.; CAILLERET, M.; BABST, F.; FORRESTER, D. I.; BALTENWEILER, A.; BUCHMANN, N.; BURGEMANN, H.; GESSLER, A.; GHARUN, M. Assessing the response of forest productivity to climate extremes in Switzerland using model-data fusion. **Global Change Biology**, Oxford, v. 26, n. 4, p. 2463-2476, 2020.

VAHEDI, A. A. Artificial neural network application in comparison with modeling allometric equations for predicting above-ground biomass in the Hyrcanian mixed-beech forests of Iran. **Biomass and Bioenergy**, Oxford, v. 88, p. 66-76, 2016.

VEGA-NIEVA, D. J.; TOMÉ, M.; TOMÉ, J.; FONTES, L.; SOARES, P.; ORTIZ, L.; BARUSCO, F.; RODRÍGUEZ-SOALLEIRO, R. Developing a general method for the estimation of the fertility rating parameter of the 3-PG model: application in Eucalyptus globulus plantations in northwestern Spain. **Canadian Journal of Forest Research**, Ottawa, v. 43, n. 7, p. 627-636, 2013.

VIEIRA, G. C.; MENDONÇA, A. R. de; SILVA, G. F. da; ZANETTI, S. S.; SILVA, M. M. da; SANTOS, A. R. dos. Prognoses of diameter and height of trees of eucalyptus using artificial intelligence. **Science of the Total Environment**, Amsterdam, v. 619/620, p. 1473-1481, 2018.

WANG, Y. P.; JARVIS, P. G. Description and validation of an array model: MAESTRO. **Agricultural and Forest Meteorology**, Amsterdam, v. 51, n. 3/4, p. 257-280, 1990.

WARING, R. H.; COOPS, N. C.; LANDSBERG, J. J. Improving predictions of forest growth using the 3-PGS model with observations made by remote sensing. **Forest Ecology and Management**, Amsterdam, v. 259, n. 9, p. 1722-1729, 2010.

WATSON, D. J. Comparative physiological studies on the growth of field crops: I., variation in net assimilation rate and leaf area between species and varieties, and within and between years. **Annals of Botany**, London, v. 11, n. 41, p. 41-76, 1947.

WEN, X.; ZHONGHUI, Z.; XIANGWEN, D.; WENHUA, X.; DALUN, T.; WENDE, Y.; XIALU, Z.; CHANGHUI, P. Applying an artificial neural network to simulate and predict Chinese fir (*Cunninghamia lanceolata*) plantation carbon flux in subtropical China. **Ecological Modelling**, Amsterdam, v. 294, p. 19-26, 2014.

WEST, P. W. **Tree and forest measurement**. 2nd ed. Berlin: Springer, 2009.

WHITE, J. D.; SCOTT, N. A.; HIRSCH, A. I.; RUNNIN, S. W. 3-PG productivity modeling of regenerating Amazon forests: climate sensitivity and comparison with MODIS-derived NPP. **Earth Interactions**, Miami, v. 10, n. 8, p. 1-26, 2006.

WHITEHEAD, D.; HALL, G. M. J.; WALCROFT, A. S.; BROWN, K. J.; LANDSBERG, J. J.; TISSUE, D. T.; TURNBULL, M. H.; GRIFFIN, K. L.; SCHUSTER, W. S. F.; CARSWELL, F. E.; TROTTER, C. M.; JAMES, I. J.; NORTON, D. A. Analysis of the growth of rimu (*Dacrydium cupressinum*) in South Westland, New Zealand, using process-based simulation models. **International Journal of Biometeorology**, Lisse, v. 46, n. 2, p. 66-75, 2002.

WILSON, A. T.; CALVIN, M. The photosynthetic cycle: CO₂ dependent transients. **Journal of the American Chemical Society**, Easton, v. 77, n. 22, p. 5948-5957, 1955.

WIT, C. T. de. Potential photosynthesis of crop surfaces. **Netherlands Journal of Agricultural Science**, Amsterdam, v. 7, n. 2, p. 141-149, 1959.

XENAKIS, G.; RAY, D.; MENCUCCINI, M. Sensitivity and uncertainty analysis from a coupled 3-PG and soil organic matter decomposition model. **Ecological Modelling**, Amsterdam, v. 219, n. 1/2, p. 1-16, 2008.

XIE, Y.; WANG, H.; LEI, X. Application of the 3-PG model to predict growth of *Larix olgensis* plantations in northeastern China. **Forest Ecology and Management**, Amsterdam, v. 406, p. 208-218, Sept. 2017.

XIE, Y.; WANG, H.; LEI, X. Simulation of climate change and thinning effects on productivity of *Larix olgensis* plantations in northeast China using 3-PGmix model. **Journal of Environmental Management**, New York, v. 261, p. 110249, Feb. 2020.

ZHAO, M.; XIANG, W.; PENG, C.; TIAN, D. Simulating age-related changes in

carbon storage and allocation in a Chinese fir plantation growing in southern China using the 3-PG model. **Forest Ecology and Management**, Amsterdam, v. 257, n. 6, p. 1520-1531, 2009.

CAPÍTULO II - USO DE REDES NEURAS ARTIFICIAIS NO MODELO 3-PG

RESUMO: Diante dos novos desafios frente à produtividade dos plantios florestais no Brasil, os modelos com abordagem processual se tornaram ferramentas essenciais para o planejamento e manejo das florestas. Esses modelos permitem avaliar o efeito de mudanças operacionais ou climáticas na produtividade de um plantio florestal. O modelo 3-PG é um modelo processual de caráter híbrido, por estar associado a modelos de regressão para cálculo da altura total média e volume do povoamento. Porém, existem aspectos do modelo que precisam ser aprimorados, como o cálculo das variáveis dendrométricas e predições de parâmetros. Neste trabalho testamos a eficiência das redes neurais artificiais (RNA) para prever o diâmetro médio à 1,30 m de altura (D), altura total e volume do povoamento, bem como as biomassas de raiz, fuste e folha diretamente. Também foi avaliado o desempenho das redes para prever dois parâmetros presentes na relação que determina a proporção de biomassa a ser alocada entre folha e fuste (a_p e n_p). A partir de parametrizações coletadas na literatura, foi possível gerar um banco de dados para alimentar as redes e avaliar diferentes combinações entre variáveis para compor os modelos de RNA. Foi realizada validação das redes a partir de dados observados em dois municípios de MG e foram gerados mapas de produtividade potencial para o Brasil, para avaliar o desempenho do modelo 3-PG + RNA. As estimativas do modelo 3-PG foram consistentes com as características climáticas de cada região e o ajuste de um modelo sigmoide as estimativas de volume permitiram ampliar as possibilidades de interpretações sobre as saídas geradas pelo 3-PG. Todas as redes apresentaram resultados estatísticos satisfatórios, principalmente para prever os parâmetros a_p e n_p , e as variáveis biomassa de folha, D , altura total e volume do povoamento. O emprego das redes neurais artificiais integradas ao 3-PG, ou outro modelo processual, é uma alternativa promissora para melhorar a precisão das estimativas, em especial àquelas de interesse para o manejo florestal. Além disso, com os avanços tecnológicos, as redes podem ser uma forma mais simples e flexível para inserir e relacionar variáveis importantes em um modelo processual.

Palavras-chave: Modelo processual híbrido. *Eucalyptus*. Manejo Florestal. Aprendizado de máquina.

USE OF ARTIFICIAL NEURAL NETWORKS IN THE 3-PG MODEL

ABSTRACT: Given the new challenges facing the forest plantations productivity in Brazil, process-based models have become essential tools for planning and managing forests. These models make it possible to assess the effect of operational or climatic changes on a forest plantation productivity. The 3-PG model is a process-based/hybrid model, as it is associated with allometric models to make average total height and stand volume estimates. However, there are parts of the model that need to be improved, such as the dendrometric variables and parameters estimates. In this work we tested the artificial neural networks (ANN) efficiency to predict the average diameter at 1.30 m height (D), total height and stand volume, as well as the directly prediction of root, stem and foliage biomass. The networks performance to predict two parameters present in the relationship that determines the proportion of biomass to be allocated between foliage and stem (a_p and n_p) was also evaluated. It was possible to generate a database from parameterizations, selected in the literature, to train the networks and evaluate different combinations between variables to compose the structure of the ANN models. Validation of the networks was carried out based on observed data in two municipalities in MG. And potential productivity maps for Brazil at 6 and 7 years were also generated to evaluate the performance of the 3-PG + RNA model. The 3-PG estimates were consistent with the climatic characteristics of each region and the fit of a sigmoid model to the volume estimates allowed to expand the possibilities of interpretations about the outputs generated by the 3-PG. All ANNs presented satisfactory statistical results, mainly to predict the a_p and n_p parameters, foliage biomass, D , total height and stand volume. The use of artificial neural networks integrated to the 3-PG model or another process-based model is a promising alternative to improve the accuracy of estimates, especially those of interest for forest management. Furthermore, with technological advances, neural networks can be a simpler and more flexible way to insert and relate important variables in a process-based model. Parameters and 3-PG outputs can be efficiently predicted using artificial neural networks.

Keywords: Process-based/hybrid model. *Eucalyptus*. Forest management. Machine learning.

1 INTRODUÇÃO

A produtividade média dos plantios de eucalipto no Brasil não tem aumentado como em décadas passadas. Existe um motivo óbvio e diversos outros com maior ou menor possibilidade de confirmação. O motivo óbvio é que no início não existia experiência com a cultura no Brasil e que não é factível esperar grandes ganhos de produtividade por diversas décadas; é um processo natural ter ganhos cada vez menores em relação às produtividades havidas ao final da rotação, desde o início do cultivo no país.

Há alguns anos havia uma expectativa de se atingir altíssimas produtividades. De fato, em alguns locais muito específicos são conseguidas produtividades incríveis, mas na média, para grandes áreas, isto não ocorre por motivos diversos. Um dos motivos é que à medida em ocorre a expansão da área de cultivo há uma grande probabilidade de se plantar em locais relativamente piores (CAMPOE *et al.*, 2020). O outro é que já houve uma evolução muito expressiva em termos de melhoramento genético e fertilização, além de tratos silviculturais. Ou seja, não são esperados saltos expressivos de produtividade ao final da rotação com investimentos em melhoramento, silvicultura clonal e práticas silviculturais.

Os ganhos de produtividade sempre serão esperados, mas a cada ano os deltas são naturalmente menores. Soma-se a isto as mudanças climáticas que sempre ocorrem e que, mais recentemente, tem impactado bastante o desenvolvimento dos povoamentos (ALMEIDA *et al.*, 2009; BAESSO; RIBEIRO; SILVA, 2010; ELLI *et al.*, 2020). Há ainda influências relacionadas às decisões de manejo (GONÇALVES *et al.*, 2004; LÓPEZ *et al.*, 2018; WATERWORTH *et al.*, 2007) e distúrbios fisiológicos (JARDIM; JARDIM; COLODETTE, 2018; KEITH *et al.*, 2012). Por exemplo, se por algum motivo a proporção de área de talhadia aumentar, muito provavelmente a média de produtividade poderá reduzir. O fato é que a produtividade média do eucalipto em grandes áreas de cultivo, por exemplo, em cada estado, tem se mantido ou reduzido levemente.

A modelagem do crescimento e da produção florestal utilizando, também, variáveis edáficas e climáticas, aspectos fisiológicos da árvore e suas interações, é fundamental para entender sobre causas e efeitos da redução (ou aumento) da produtividade ao final da rotação (LANDSBERG, 2003a, 2003b). Por exemplo, modelos processuais de caráter híbrido permitem quantificar a produção de

biomassa dos diferentes compartimentos das árvores, a partir das condições do ambiente e, com isso, calcular o crescimento das dimensões das árvores (FONTES *et al.*, 2010; MÄKELÄ *et al.*, 2000).

O modelo 3PG - *Physiological Principles Predicting Growth* (LANDSBERG; WARING, 1997) está entre os modelos processuais mais usados. Ele tem sido muito difundido desde o seu desenvolvimento, por ser um modelo que contempla processos ecofisiológicos de maneira simples e eficiente, com potencial para uso no manejo florestal. São muitas pesquisas já publicadas, que comprovam sua precisão para diferentes objetivos, em especial, análises sobre gradientes climáticos, condições hídricas e efeitos das mudanças do clima na distribuição de espécies ou na produtividade florestal (ALMEIDA; LANDSBERG; SANDS, 2004; AUGUSTYNICZIK *et al.*, 2017; CALDEIRA *et al.*, 2020; COOPS; WARING, 2011; LU *et al.*, 2015; SANDS; LANDSBERG, 2002; SMETTEM *et al.*, 2013; TICKLE; COOPS; HAFNER, 2001), inclusive com adaptações do modelo para uso em florestas inequiâneas, o 3-PG_{mix} (FORRESTER; TANG, 2016), e para uso a partir de informações obtidas via sensoriamento remoto, o 3-PGS (COOPS; WARING; LANDSBERG, 1998).

No entanto, existem alguns aspectos do modelo que precisam ser aprimorados. A desconsideração do crescimento compensatório é um deles. Trata-se da mudança nos processos de alocação de biomassa em condições desfavoráveis ao crescimento, como períodos de seca. Na ocorrência de eventos dessa natureza, as árvores tendem a alocar mais biomassa para as raízes, porém quando as condições se tornam favoráveis, o processo de alocação muda novamente e mais biomassa passa a ser alocada para a parte aérea, caracterizando uma retomada do crescimento, o que causa aumentos consideráveis na taxa de crescimento. Esse crescimento compensatório é muito recorrente em plantios florestais no Brasil, mas não é considerado no modelo 3-PG.

Outro exemplo é sobre o fato do modelo 3-PG fornecer apenas o D médio, o que não satisfaz para povoamentos submetidos a desbastes e que também pressupõe que a floresta possui distribuição normal dos diâmetros. Na verdade essa distribuição tende a se aproximar mais das distribuições F ou χ^2 com o passar dos anos, as pesquisas desenvolvidas por Pontes (2011) e Stahring (2017) trabalharam com a proposta de incluir um modelo de distribuição diamétrica no 3-PG.

Além disso, existe ainda a possibilidade de acrescentar as temperaturas noturna e diurna no modelo 3-PG. Essas informações, que não são difíceis de serem obtidas, podem acrescentar interpretações sobre o ganho de carbono para a fotossíntese em dias com alta radiação solar e noites frescas. No Brasil, é frequente observações de maiores produtividades de culturas agrícolas, como soja e algodão e até mesmo plantios florestais em locais com essa característica.

Outra parte do modelo 3-PG que pode ser aprimorada é o perfil do solo, que considera apenas uma camada, como uma caixa única, e trata o relevo como plano. Esses dois aspectos são limitações não só do modelo 3-PG como de outros modelos processuais. Na presente pesquisa, buscamos colaborar no aprimoramento de alguns componentes determinísticos e relações alométricas do 3-PG, para estimar o volume e a altura total, que são baseadas apenas nas variáveis D (diâmetro a 1,3 m de altura) e no número de fustes por unidade de área. Uma possibilidade para esse aprimoramento é o emprego de métodos de aprendizado de máquina, com inclusão de diferentes tipos de variáveis, de natureza quantitativa ou qualitativa, por exemplo variáveis climáticas, edáficas, dendrométricas, de ordem silvicultural ou de cadastro florestal.

Métodos de aprendizado como redes neurais artificiais (RNA) podem representar de forma eficiente as não linearidades intrínsecas que ocorrem entre variáveis de processo, podendo conferir maior abrangência e flexibilidade ao modelo processual 3-PG. Além das relações alométricas mencionadas, há ainda um certo empirismo na calibração dos modelos, além da necessidade de um certo esforço amostral. E aí surge uma ideia: quem sabe um algoritmo de aprendizado de máquina como a RNA possa ser utilizado para modelar e prever os parâmetros do modelo 3-PG tendo como variáveis de entrada diferentes variáveis e informações do lugar onde o mesmo será aplicado.

RNA são modelos matemáticos inspirados no funcionamento do sistema nervoso, compostos por unidades de processamento chamados neurônios artificiais, que distribuídos em camadas conectadas por pesos, determinados por meio de um algoritmo de aprendizagem, geram as previsões desejadas, denominadas como saídas, obtidas a partir das variáveis preditoras presentes na camada de entrada da rede (SILVA; SPATTI; FLAUZINO, 2016; WANG, 2003).

Desde a década de 1990 foram intensificados os estudos com o uso das RNA em diferentes áreas do setor florestal, com resultados satisfatórios que comprovaram

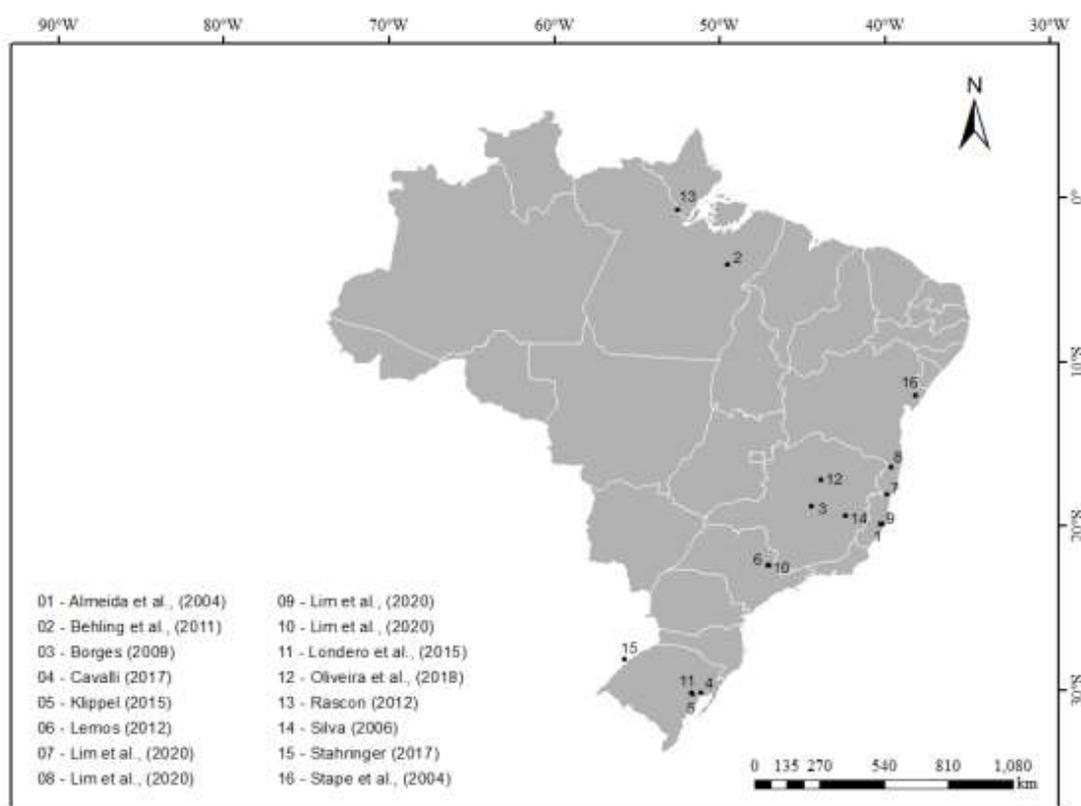
sua eficiência para diversas finalidades. Por exemplo, predição de altura de árvores em plantios clonais de eucalipto (BINOTI *et al.*, 2017), modelagem do crescimento em diâmetro ao longo do fuste em plantios de teca (LEITE *et al.*, 2011) e de eucalipto (AZEVEDO *et al.*, 2020); predição de volume de árvores a partir de dados de inventário (MIGUEL *et al.*, 2016) e a partir de dados espaciais (CORTE *et al.*, 2020; LEITE *et al.*, 2020); predição do volume com redução de esforço amostral (TAVARES JÚNIOR *et al.*, 2019); prognose em diâmetro e altura de árvores de eucalipto (VIEIRA *et al.*, 2018) e modelagem da produtividade com base em aspectos silviculturais (FREITAS *et al.*, 2020). Nesse contexto, o objetivo dessa pesquisa foi testar o uso das redes neurais artificiais para prever parâmetros e saídas do modelo 3-PG, com o uso de variáveis climáticas e ecofisiológicas, abrangendo diferentes regiões.

2 MATERIAL E MÉTODOS

2.1 Obtenção dos dados

O banco de dados usado no treinamento das RNA foi gerado pelo próprio modelo 3-PG a partir de parametrizações realizadas para diferentes regiões climáticas. Foram selecionadas parametrizações do modelo 3-PGpjs2.7 feitas para eucalipto, em diferentes regiões do Brasil e uma na Argentina, próximo ao RS (Figura 1). Nesse caso, as saídas do 3-PG foram referências para a validação das redes treinadas. As parametrizações foram selecionadas buscando abranger diferentes clones e condições climáticas, para gerar maior variabilidade de informações, de acordo com o comportamento dos povoamentos florestais em cada região.

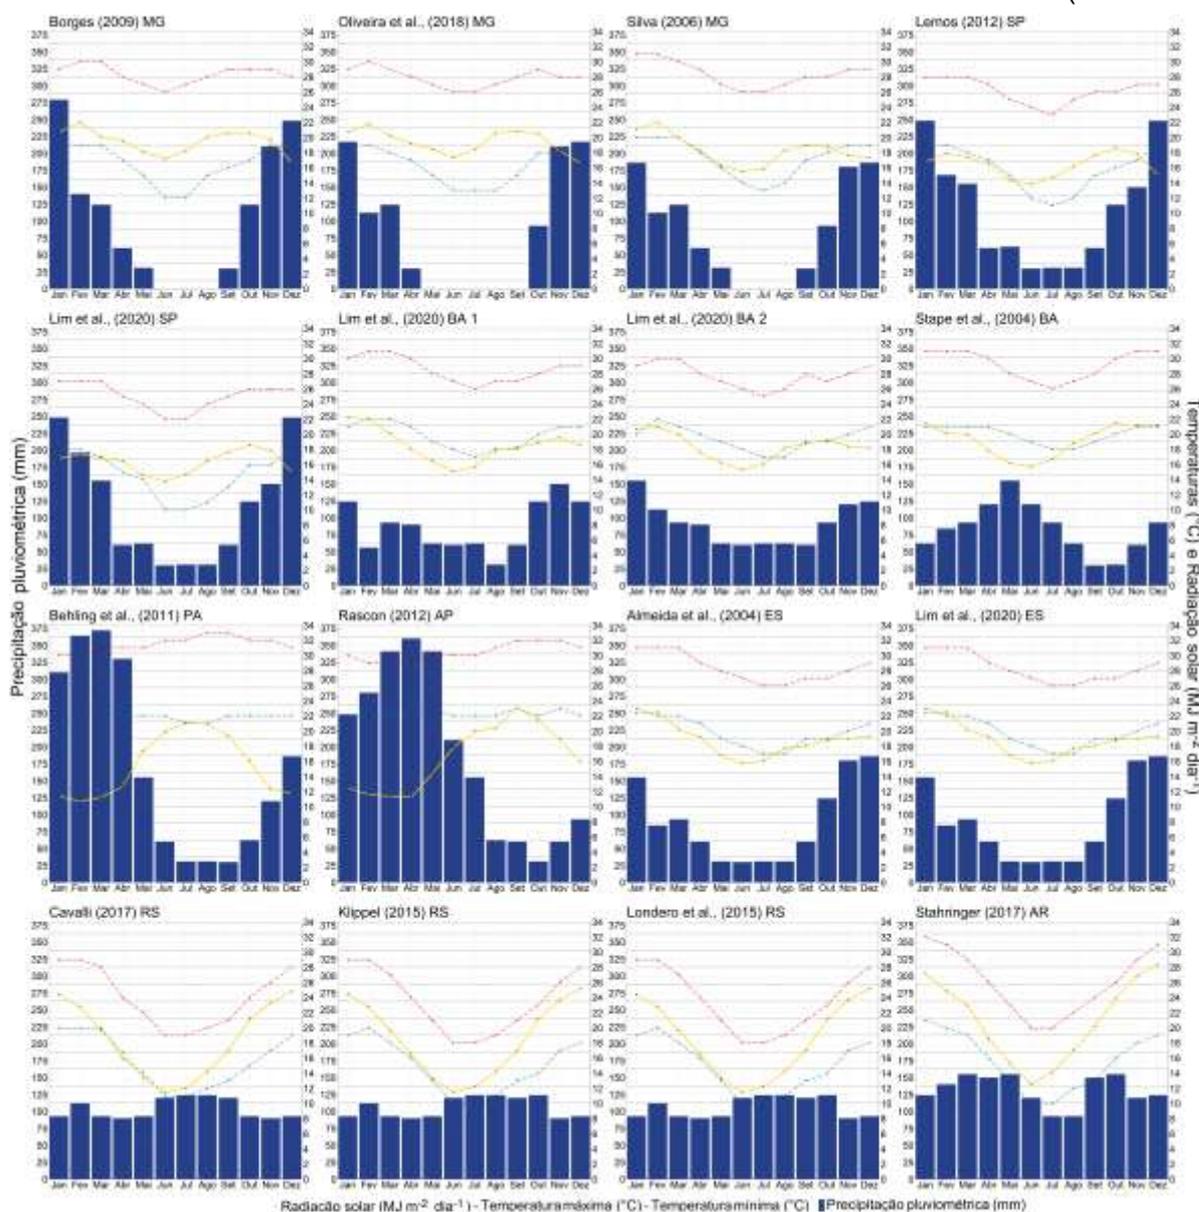
Figura 1 – Localização das parametrizações selecionadas para eucalipto. O ponto externo refere-se à parametrização realizada na Argentina.



Fonte: Elaborada pela autora.

Figura 2 - Climatograma mensal de precipitação pluviométrica (mm mês⁻¹), temperaturas mínima e máxima (°C) e radiação solar (MJ m⁻² dia⁻¹) para cada localização das parametrizações selecionadas e tipo climático de acordo com a classificação de Köppen (ALVARES *et al.*, 2013). Am = clima tropical úmido ou subúmido, Aw = clima tropical, com inverno seco, Af = clima tropical úmido ou superúmido, Cwa = clima subtropical de inverno seco e verão quente, Cfa = clima subtropical, com verão quente.

(Continua)



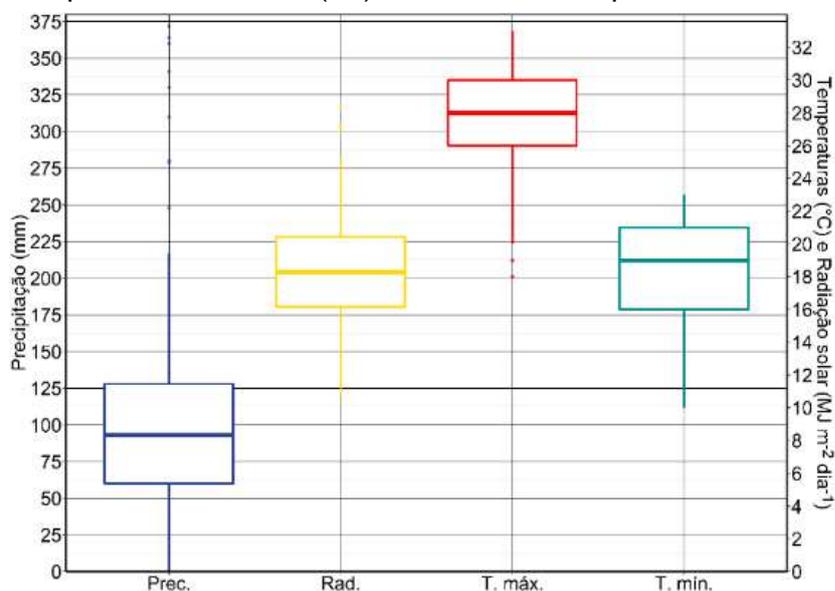
Pesquisa	Köppen	Tipo
Almeida, Landsberg e Sands (2004) ES	Am	Tropical
Behling <i>et al.</i> (2011) PA	Am	Tropical
Borges (2009) MG	Aw	Tropical
Cavalli (2017) RS	Cfa	Subtropical
Klippel (2015) RS	Cfa	Subtropical
Lemos (2012) SP	Cwa	Tropical
Lim <i>et al.</i> (2020) BA 1	Af	Tropical

Lim <i>et al.</i> (2020) BA 2	Am	Tropical
Lim <i>et al.</i> (2020) ES	Am	Tropical
Lim <i>et al.</i> (2020) SP	Cwa	Tropical
Londero <i>et al.</i> (2015) RS	Cfa	Subtropical
Oliveira <i>et al.</i> (2018) MG	Aw	Tropical
Rascon (2012) AP	Am	Tropical
Silva (2006) MG	Aw	Tropical
Stahinger (2017) AR	Cfa	Subtropical
Stape, Ryan e Binkley (2004) BA	Af	Tropical

Fonte: Elaborada pela autora.

Os dados climáticos foram provenientes da base da Organização Meteorológica Mundial para a América do Sul, com resolução de $0,5^\circ$ de latitude e de longitude, o modelo foi processado a partir de normais climatológicas de temperaturas mínima e máxima ($^\circ\text{C}$), precipitação pluviométrica (mm), radiação solar ($\text{MJ m}^{-2} \text{dia}^{-1}$) (Figuras 2 e 3) e dias com geada.

Figura 3 - Distribuição geral das variáveis climáticas. Prec. = precipitação pluviométrica mensal (mm), Rad. = Radiação solar ($\text{MJ m}^{-2} \text{dia}^{-1}$), T. máx. = Temperatura máxima ($^\circ\text{C}$) e T. mín. = Temperatura mínima ($^\circ\text{C}$).



Fonte: Elaborada pela autora.

2.2 Processamentos com o modelo 3-PG

As 16 parametrizações foram rodadas considerando características semelhantes de solo (textura média) e dados para inicialização do modelo (Tabela

1). O processamento foi realizado no *software* R (R CORE TEAM, 2020) pelo pacote r3PG (TROTSIUK; HARTIG; FORRESTER, 2020). Alteramos o valor de temperatura ótima das parametrizações para 20°C, com base nos resultados obtidos por Binkley *et al.* (2020), que verificaram maiores produtividades de eucalipto em temperaturas médias entre 19°C e 20°C.

Tabela 1 - Configurações de sítio para a inicialização dos processamentos do 3-PG.

Características para inicialização	Valor
Classe de solo	SL
Quantidade mínima de água no solo (mm)	0
Quantidade máxima de água no solo (mm)	150
Quantidade inicial de água no solo (mm)	150
Taxa de fertilidade do solo	0,8
Valor de f_N quando FR = 0	0,5
Número inicial de fustes	1111
Biomassas iniciais de fuste, folha e raiz (Mg ha ⁻¹)	1/1/1
CO ₂ atmosférico (ppm)	350
Idade final (anos)	7/20

SL = *Sandy Loam* (Areno-siltoso).

Fonte: Elaborada pela autora.

Existem duas alternativas para estimar o volume pelo modelo 3-PG, a primeira consiste em inserir entre os parâmetros requeridos pelo modelo, os parâmetros da regressão feita pelo pesquisador para a região em estudo (1), da mesma forma como é feito para a altura total. A segunda alternativa é estimar o volume em função da densidade da madeira, descontando a fração de biomassa alocada para galhos e casca (2). Esta última foi a utilizada neste trabalho como a estimava do volume pelo 3-PG, sendo que:

$$V_s = a_v D^{n_{vB}} N^{n_{vN}} + \varepsilon \quad (1)$$

$$V_s = \frac{W_s (1 - p_{BB})}{\rho} \quad (2)$$

em que: V_s = volume do povoamento sem casca (m³ ha⁻¹); a_v , n_{vB} e n_{vN} = parâmetros do modelo; D = diâmetro à 1,30 m de altura; N = número de fustes; ε = erro aleatório; p_{BB} = fração de biomassa alocada para galho e casca; W_s = biomassa de fuste (Mg ha⁻¹); ρ = densidade básica da madeira (t m⁻³).

O comportamento e consistência das simulações realizadas com o modelo 3-PG em cada região foram analisadas a partir dos gráficos de biomassa de raiz, fuste e folha, até 7 anos. E as produtividades pelos gráficos de Incremento Médio Anual (I_m) e Incremento Corrente Anual (I_c), até 20 anos. Também foram analisados os comportamentos e tendências do I_m aos 7 anos em relação à temperatura média, latitude e precipitação pluviométrica anual das 16 localizações.

A partir das produções volumétricas estimadas pelo 3-PG, foi feita uma análise dos aspectos biológicos associados às tendências de crescimento em cada região. Para isso, foi utilizado um modelo sigmoide, que permitem análises sobre as tendências das taxas de crescimento ao longo do tempo. Utilizamos o modelo de Chapman-Richards (3), que foi ajustado aos dados de volume e usado como base para a identificação dos principais pontos da curva de crescimento sigmoide: t_1 - idade de máxima aceleração do crescimento, t_2 - idade de máxima taxa de crescimento (ponto de inflexão), t_3 - idade de máxima desaceleração do crescimento e t_4 - idade de máxima produtividade média (I_m) de cada parametrização, a partir das derivadas até a quarta ordem do modelo Chapman-Richards e a derivada do I_m ao longo do tempo. A aceleração do crescimento é máxima em t_1 e nula em t_2 . A fase de crescimento t_2 , representa o momento em que a máxima taxa de crescimento é atingida, a partir de t_2 inicia-se a desaceleração do crescimento, onde o sentido de crescimento da curva sigmoide é invertido. Esta análise foi feita seguindo a metodologia proposta por Cordido (2019) e o modelo utilizado foi:

$$V_s = \beta_0(1 - e^{-\beta_1 t_i})^{\beta_2} + \varepsilon_i \quad (3)$$

em que: V_s = volume do povoamento sem casca ($m^3 \text{ ha}^{-1}$); β_0 , β_1 e β_2 = parâmetros do modelo; t_i = idade no período i (anos); ε = erro aleatório.

2.3 Configuração e treinamento das Redes Neurais Artificiais

Foram configuradas, treinadas e validadas redes neurais como alternativa às relações alométricas do modelo 3-PG e para predição direta das biomassas. As variáveis de saída foram os parâmetros da relação alométrica $p_{FS} = f(D)$ (4), que

define a proporção de biomassa a ser alocada para a parte aérea (folha/fuste), o D , a altura total, o volume e as biomassas alocadas para os compartimentos raiz (W_R), fuste (W_S) e folha (W_F). Em apenas 12 das 16 parametrizações estavam disponíveis os parâmetros para estimar a altura total. Portanto, quatro parametrizações foram descartadas para treino das redes visando prever volume e altura total.

$$n_p = \frac{\ln(p_{20} / p_2)}{\ln(20 / 2)} ; a_p = \frac{p_2}{2^{n_p}} \longrightarrow p_{FS} = a_p D^{n_p} \quad (4)$$

em que: a_p e n_p = parâmetros calculados pelo 3-PG para a relação funcional que estima o valor da p_{FS} ; p_{FS} = fração de biomassa alocada para a parte aérea; p_2 = fração de biomassa alocada para a parte aérea para um $D = 2$ cm (planta jovem); p_{20} = fração de biomassa alocada para a parte aérea para um $D = 20$ cm (planta adulta).

Foi utilizada a rede do tipo *Multilayer Perceptron* (MLP) com arquitetura *feedforward*. As variáveis de entrada testadas nas redes foram de clima e àquelas supostamente relacionadas às saídas desejadas, buscando sempre uma relação com consistência biológica e segundo a lógica da sequência de processamentos do 3-PG, bem como o uso de variáveis que facilitassem o processo de coleta de informações pelo usuário do modelo. A partir destas análises foram testadas diferentes combinações entre as variáveis com diferentes números de neurônios na camada intermediária da rede.

Os treinos foram realizados no *software* R (R CORE TEAM, 2020) pelo pacote *neuralnet* (FRITSCH; GUENTHER; GUENTHER, 2019) utilizando o algoritmo *Resilient Backpropagation* (RIEDMILLER; BRAUN, 1993) e a função de ativação logística (5). A base de dados foi normalizada para valores entre 0 e 1, pelo método de mínimos e máximos (6), e separada em 70% para treino e 30% para validação.

$$g(u) = 1 / (1 + e^{-bu}) \quad (5)$$

$$Y_{norm} = \frac{Y - \min(Y)}{\max(Y) - \min(Y)} (\max - \min) + \min \quad (6)$$

em que: $g(u)$ = sinal de saída do neurônio após a aplicação da função de ativação logística; b = constante real associada ao nível de inclinação da função logística frente ao seu ponto de inflexão; u = potencial de ativação resultante da combinação linear entre o limiar de ativação, os pesos sinápticos e as variáveis de entrada; Y = variável na unidade original; Y_{norm} = valor normalizado; $\min(Y)$ = valor mínimo da variável em unidade original; $\max(Y)$ = valor máximo da variável em unidade original; \min = valor mínimo do intervalo em que se deseja normalizar os dados (0); \max = valor máximo do intervalo em que se deseja normalizar os dados (1).

As saídas das redes foram avaliadas utilizando as estatísticas raiz quadrada do erro quadrático médio, absoluto e percentual (7 e 8), correlação de Pearson entre valores estimados pelo 3-PG e preditos pela RNA (9) com os gráficos de dispersão e frequência de casos dos erros relativos percentuais entre valores estimados pelo 3-PG e preditos pela RNA (10) e da correlação. Foi também aplicado o teste F, conforme Graybill (1976) (11), para avaliar a hipótese $H_0: [\beta_0 \ \beta_1] = [0 \ 1]$, com $Y_{3PG} = \beta_0 + \beta_1 Y_{RNA} + \varepsilon$ (PIÑEIRO *et al.*, 2008), sendo Y a variável de interesse.

$$RQEM = n^{-1} \sum_{i=1}^n (Y_{3PG_i} - Y_{RNA_i})^2 \quad (7)$$

$$RQEM(\%) = 100 \bar{Y}_{3PG}^{-1} RQEM \quad (8)$$

$$r = \frac{\sum_{i=1}^n (Y_{3PG_i} - \bar{Y}_{3PG})(Y_{RNA_i} - \bar{Y}_{RNA})}{\sqrt{\sum_{i=1}^n (Y_{3PG_i} - \bar{Y}_{3PG})^2 \sum_{i=1}^n (Y_{RNA_i} - \bar{Y}_{RNA})^2}} \quad (9)$$

$$ER\% = 100 n^{-1} \sum_{i=1}^n (Y_{RNA_i} - Y_{3PG_i}) Y_{3PG_i}^{-1} \quad (10)$$

$$F(H_0) = \frac{\left[(\beta_0 - 0)n + (\beta_1 - 1) \sum_{i=1}^n Y_{RNA_i} \right] (\beta_0 - 0) + \left[(\beta_0 - 0) \sum_{i=1}^n Y_{RNA_i} + (\beta_1 - 1) \sum_{i=1}^n Y_{RNA_i}^2 \right] (\beta_1 - 1)}{2RMS} \sim F_{\alpha}(2, n-1 \text{ g.l.}) \quad (11)$$

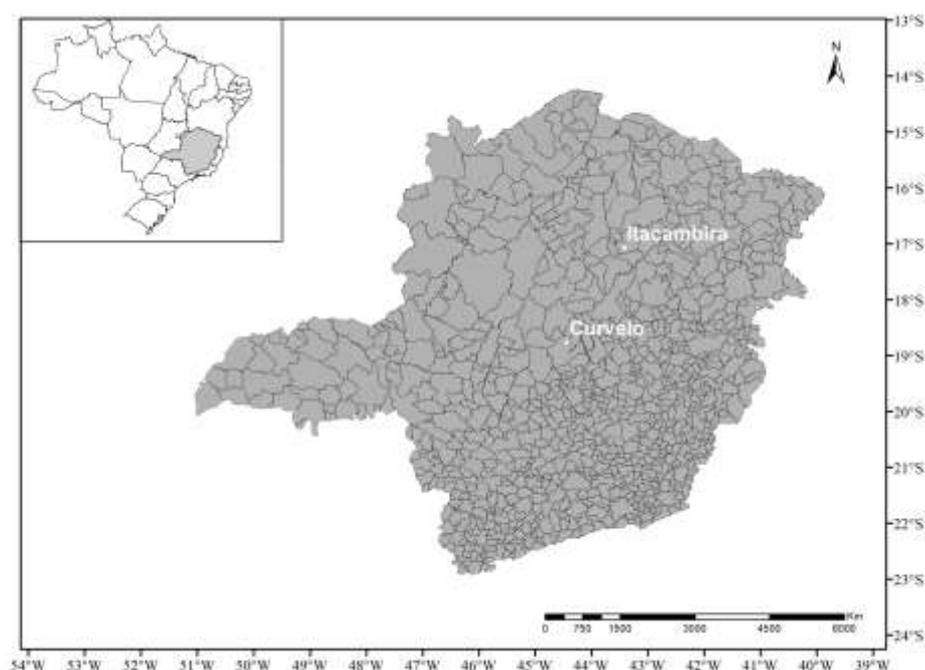
em que: Y_{3PG_i} = i-ésimo valor estimado pelo 3-PG; Y_{RNA_i} = i-ésimo valor predito pela RNA; n = número de observações; \bar{Y}_{3PG} = média dos valores estimados pelo 3-PG; \bar{Y}_{RNA} = média dos valores preditos pela RNA; β_0 e β_1 = parâmetros da regressão linear simples; RMS = quadrado médio da regressão; α = nível de significância do teste (0,05); *g.l.* = graus de liberdade.

Após a escolha das redes de melhor desempenho para prever cada uma das variáveis analisadas, foi gerado o diagrama de interpretação neural (DIN) associado ao teste de Garson (GOH, 1995), para interpretar o conjunto de pesos em relação às variáveis de entrada e saída de cada modelo.

As redes selecionadas foram aplicadas em um conjunto de dados observados para duas regiões de MG, Curvelo (18° 45' 23" S e 44° 25' 51" O a 600 m de altitude) e Itacambira (17° 03' 53" S e 43° 18' 32" O a 1100 m de altitude) (Figura 4). Os dados foram coletados em povoaamentos com clones do híbrido *Eucalyptus urophylla* x *Eucalyptus grandis* em parcelas de inventário florestal com 40 plantas (600 m²) com idades entre 1,4 e 7 anos. Com esses dados foram validadas as redes para prever os parâmetros a_p e n_p , as biomassas de fuste e de folha, D , altura total e volume, analisando o comportamento das previsões por clone. Mais detalhes podem ser encontrados em Borges (2009).

Os resultados foram avaliados pelo teste F (GRAYBILL, 1976), RQEM, correlação de Pearson, gráficos de correlação entre dados observados e preditos pela RNA, dispersão e frequência dos erros relativos percentuais entre valores observados e preditos pela RNA.

Figura 4 - Localização dos municípios referentes aos dados observados para validação das redes.



Fonte: Elaborada pela autora.

O modelo 3-PG + RNA foi aplicado em todo o Brasil para cálculo da produtividade potencial. Foi utilizada a parametrização feita por Borges (2012), em seu trabalho, foi feito um teste de universalidade das parametrizações a partir de quatro localidades, duas em MG, uma na BA e uma no litoral do ES. As quatro parametrizações foram aplicadas em cada local e o autor selecionou a parametrização para o cerrado de MG como a de maior universalidade, pois foi a que mais se aproximou dos valores observados nas quatro regiões (Tabela 2).

Tabela 2 – Parametrização de Borges (2012), usada para gerar os mapas de produtividade potencial de eucalipto no Brasil a partir da proposta 3-PG + RNA.

(Continua)

Parâmetro	Símbolo*	Unidade	Valor
Biomassa inicial de folhas	W_F	Mg ha ⁻¹	0,168
Biomassa inicial de fuste (galho + casca + lenho)	W_S	Mg ha ⁻¹	0,099
Biomassa inicial de raiz	W_R	Mg ha ⁻¹	0,106
Partição folha/fuste para $D = 2$ cm	p_2	-	1,64
Partição folha/fuste para $D = 20$ cm	p_{20}	-	0,1
Constante da relação biomassa de fuste vs D	a_S	-	0,02
Potência da relação biomassa de fuste vs D	n_S	-	3,11
Fração máxima de PPL para raízes	η_{Rx}	-	0,5
Fração mínima de PPL para raízes	η_{Rn}	-	0,1
Máxima taxa de serapilheira	γ_{F1}	mês ⁻¹	0,07
Mínima taxa de serapilheira	γ_{F0}	mês ⁻¹	0,001
Idade na qual a taxa de serapilheira tem valor médio	$t_{\gamma F}$	meses	4
Taxa média de <i>turnover</i> de raiz	γ_R	mês ⁻¹	0,015
Temperatura mínima de crescimento	T_{min}	°C	8
Temperatura ótima de crescimento	T_{opt}	°C	20/25
Temperatura máxima de crescimento	T_{max}	°C	40
Dias de produção perdidos a cada dia com geada	k_F	dias	0
Taxa de déficit de umidade para $f_\theta = 0,5$	c_θ	-	0,7
Potência da taxa de déficit de umidade	n_θ	-	9
Fator de enriquecimento da assimilação a 700 ppm	f_{Ca700}	-	1,4
Fator de enriquecimento da condutância do dossel a 700 ppm	f_{Cg700}	-	0,7
Valor de m quando FR = 0	m_0	-	0
Valor de f_N quando FR = 0	f_{N0}	-	0,5
Potência de (1-FR) em f_N	n_{fN}	-	1
Idade máxima do povoamento	t_x	anos	9
Potência da idade relativa em f_{age}	n_{age}	-	4
Idade relativa para $f_{age} = 0,5$	r_{age}	-	0,95
Taxa de mortalidade para idade madura	γ_{N1}	ano ⁻¹	0

Tabela 2 – Parametrização de Borges (2012), usada para gerar os mapas de produtividade potencial de eucalipto no Brasil a partir da proposta 3-PG + RNA.

(Conclusão)

Parâmetro	Símbolo*	Unidade	Valor
Taxa de mortalidade de mudas (t = 0)	γ_{No}	ano ⁻¹	0
Idade na qual a taxa de mortalidade tem valor médio	$t_{\gamma N}$	anos	2
Forma da resposta a mortalidade	$n_{\gamma N}$	-	1
Biomassa de fuste máxima por árvore para 1000 árvores por ha	W_{Sx1000}	kg árvore ⁻¹	300
Potência da regra de auto-desbaste	n_N	-	1,5
Fração média de biomassa de folha perdida por árvore morta	m_F	-	0
Fração média de biomassa de raiz perdida por árvore morta	m_R	-	0,2
Fração média de biomassa de fuste perdida por árvore morta	m_S	-	0,2
Área foliar específica na idade 0	σ_0	m ² kg ⁻¹	13,74
Área foliar específica para árvores maduras	σ_1	m ² kg ⁻¹	7,56
Idade na qual a área foliar específica = $(\sigma_0 + \sigma_1)/2$	t_σ	anos	1,23
Coeficiente de extinção da RFA absorvida pelo dossel	k	-	0,5
Idade de fechamento do dossel	t_c	anos	2
Proporção máxima da chuva evaporada do dossel	i_{Rx}	-	0,15
A_r para a máxima interceptação da chuva	L_{ix}	-	3,33
Eficiência quântica máxima do dossel	α_{Cx}	mol mol ⁻¹	0,08
Razão PPL/PPB	Y	-	0,5
Condutância mínima do dossel	g_{Cn}	m s ⁻¹	0
Condutância máxima do dossel	g_{Cx}	m s ⁻¹	0,02
A_r para a máxima condutância do dossel	L_{Cx}	-	3,33
Define resposta estomática ao DPV	k_D	mBar ⁻¹	0,0324
Condutância na camada limítrofe do dossel	g_B	m s ⁻¹	0,2
Fração de galho e casca na idade 0	ρ_{BB0}	-	0,59
Fração de galho e casca em idade madura	ρ_{BB1}	-	0,19
Idade na qual $\rho_{BB} = (\rho_{BB0} + \rho_{BB1})/2$	t_{BB}	anos	2,17
Densidade básica mínima da madeira (para árvores jovens)	ρ_0	t m ⁻³	0,382
Densidade básica máxima da madeira (para árvores maduras)	ρ_1	t m ⁻³	0,505
Idade na qual a densidade básica da madeira = $(\rho_0 + \rho_1)/2$	t_ρ	anos	2,264
Intercepto da relação entre radiação líquida vs radiação solar	Q_a	W m ⁻²	-90
Inclinação da relação entre radiação líquida vs radiação solar	Q_b	-	0,8
Peso molecular da matéria seca	-	g mol ⁻¹	24
Fator de conversão da radiação solar para RFA	-	mol MJ ⁻¹	2,3

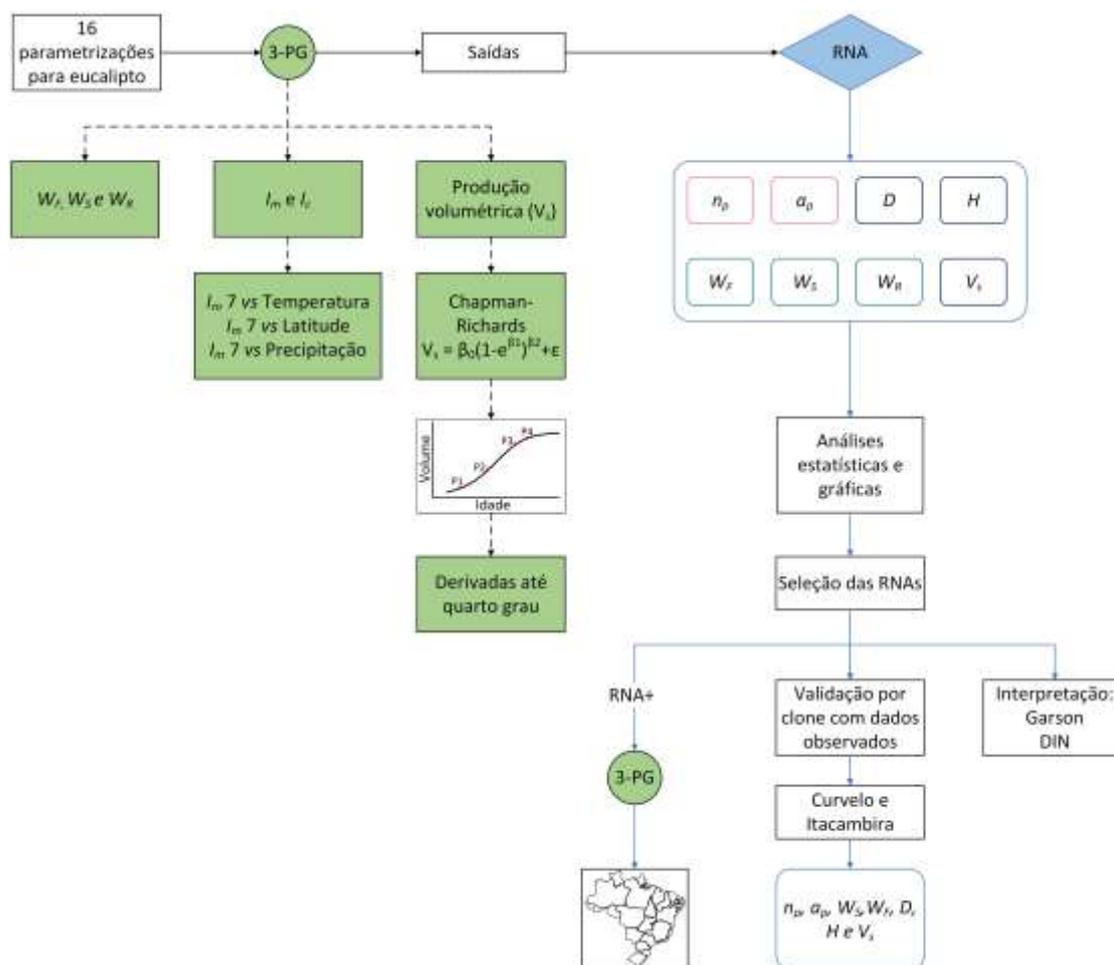
* Todos os símbolos do modelo 3-PG foram padronizados, em toda a tese, conforme Sands (2010).

Fonte: Elaborado pela autora, baseado em Borges (2012).

Esta foi a parametrização usada na presente pesquisa, porém, a altura total e o volume do povoamento foram calculados com as redes neurais artificiais integradas ao 3-PG. Considerou-se $FR = 1$, classe de solo com textura média (*Sandy Loam*), a quantidade máxima de água disponível no solo foi de 100 e 150 mm e a temperatura ótima de 20 e 25°C. O treinamento das redes foi realizado com um banco de dados definido a partir de processamentos com o modelo 3-PG, considerando 150 mm, como o máximo de água disponível no solo e 20°C, como temperatura ótima. Embora alguns trabalhos mostrem não haver diferenças significativas em relação a quantidade máxima de água disponível no solo (ESPREY; SANDS; SMITH, 2004; NIGHTINGALE *et al.*, 2007), optamos por usar duas configurações para comparar os resultados, assim como na temperatura ótima, chegando a oito mapas diferentes com produtividades aos 6 e 7 anos.

Os dados climáticos, para todo o Brasil, foram provenientes da base da Organização Meteorológica Mundial para a América do Sul, com resolução de 0,5° de latitude e de longitude, o modelo foi processado a partir de normais climatológicas. Um resumo de todo o processamento realizado está apresentado na Figura 5.

Figura 5 - Sequência de todos os processamentos realizados.



Fonte: Elaborada pela autora.

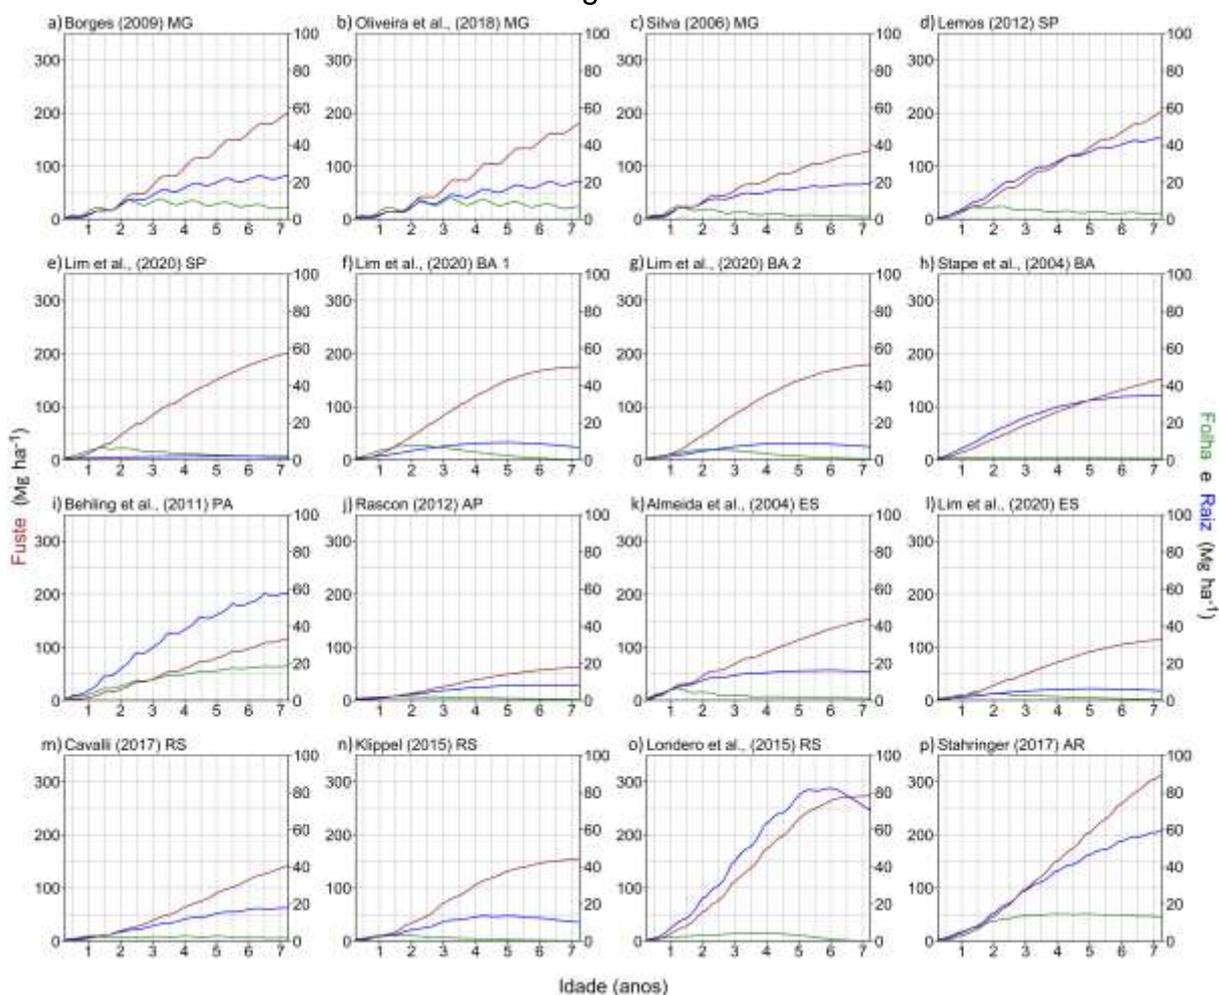
3 RESULTADOS

3.1 Processamentos com o modelo 3-PG

As biomassas de raiz, fuste e folha estimadas pelo 3-PG para cada região, apresentaram tendências diferentes de acordo, principalmente, com o genótipo e as características climáticas de cada sítio, já que as condições de solo foram mantidas as mesmas. As menores estimativas de biomassa de fuste foram para a região norte do Brasil, nos estados do Amapá (j) e Pará (i) e uma ao sudeste, no Espírito Santo (l), atingindo 62,18; 113,51 e 113,78 Mg ha⁻¹ aos 7 anos, respectivamente. Maiores produções de biomassa de fuste ocorreram na Argentina (p → 304,00 Mg ha⁻¹), Rio Grande do Sul (o → 273,11 Mg ha⁻¹) e em dois sítios em São Paulo (d → 197,97 Mg ha⁻¹; e → 194,00 Mg ha⁻¹), as demais regiões foram intermediárias, com produções entre 126 e 191 Mg ha⁻¹ de biomassa de fuste aos 7 anos (Figura 6).

As estimativas de biomassa para as regiões de Minas Gerais (a, b, c) apresentaram tendências semelhantes, com maior oscilação dos valores de biomassa ao longo do tempo e maiores biomassas de fuste e folha nas regiões central e norte do estado (a, b). No estado de São Paulo (d, e) foram consideradas regiões próximas, porém as estimativas de biomassa de raiz foram maiores na região de Mogi-Guaçu (d). Regiões ao sul da BA (f, g) apresentaram maiores estimativas de biomassa de fuste em relação ao litoral norte da Bahia (h) e, em geral, houveram menores oscilações. As biomassas de folha corresponderam aos menores valores, atingindo maiores produções na Argentina (p) e no Pará (i).

Figura 6 - Estimativas das biomassas de raiz, fuste e folha para as 16 parametrizações selecionadas na literatura. MG = Minas Gerais, BA = Bahia, BA 1,2 = parametrizações em duas regiões diferentes da Bahia pelo mesmo autor, PA = Pará, AP = Amapá, ES = Espírito Santo, RS = Rio Grande do Sul e AR = Argentina.

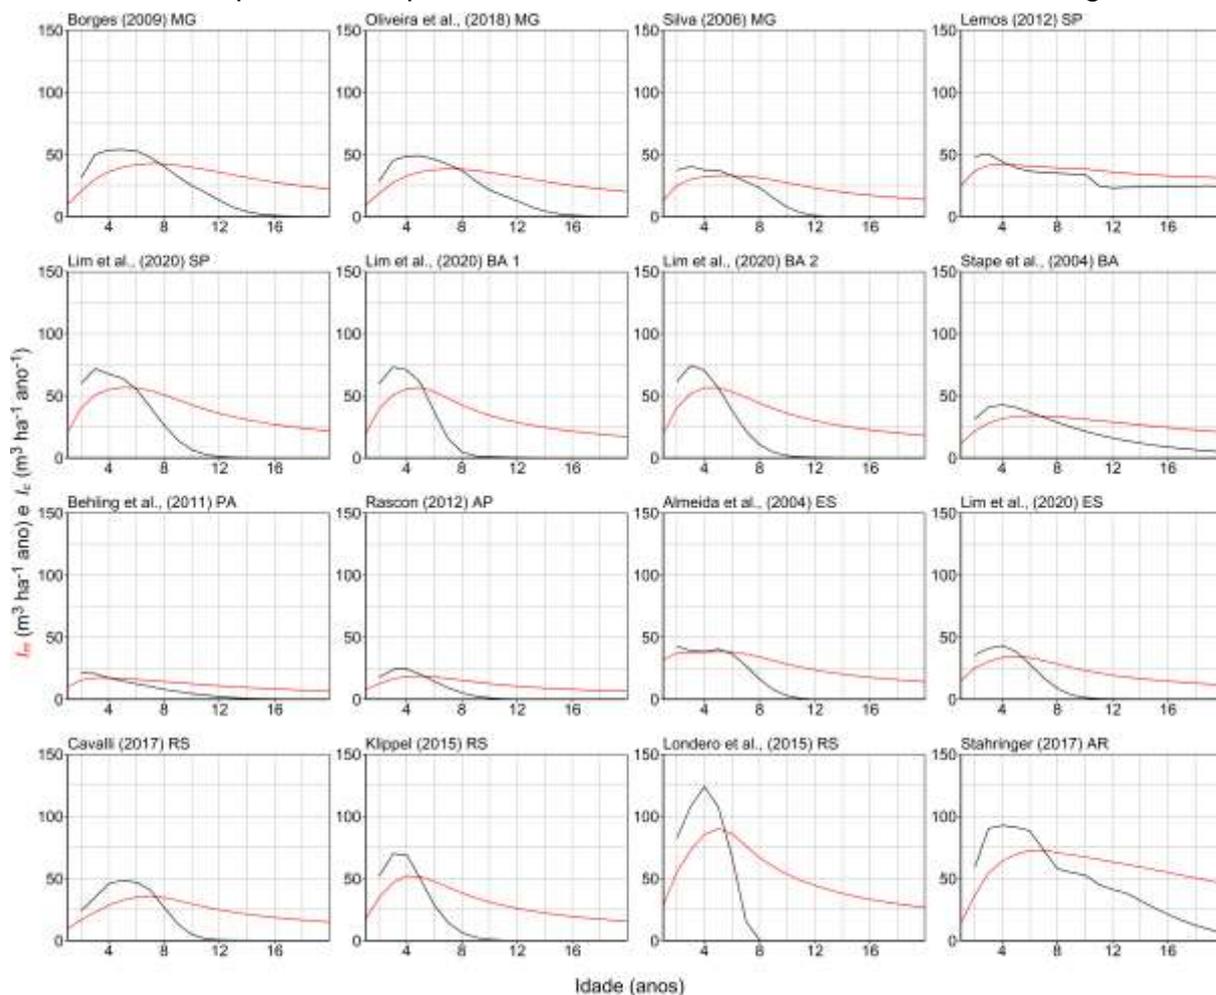


Fonte: Elaborada pela autora.

O comportamento das curvas de l_c e de l_m apresentaram tendência conforme o esperado (Figura 7), com produtividade média global aos 7 anos ($l_m 7$) de $41,60 \text{ m}^3 \text{ ha}^{-1} \text{ ano}$. Na Figura 8 é possível observar que, em geral, as produtividades reduziram com o aumento da temperatura (a) e foram mais altas em maiores latitudes (b), já o aumento da precipitação pluviométrica mostra uma redução da produtividade (c), porém o β_1 foi não significativo, e ao desconsiderar as regiões ao norte do Brasil, o β_1 passa a ser positivo e estatisticamente significativo (d). Os sítios mais produtivos foram aqueles localizados a leste do Rio Grande do Sul ($76,08 \text{ m}^3 \text{ ha}^{-1} \text{ ano}$), Argentina ($72,58 \text{ m}^3 \text{ ha}^{-1} \text{ ano}$), leste de São Paulo ($54,28 \text{ m}^3 \text{ ha}^{-1} \text{ ano}$) e sul da Bahia ($48,90$ e $47,94 \text{ m}^3 \text{ ha}^{-1} \text{ ano}$) e os menos produtivos ao norte do Brasil,

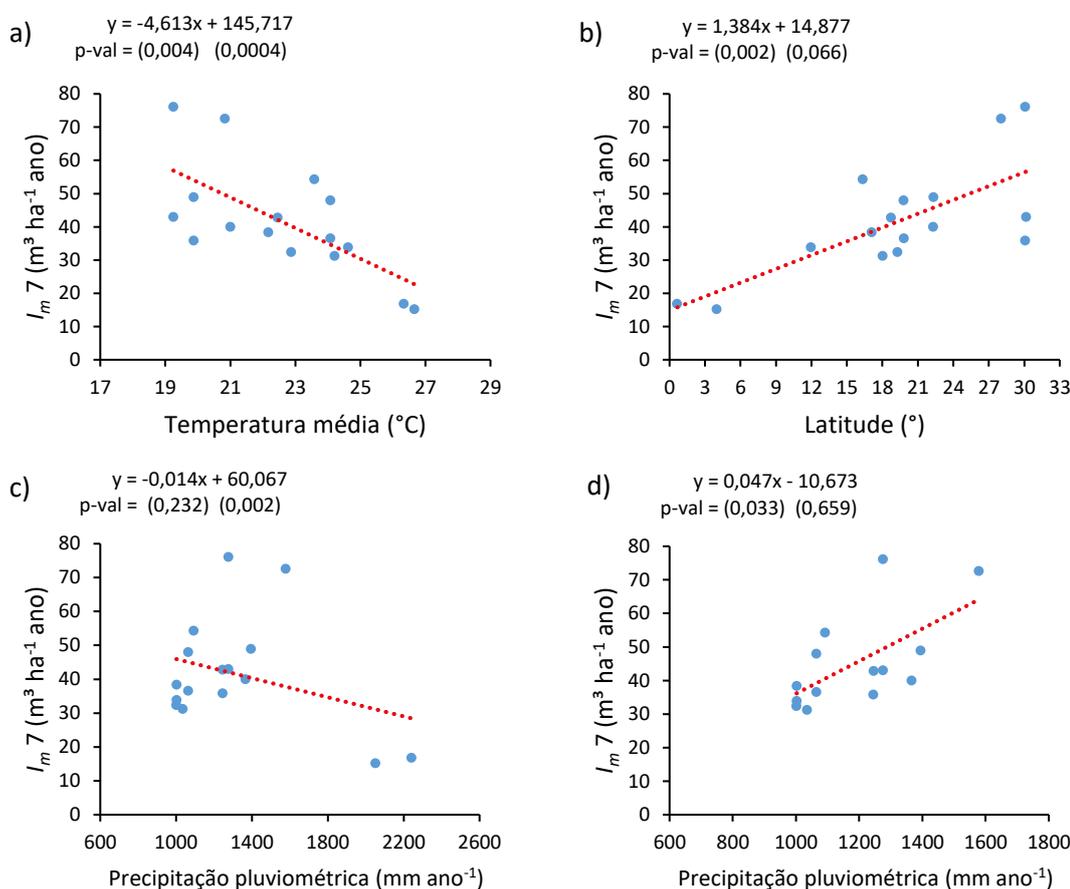
no sul do Amapá ($16,78 \text{ m}^3 \text{ ha}^{-1} \text{ ano}$) e sudeste do Pará ($15,20 \text{ m}^3 \text{ ha}^{-1} \text{ ano}$) (Figura 8).

Figura 7 - Estimativas do I_c e do I_m pelo modelo 3-PG para as 16 parametrizações analisadas. MG = Minas Gerais, BA = Bahia, BA 1 e 2 = parametrizações em duas regiões diferentes da Bahia pelo mesmo autor, PA = Pará, AP = Amapá, ES = Espírito Santo, RS = Rio Grande do Sul e AR = Argentina.



Fonte: Elaborada pela autora.

Figura 8 - Comportamento da produtividade média aos 7 anos ($I_m 7$), estimada pelo 3-PG, para as 16 parametrizações selecionadas em relação à latitude (a), temperatura média (b), precipitação pluviométrica (c) e precipitação pluviométrica sem considerar as duas regiões ao norte do país (d), valores tabelados estão ordenados por latitude.



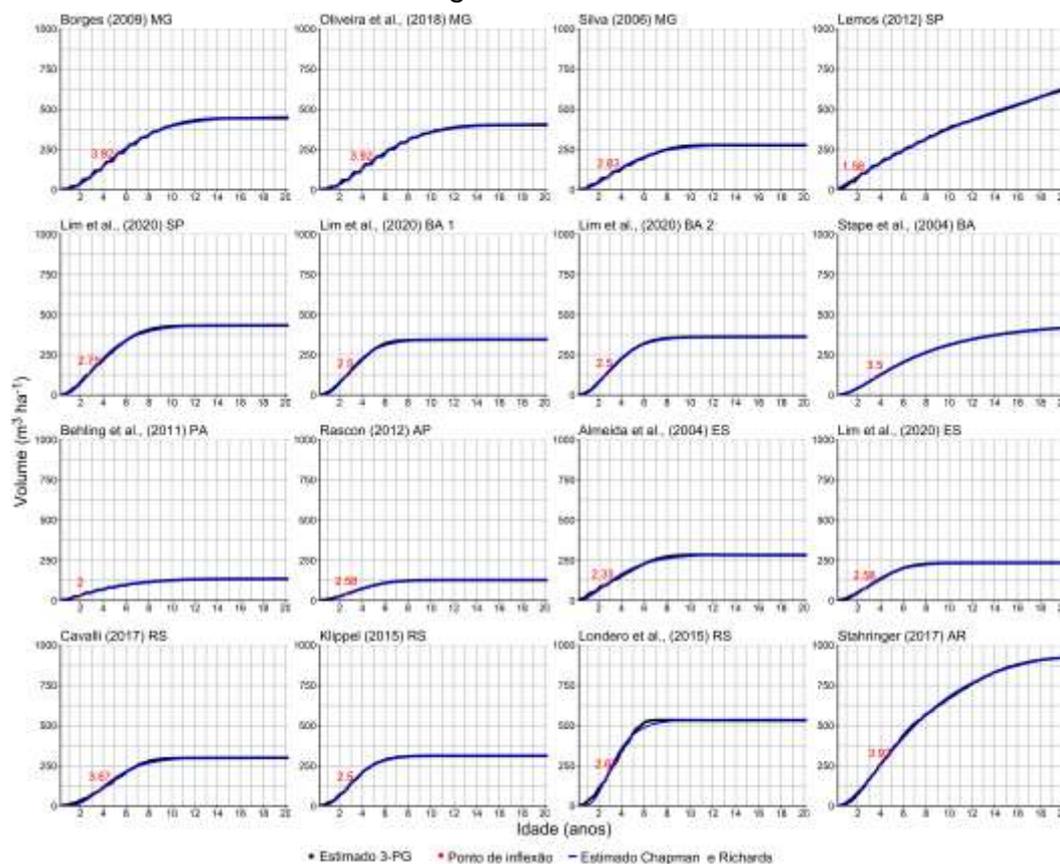
Pesquisa	$I_m 7$ ($m^3 ha^{-1} ano$)
Rascon (2012) AP	16,78
Behling <i>et al.</i> (2011) PA	15,20
Stape, Ryan e Binkley (2004) BA	33,84
Lim <i>et al.</i> (2020) BA 2	48,90
Oliveira <i>et al.</i> (2018) MG	38,36
Lim <i>et al.</i> (2020) BA 1	47,94
Borges (2009) MG	42,78
Silva (2006) MG	32,36
Lim <i>et al.</i> (2020) ES	31,19
Almeida, Landsberg e Sands (2004) ES	36,54
Lemos (2012) SP	39,94
Lim <i>et al.</i> (2020) SP	54,28
Stahringer (2017) AR	72,58
Londero <i>et al.</i> (2015) RS	76,08
Cavalli (2017) RS	35,81
Klippel (2015) RS	42,97

Fonte: Elaborada pela autora.

As estimativas de volume geradas pelo modelo 3-PG resultaram em tendências sigmoidais. Os pontos indicativos das fases de crescimento variaram conforme o clima e genótipo. Esses pontos ou idades que descrevem todas as fases de crescimento foram explorados e explicados por Cordido (2019). Em seu estudo, Cordido (2019) demonstrou matematicamente os momentos de máxima taxa, aceleração e desaceleração do crescimento, por meio de derivadas de primeira a terceira ordem do modelo logístico. Aqui seguimos os desenvolvimentos desse autor, porém, utilizando as respostas do modelo 3-PG suavizadas pelo modelo Chapman-Richards (C-H).

Utilizando as derivadas de primeira à quarta ordem do modelo C-H foram identificadas as idades de máxima produtividade média, máxima taxa de crescimento e máximas taxas de aceleração e de desaceleração do crescimento. Em geral, os sítios com as menores idades de máxima taxa de crescimento (t_2 = ponto de inflexão), apresentaram também as menores idades de máxima aceleração do crescimento (t_1), com exceção das regiões no litoral norte da Bahia (h) e na Argentina (p). Quanto maior a rotação, maiores foram as idades de máxima taxa de crescimento (t_2); o mesmo foi observado em relação à idade de desaceleração máxima do crescimento (t_3), exceto na região leste de São Paulo (d). A idade de máxima aceleração do crescimento variou de 0,1 a 1,8 anos, os pontos de inflexão (máxima taxa de crescimento) entre 1,6 e 3,9 anos, as idades de máxima desaceleração entre 3,9 e 7,8 anos e o máximo I_m entre 3,2 e 7,10 anos (Figuras 9 e 10).

Figura 9 - Ajuste do modelo Chapman e Richards ($Y = \beta_0(1 - e^{\beta_1 t})^{\beta_2} + \varepsilon$). β_0 ; β_1 e β_2 = parâmetros do modelo, r_{YY} = correlação entre dados estimados pelo 3-PG e pelo modelo sigmoide, $S_{y.x}$ = erro padrão residual; Pto. Inf. = idade correspondente ao ponto de inflexão, MG = Minas Gerais, BA = Bahia, BA 1,2 = parametrizações em duas regiões diferentes da Bahia pelo mesmo autor, PA = Pará, AP = Amapá, ES = Espírito Santo, RS = Rio Grande do Sul e AR = Argentina.



Pesquisa	β_0	β_1	β_2	r_{YY}	$S_{y.x}$ (%)	Pto. Inf.
Almeida, Landsberg e Sands (2004) ES	287,28	-0,41	2,58	0,9964	3,10	2,33
Behling <i>et al.</i> (2011) PA	135,91	-0,31	1,85	0,9994	1,28	2,00
Borges (2009) MG	454,82	-0,32	3,45	0,9991	2,02	3,92
Cavalli (2017) RS	302,63	-0,48	5,82	0,9979	3,03	3,67
Klippel (2015) RS	312,58	-0,65	5,10	0,9993	1,42	2,50
Lemos (2012) SP	921,61	-0,06	1,10	0,9993	1,88	1,58
Lim <i>et al.</i> (2020) ES	235,30	-0,52	3,79	0,9988	1,89	2,58
Lim <i>et al.</i> (2020) SP	437,03	-0,44	3,43	0,9989	1,87	2,75
Lim <i>et al.</i> (2020) BA 1	346,62	-0,62	4,69	0,9989	1,74	2,50
Lim <i>et al.</i> (2020) BA 2	363,46	-0,56	4,00	0,9995	1,22	2,50
Londero <i>et al.</i> (2015) RS	536,42	-0,71	6,76	0,9972	2,83	2,67
Oliveira <i>et al.</i> (2018) MG	411,36	-0,31	3,34	0,9991	1,99	3,92
Rascon (2012) AP	127,79	-0,52	3,86	0,9992	1,59	2,58
Silva (2006) MG	280,69	-0,39	3,05	0,9980	2,56	2,83
Stahringer (2017) AR	978,91	-0,18	2,02	0,9997	1,27	3,92
Stape, Ryan e Binkley (2004) BA	434,80	-0,18	1,90	0,9999	0,60	3,50

Fonte: Elaborada pela autora.

Figura 10 – Curvas de produção (Y), crescimento (Y'), aceleração do crescimento (Y''), taxa de aceleração (Y'''), ponto de mínima taxa de aceleração (Y'''') e produtividade média (I_m) obtidas ao ajustar o modelo Chapman-Richards ($Y = \beta_0(1 - e^{-\beta_1 t})^{\beta_2} + \varepsilon$) às saídas de volume do modelo 3-PG por cada parametrização.

a) Borges (2009) MG

b) Oliveira *et al.* (2018) MG

t1: Idade de máxima aceleração do crescimento = 1,3 anos

t1: Idade de máxima aceleração do crescimento = 1,3 anos

t2: Idade de máxima taxa de crescimento = 3,9 anos

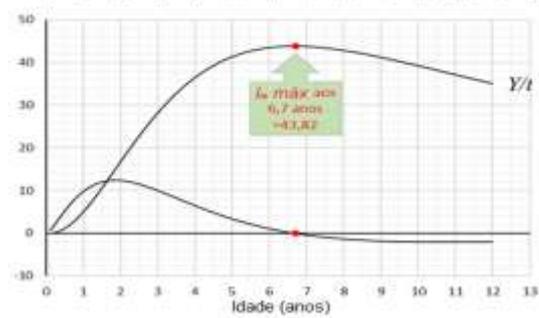
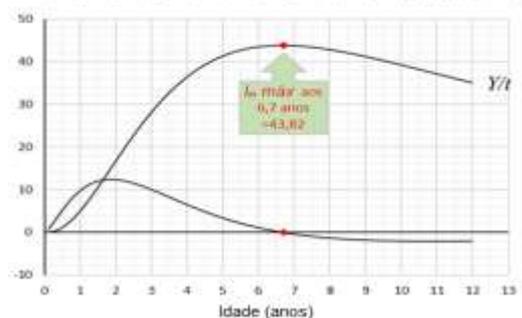
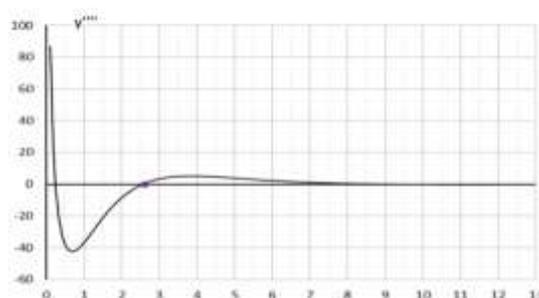
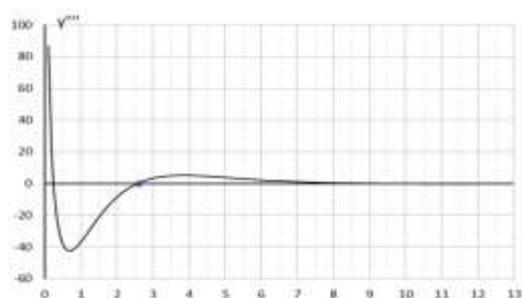
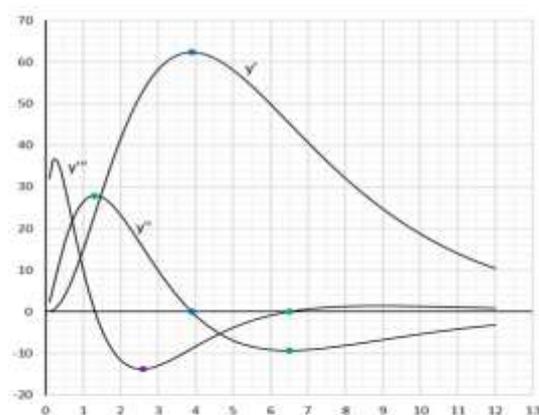
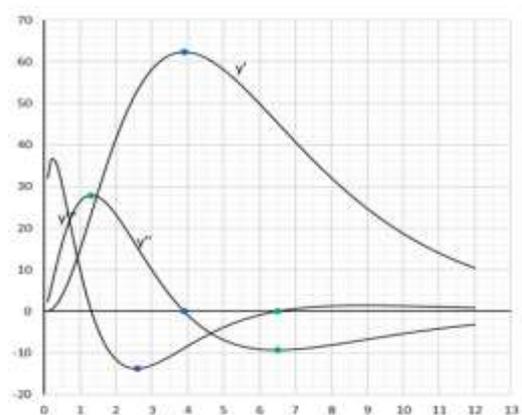
t2: Idade de máxima taxa de crescimento = 3,9 anos

t3: Idade de máxima desaceleração do crescimento = 6,5 anos

t3: Idade de máxima desaceleração do crescimento = 6,5 anos

Idade de máxima produtividade média (I_m) = 6,7 anos

Idade de máxima produtividade média (I_m) = 6,7 anos

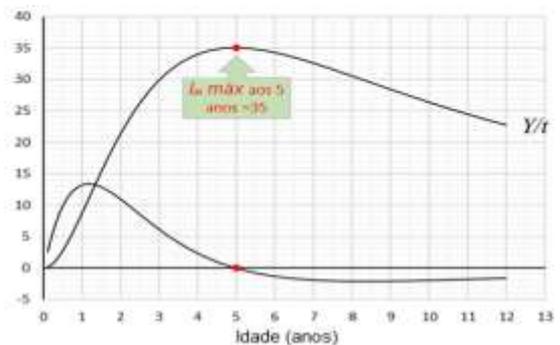
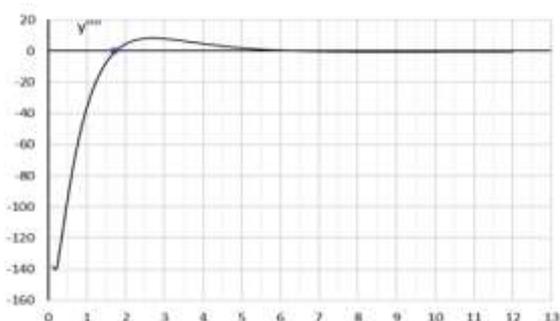
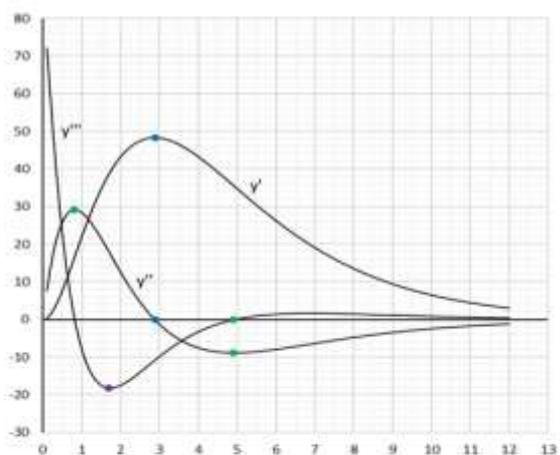


c) Silva (2006) MG

t1: Idade de máxima aceleração do crescimento = 0,8 anos

t2: Idade de máxima taxa de crescimento = 2,9 anos

t3: Idade de máxima desaceleração do crescimento = 4,9 anos

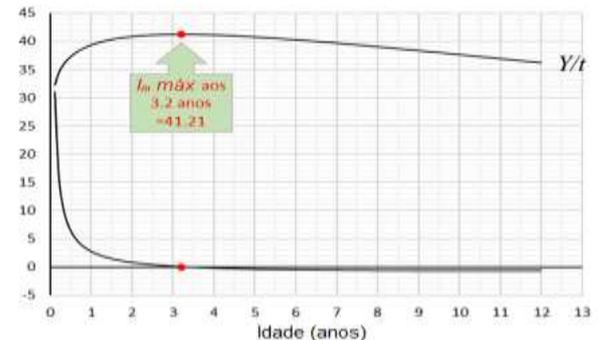
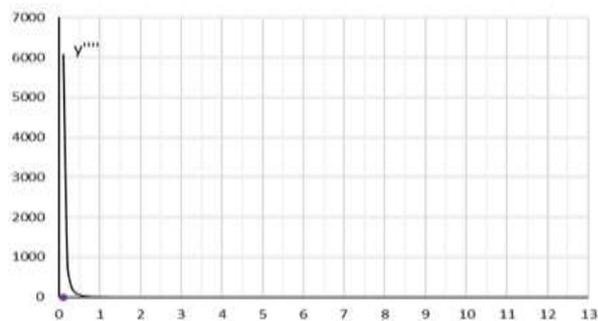
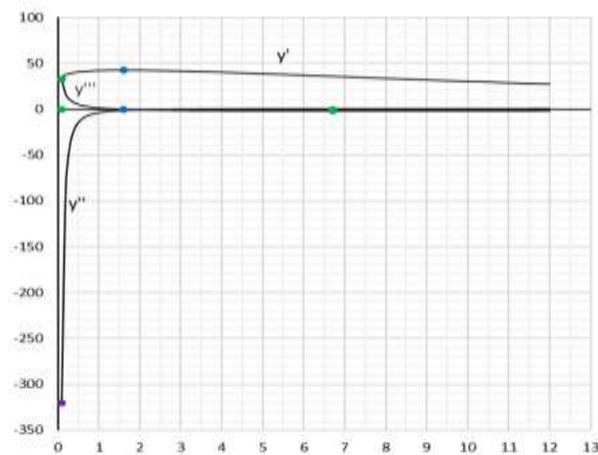
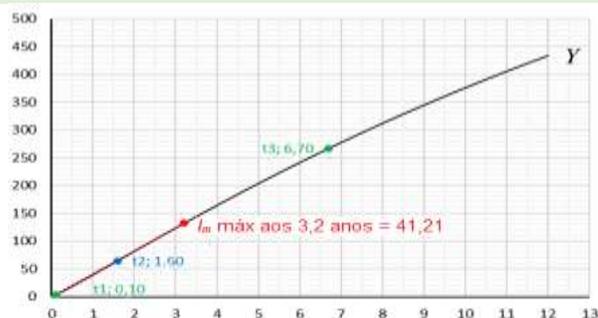
Idade de máxima produtividade média (I_m) = 5 anos

d) Lemos (2012) SP

t1: Idade de máxima aceleração do crescimento = 0,1 anos

t2: Idade de máxima taxa de crescimento = 1,6 anos

t3: Idade de máxima desaceleração do crescimento = 6,7 anos

Idade de máxima produtividade média (I_m) = 3,2 anos

e) Lim et al. (2020) SP

f) Lim et al. (2020) BA 1

t1: Idade de máxima aceleração do crescimento = 0,9 anos

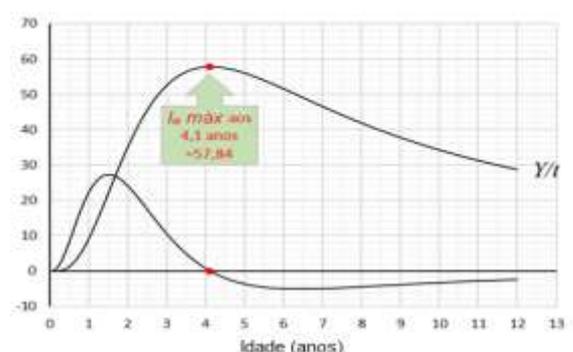
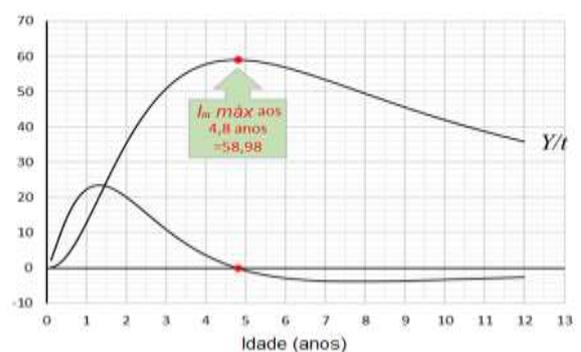
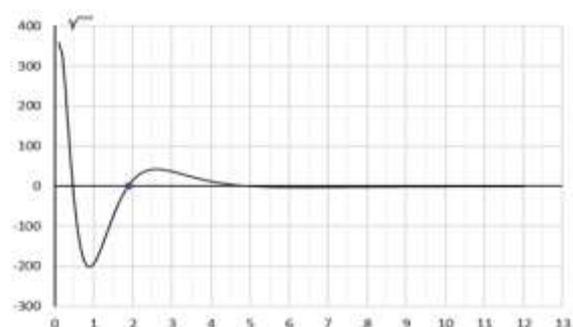
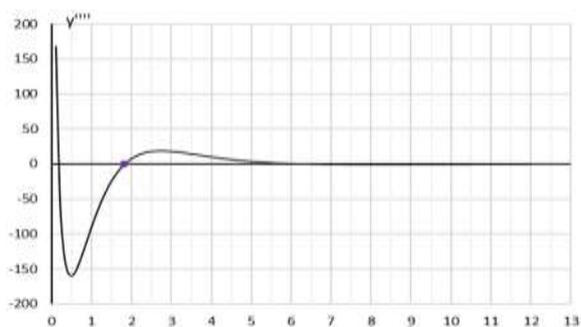
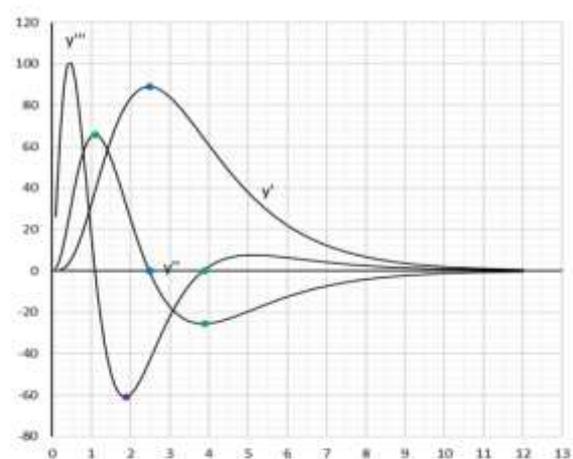
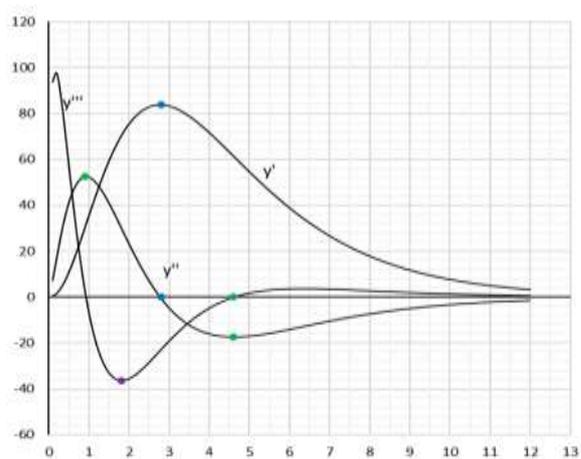
t1: Idade de máxima aceleração do crescimento = 1,1 anos

t2: Idade de máxima taxa de crescimento = 2,8 anos

t2: Idade de máxima taxa de crescimento = 2,5 anos

t3: Idade de máxima desaceleração do crescimento = 4,6 anos

t3: Idade de máxima desaceleração do crescimento = 3,9 anos

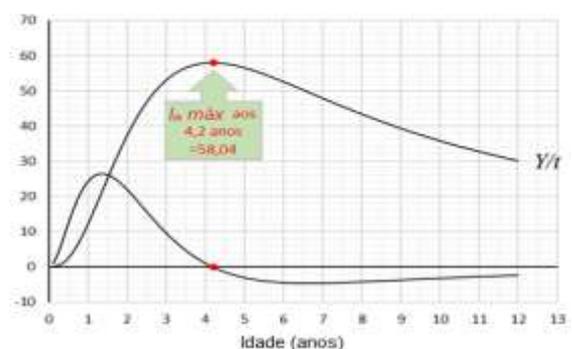
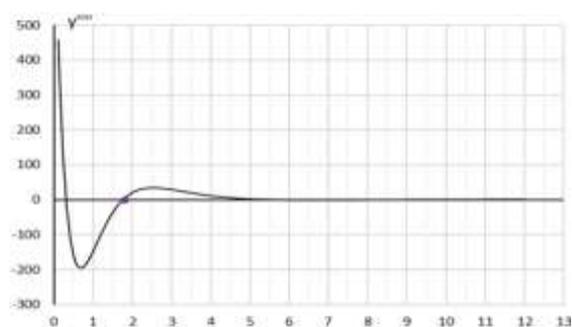
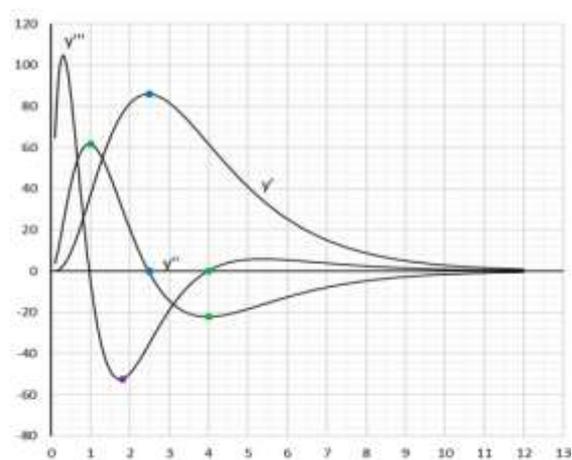
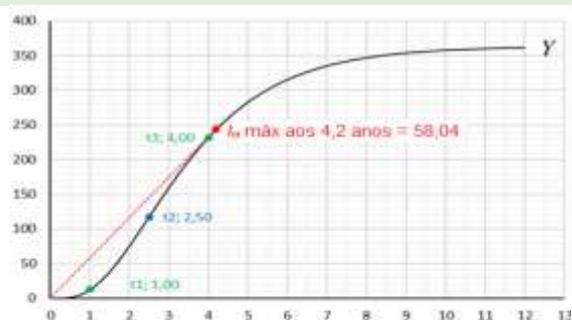
Idade de máxima produtividade média (I_m) = 4,8 anosIdade de máxima produtividade média (I_m) = 4,1 anos

g) Lim *et al.* (2020) BA 2

t1: Idade de máxima aceleração do crescimento = 1 ano

t2: Idade de máxima taxa de crescimento = 2,5 anos

t3: Idade de máxima desaceleração do crescimento = 4 anos

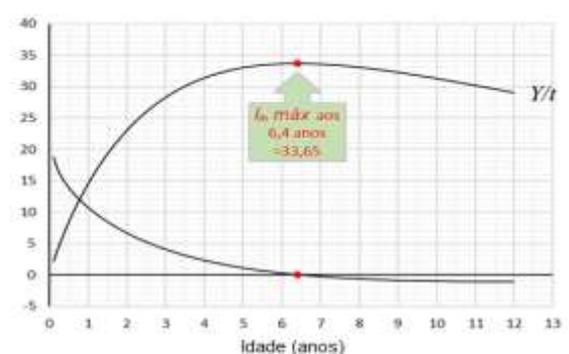
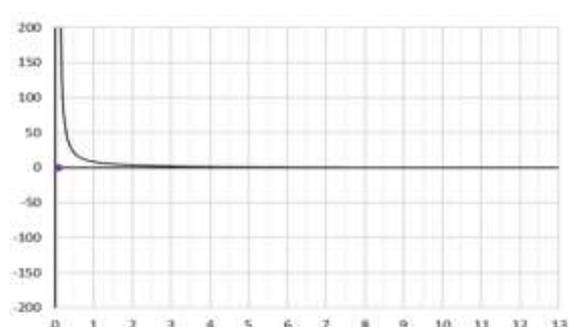
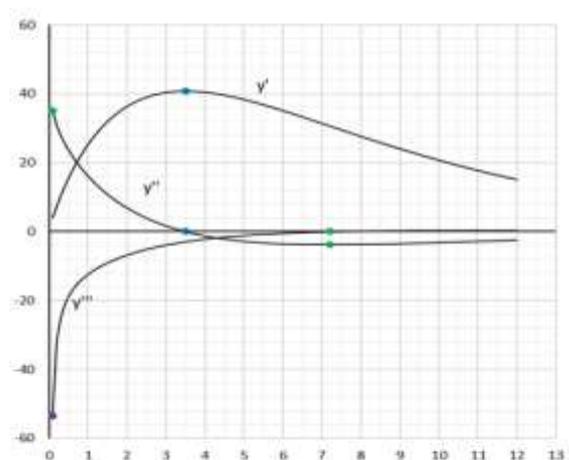
Idade de máxima produtividade média (I_m) = 4,2 anos

h) Stape, Ryan e Binkley (2004) BA

t1: Idade de máxima aceleração do crescimento = 0,1 anos

t2: Idade de máxima taxa de crescimento = 3,5 anos

t3: Idade de máxima desaceleração do crescimento = 7,2 anos

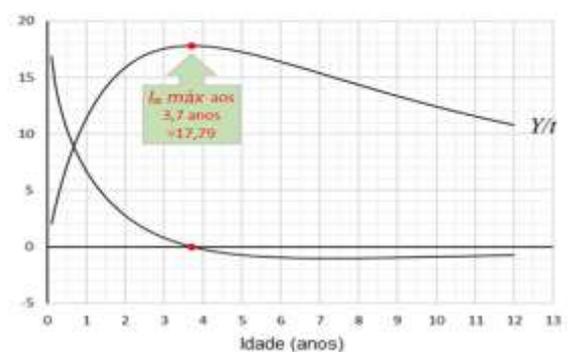
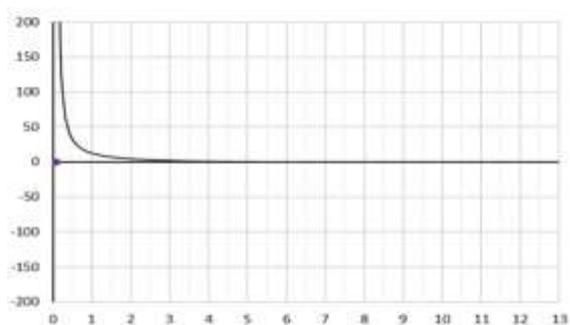
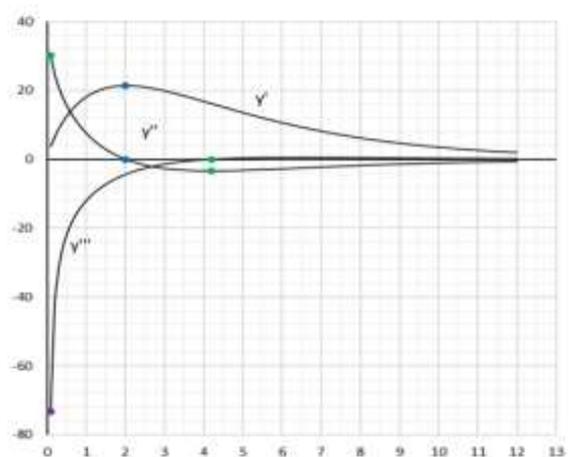
Idade de máxima produtividade média (I_m) = 6,4 anos

i) Behling *et al.* (2011) PA

t1: Idade de máxima aceleração do crescimento = 0,1 anos

t2: Idade de máxima taxa de crescimento = 2 anos

t3: Idade de máxima desaceleração do crescimento = 4,2 anos

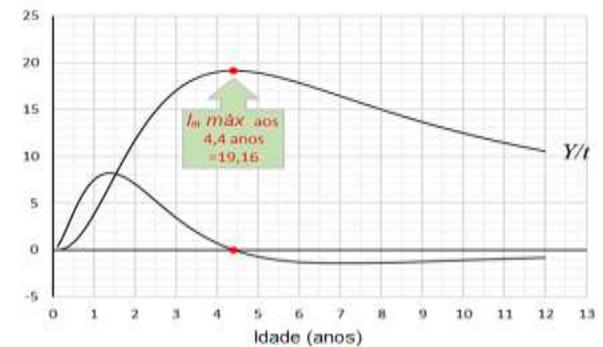
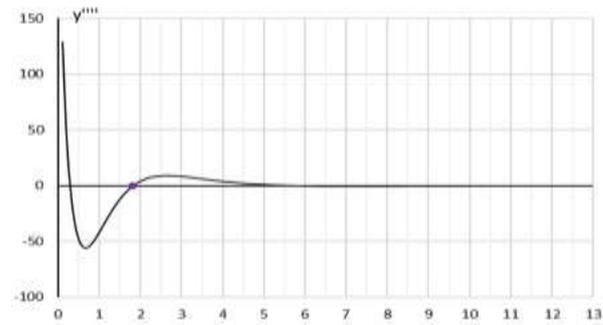
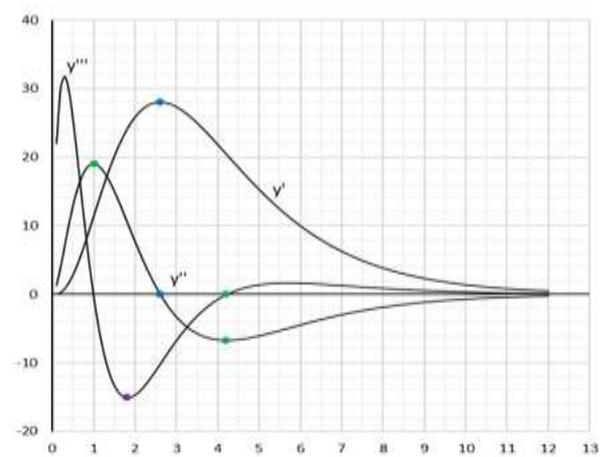
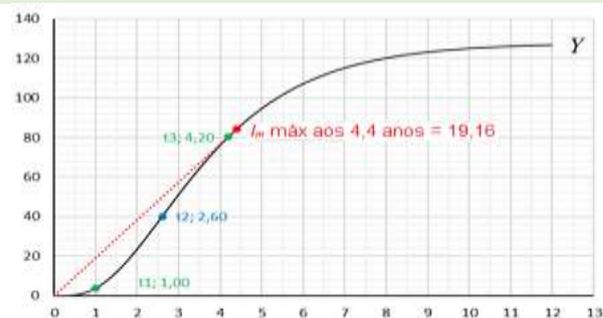
Idade de máxima produtividade média (I_m) = 3,7 anos

j) Rascon (2012) AP

t1: Idade de máxima aceleração do crescimento = 1 anos

t2: Idade de máxima taxa de crescimento = 2,6 anos

t3: Idade de máxima desaceleração do crescimento = 4,2 anos

Idade de máxima produtividade média (I_m) = 4,4 anos

k) Almeida, Landsberg e Sands (2004) ES

l) Lim *et al.* (2020) ES

t1: Idade de máxima aceleração do crescimento = 0,4 anos

t1: Idade de máxima aceleração do crescimento = 1 ano

t2: Idade de máxima taxa de crescimento = 2,3 anos

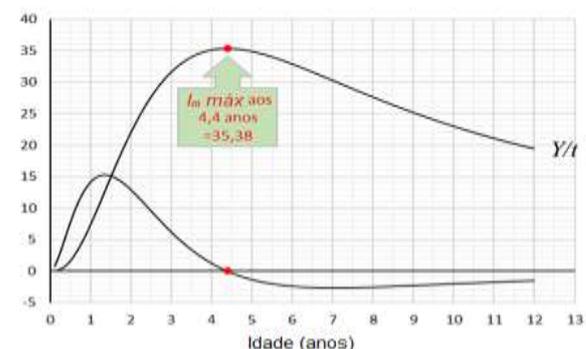
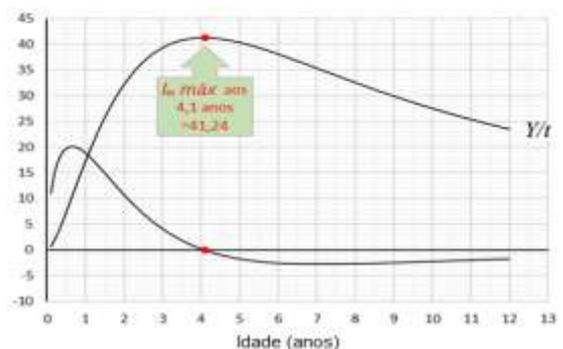
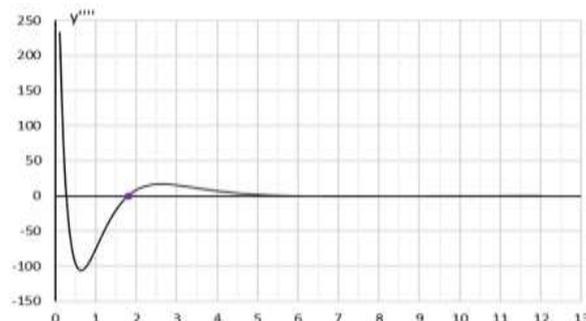
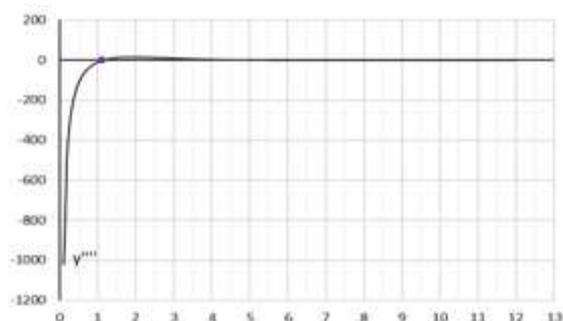
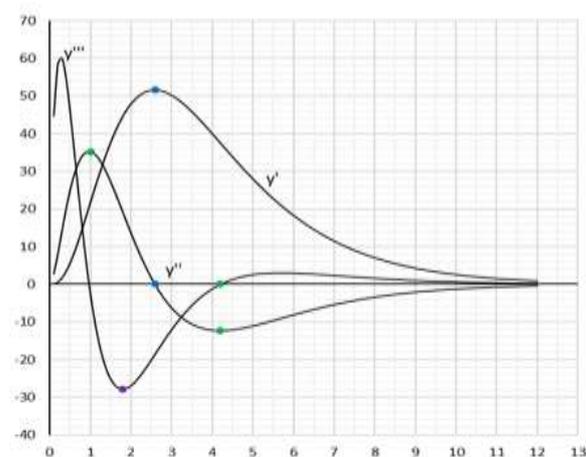
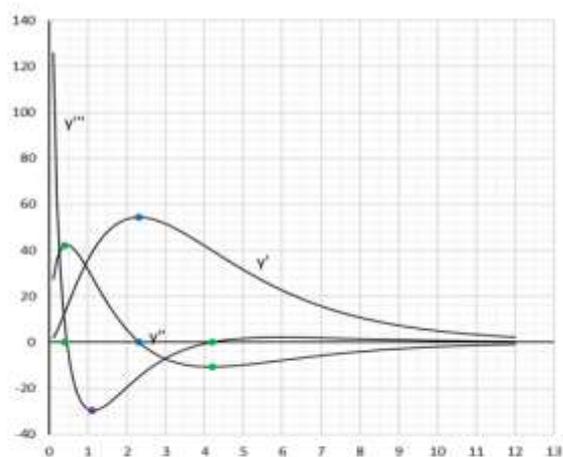
t2: Idade de máxima taxa de crescimento = 2,6 anos

t3: Idade de máxima desaceleração do crescimento = 4,2 anos

t3: Idade de máxima desaceleração do crescimento = 4,2 anos

Idade de máxima produtividade média (I_m) = 4,1 anos

Idade de máxima produtividade média (I_m) = 4,4 anos



m)

Cavalli (2017) RS

n)

Klippel (2015) RS

t1: Idade de máxima aceleração do crescimento = 1,8 anos

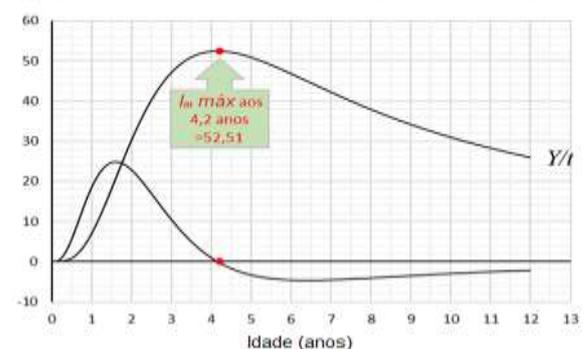
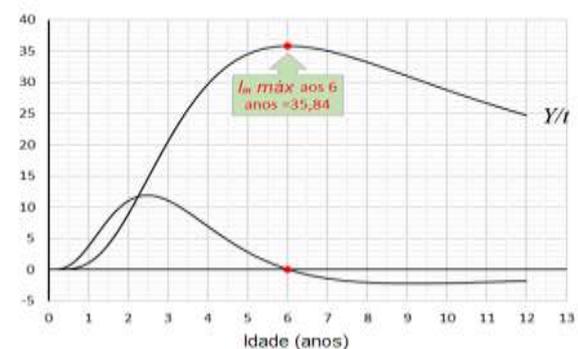
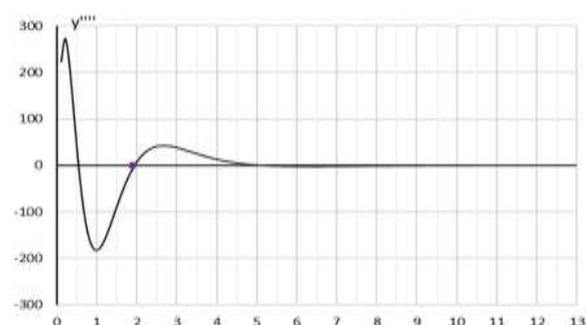
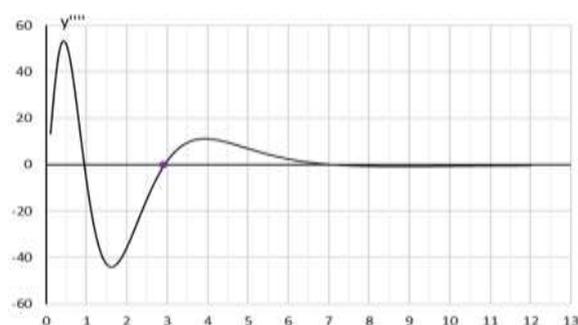
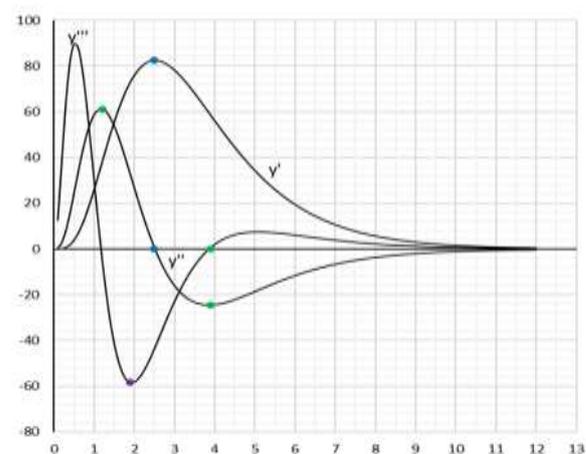
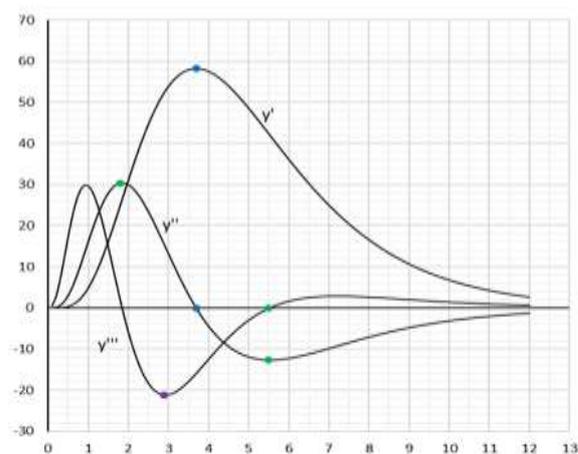
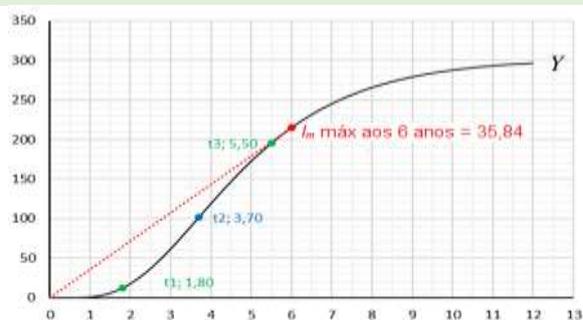
t1: Idade de máxima aceleração do crescimento = 1,2 anos

t2: Idade de máxima taxa de crescimento = 3,7 anos

t2: Idade de máxima taxa de crescimento = 2,5 anos

t3: Idade de máxima desaceleração do crescimento = 5,5 anos

t3: Idade de máxima desaceleração do crescimento = 3,9 anos

Idade de máxima produtividade média (I_m) = 6 anosIdade de máxima produtividade média (I_m) = 4,2 anos

Idade (anos)

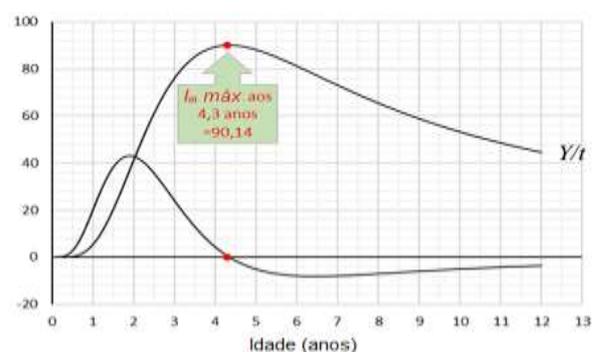
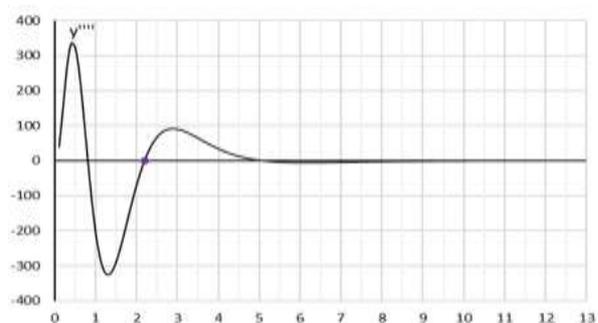
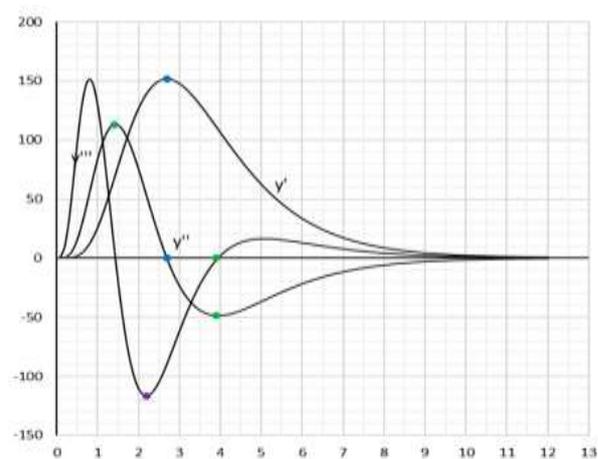
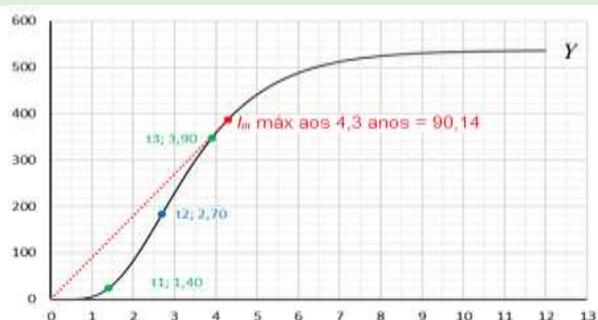
Idade (anos)

o) Londero *et al.* (2015) RS

t1: Idade de máxima aceleração do crescimento = 1,4 anos

t2: Idade de máxima taxa de crescimento = 2,7 anos

t3: Idade de máxima desaceleração do crescimento = 3,9 anos

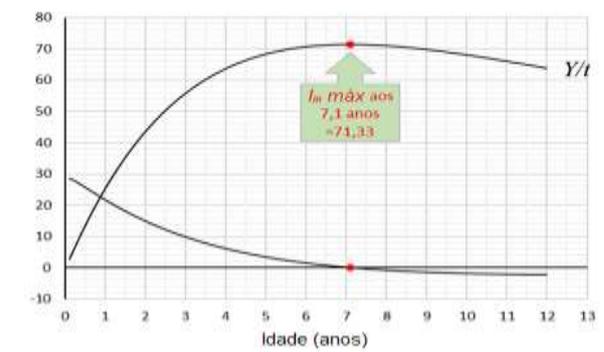
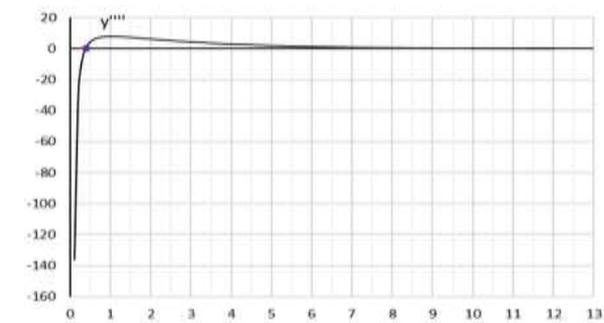
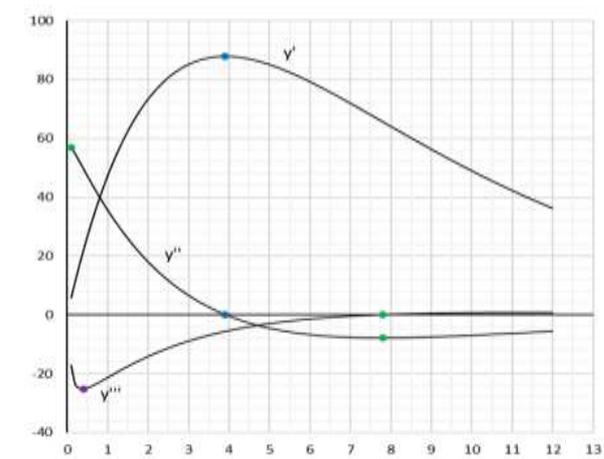
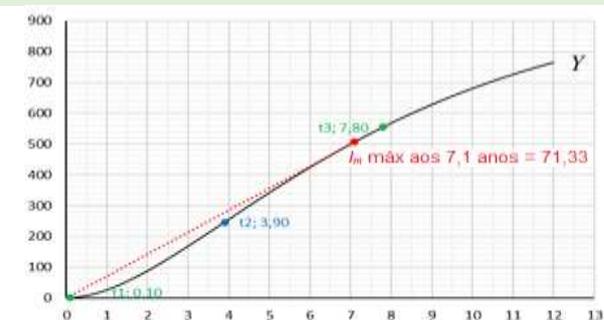
Idade de máxima produtividade média (I_m) = 4,3 anos

p) Stahringer (2017) AR

t1: Idade de máxima aceleração do crescimento = 0,1 anos

t2: Idade de máxima taxa de crescimento = 3,9 anos

t3: Idade de máxima desaceleração do crescimento = 7,8 anos

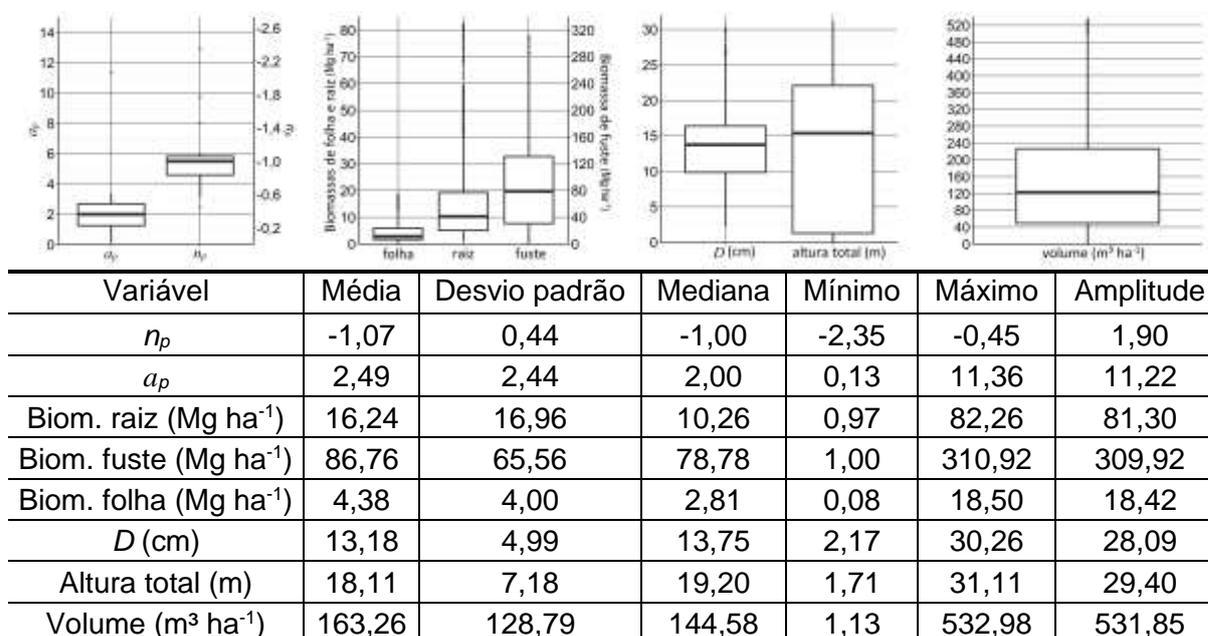
Idade de máxima produtividade média (I_m) = 7,1 anos

Fonte: Elaborada pela autora.

3.2 Configuração e treinamento das redes neurais artificiais

O treinamento das redes foi realizado com o banco de dados gerado pelo 3-PG, considerando o processamento até a idade de 7 anos. A descrição das variáveis de saída encontra-se na Figura 11.

Figura 11 - Distribuição e resumo estatístico dos dados referentes as variáveis estudadas como saída nos treinamentos das redes neurais artificiais.



Biom. = biomassa.

Fonte: Elaborada pela autora.

As combinações que melhor descreveram as variáveis a_p , n_p , biomassas de raiz, fuste e folha, D , altura total e volume foram:

$$n_p = f[g(\text{prcp}, T_a, p_2, p_{20}, A_f)]$$

$$a_p = f[g(\text{solar_rad}, \text{prcp}, n_p, p_2)]$$

$$W_R = f[g(\text{prcp}, \text{apar}, T_{\min}, A_f, \varphi, t_i, p_2)]$$

$$W_S = f[g(\text{prcp}, T_a, \text{solar_rad}, t_i, A_f)]$$

$$W_F = f[g(\text{amp_temp}, \text{prcp}, \text{solar_rad}, t_i, A_f)]$$

$$D = f[g(\text{prcp}, \text{apar}, T_a, w_s)]$$

$$H = f[g(\text{prcp}, T_a, \text{apar}, D)]$$

$$V_s = f[g(\text{prcp}, T_a, D, H, A_f)]$$

em que: n_p = potência da função que estima a fração de biomassa a ser alocada para folha/fuste; a_p = intercepto da função que estima a fração de biomassa a ser alocada para folha/fuste; p_2 = fração de biomassa alocada para folha/fuste para um $D = 2$ cm; p_{20} = fração de biomassa alocada para folha/fuste para um $D = 20$ cm; prcp = precipitação pluviométrica (mm); T_a = temperatura média (°C); T_{\min} = temperatura mínima (°C); amp_temp = amplitude entre as temperaturas mínima e máxima (°C); solar_rad = radiação solar ($\text{MJ m}^{-2} \text{ dia}^{-1}$); apar = radiação fotossinteticamente ativa absorvida ($\text{MJ m}^{-2} \text{ dia}^{-1}$); A_f = índice de área foliar ($\text{m}^2 \text{ m}^{-2}$); φ = modificador fisiológico; W_s = biomassa de fuste (Mg ha^{-1}); w_s = biomassa médi de fuste (kg árv.^{-1}); W_R = biomassa de raiz (Mg ha^{-1}); W_F = biomassa de folha (Mg ha^{-1}); D = diâmetro à altura do peito (cm); H = altura total (m); V_s = volume do povoamento sem casca ($\text{m}^3 \text{ ha}^{-1}$); t_i = idade (anos).

Todas as redes apresentaram correlações acima de 0,90 (entre os valores estimados pelo 3-PG e preditos pela RNA) e RQEM abaixo de 10%, no treino e na validação, exceto para as variáveis biomassa de raiz e de fuste com valores acima de 20% (Tabela 3). Com exceção das predições dos parâmetros n_p e a_p e do volume, no treino e na validação, e W_F no treino, as demais variáveis apresentaram p-valor não significativo, considerando os valores estimados pelo 3-PG e preditos pela RNA estatisticamente iguais pelo teste F_{H0} (Tabela 3), o mesmo pode ser observado na Figura 12 com os detalhes de validação das redes.

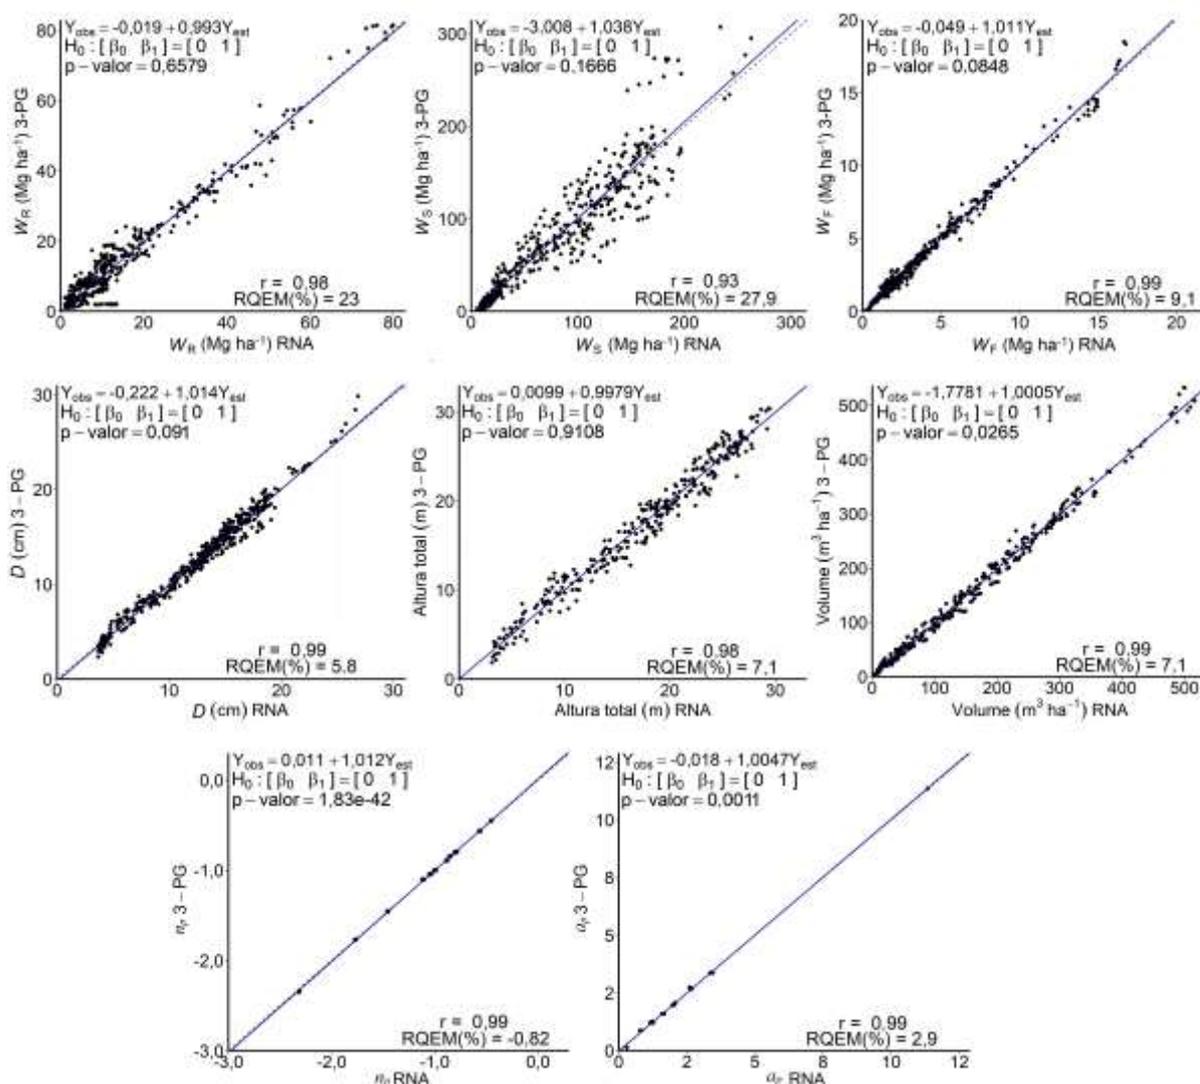
Tabela 3 – Estatísticas das redes selecionadas para prever as variáveis n_p , a_p , W_R , W_S , W_F , D , altura total e volume na validação e treino.

Variável	E-I-S	Validação				Treino			
		$r_{\hat{Y}Y}$	RQEM	RQEM (%)	p-valor	$r_{\hat{Y}Y}$	RQEM	RQEM (%)	p-valor
n_p	5-3-1	0,9999	0,009	-0,8	0,000	0,9999	0,010	-0,9	0,000
a_p	4-4-1	0,9995	0,069	2,9	0,001	0,9997	0,062	2,4	0,000
W_R	7-6-1	0,9755	3,588	23,0	0,658	0,9793	3,489	21,2	0,326
W_S	5-4-1	0,9333	23,838	27,9	0,167	0,9301	24,001	27,5	0,521
W_F	5-4-1	0,9950	0,358	9,1	0,085	0,9953	0,403	8,8	0,023
D	4-4-1	0,9892	0,747	5,8	0,091	0,9881	0,763	5,7	0,197
Altura total	4-4-1	0,9846	1,251	7,1	0,911	0,9851	1,237	6,7	0,833
Volume	5-5-1	0,9964	10,987	7,1	0,026	0,9960	11,563	6,9	0,018

E; I; S = topologia da rede com o número de neurônios nas camadas de entrada, intermediária e saída, respectivamente; p-valor do teste F de Graybill ($\alpha = 0,05$); biomassas de raiz (W_R), fuste (W_S) e folha (W_F). D = diâmetro à 1,30 m de altura; RQEM = Raiz quadrada do erro quadrático médio; $r_{\hat{Y}Y}$ = correlação entre valores preditos pela RNA e estimados pelo 3-PG.

Fonte: Elaborada pela autora.

Figura 12 – Dispersão dos valores preditos pela RNA e estimados pelo 3-PG na validação das redes selecionadas. A equação refere-se ao resultado da regressão linear simples dos dados junto com as estatísticas do teste F_{H_0} (p-valor/ $\alpha = 0,05$), correlação (r) e RQEM para as variáveis biomassa de raiz (W_R), fuste (W_S) e folha (W_F), D , altura total, volume e dos parâmetros n_p e a_p .



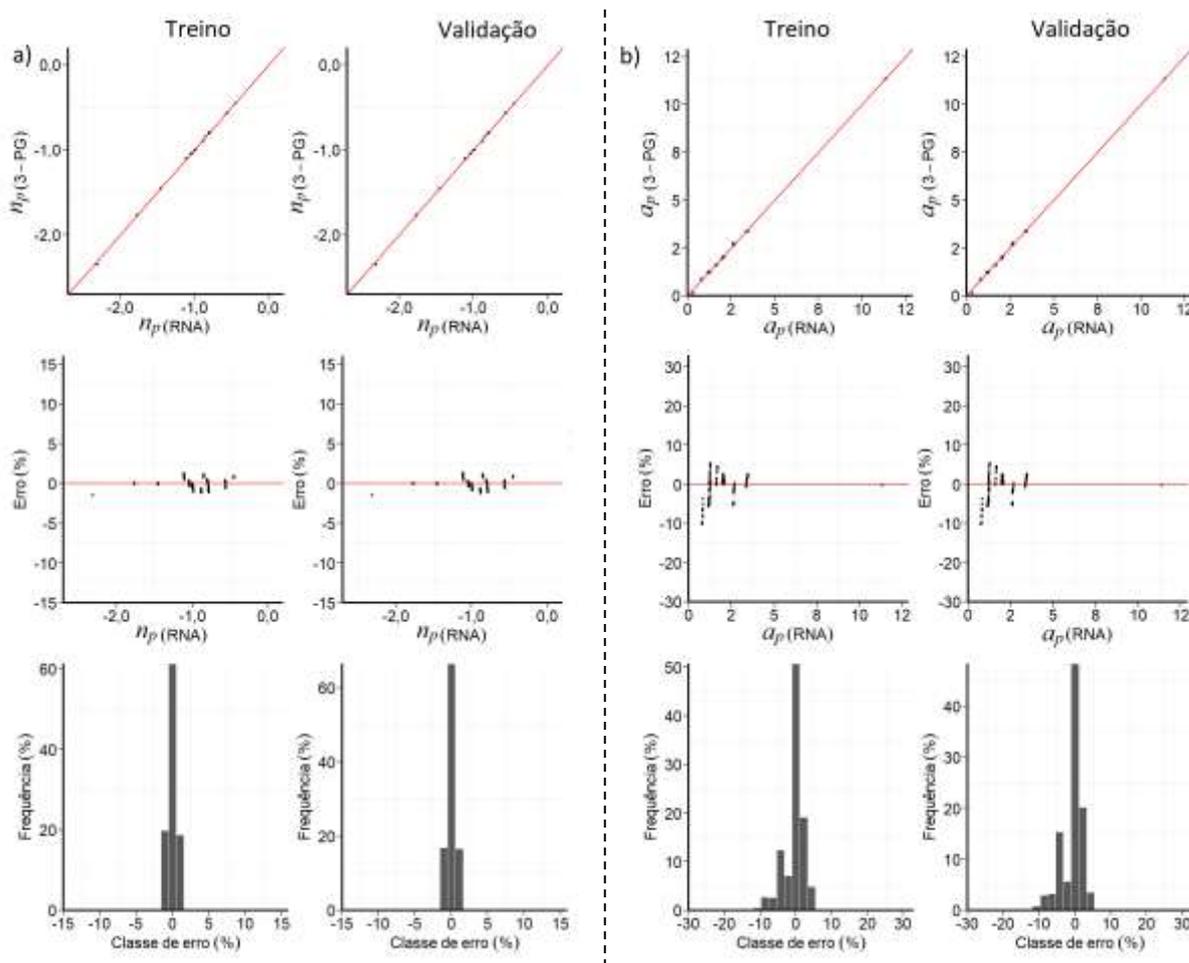
Fonte: Elaborada pela autora.

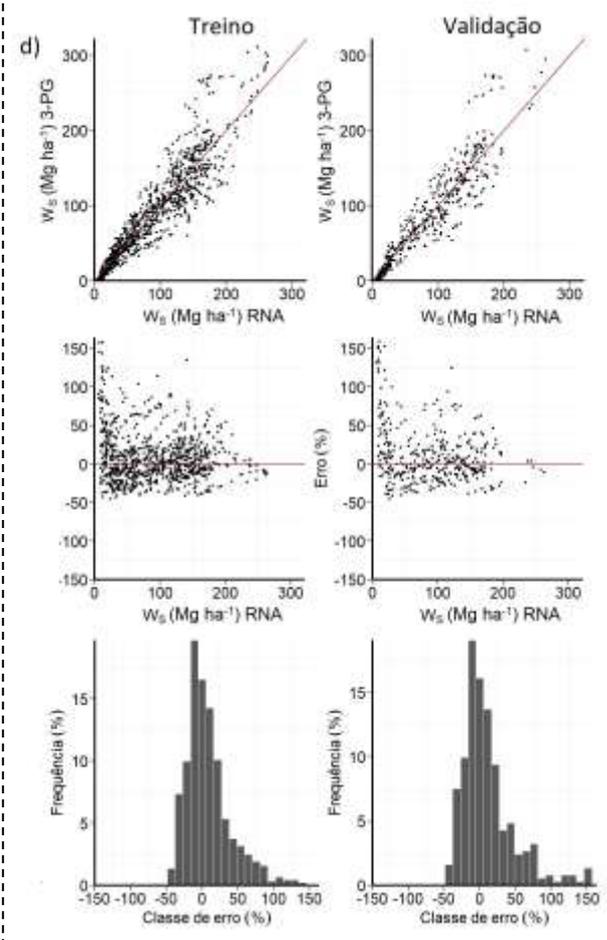
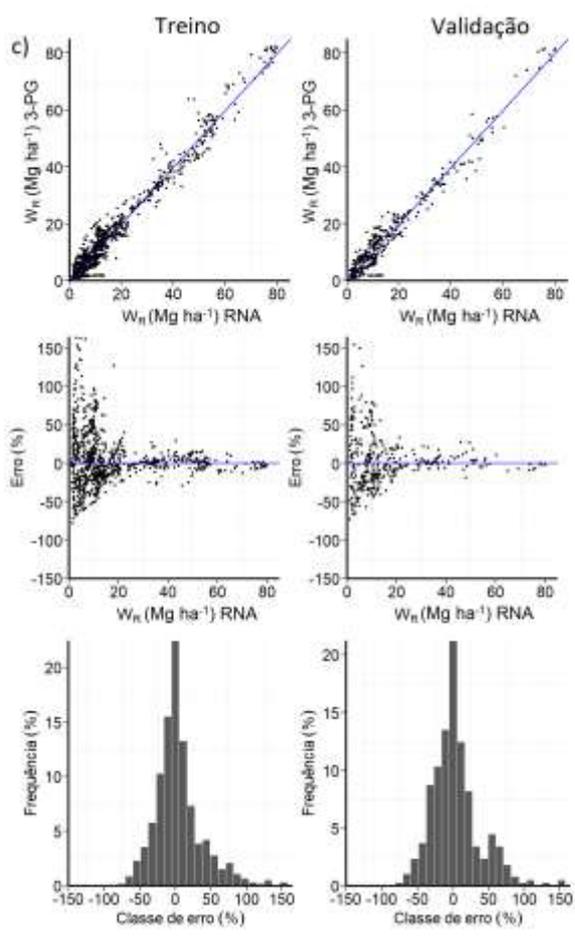
A maior parte dos erros relativos percentuais entre valores preditos pela RNA e estimados pelo 3-PG do conjunto de validação se concentraram entre $\pm 10\%$ para os parâmetros n_p (100%), a_p (92%), biomassa de folha (68%), D (85%), altura total (76%) e volume (65%), já as biomassas de raiz e de fuste apresentaram a maior parte dos erros concentrados entre $\pm 20\%$, com 51 e 52% dos erros neste intervalo, respectivamente (Figura 13).

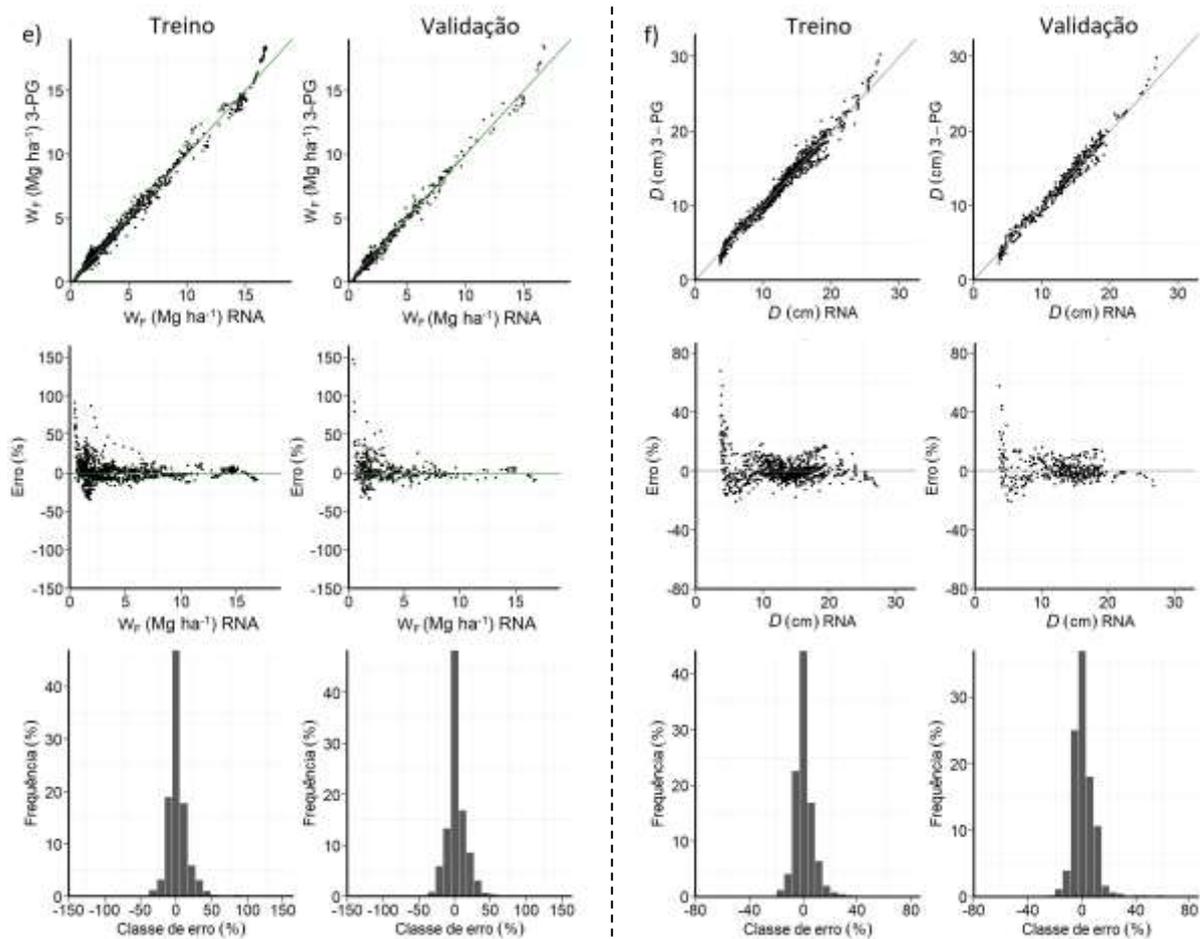
Superestimativas geraram os maiores valores de erro relativo em todas as redes, principalmente nas idades iniciais. Avaliando erros acima de $\pm 60\%$, observa-

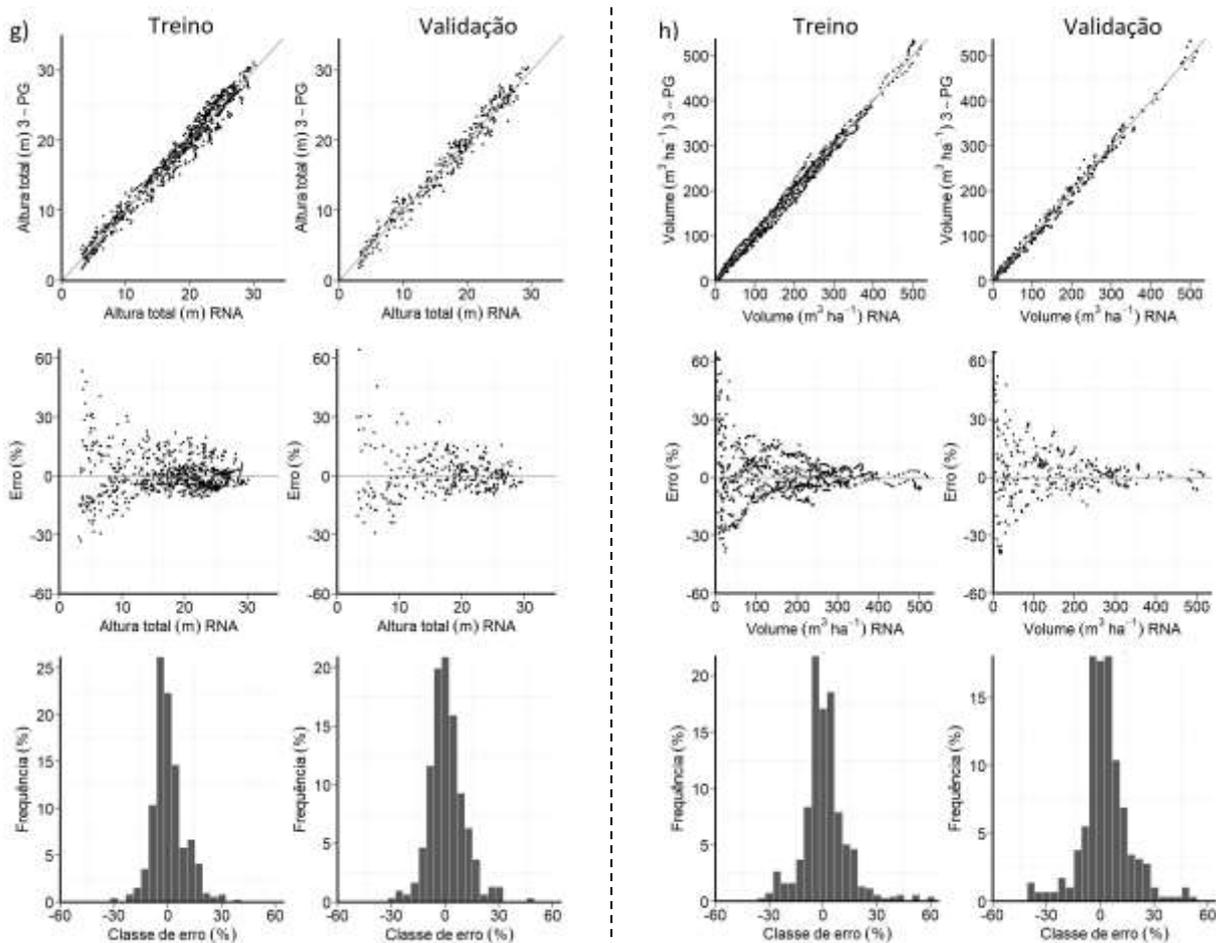
se que eles representaram 0,5% dos dados para altura total, 8% para o parâmetro a_p , 1,5% para biomassa de folha, 3,7% para volume, 15% para biomassa de raiz e 18% para biomassa de fuste. Nas previsões das demais variáveis (n_p e D) não ocorreram erros acima de $\pm 60\%$, além de, em grande parte dos casos, indicar aumentos não muito consideráveis, por se tratar de valores pequenos (Figura 13).

Figura 13 – Dispersão dos valores preditos pela RNA e estimados pelo 3-PG, erros relativos percentuais e percentagem dos casos por classe de erro relativo percentual, dos conjuntos de treino e de validação das redes selecionadas para prever os parâmetros a_p (a) e n_p (b), biomassas de raiz (c), fuste (d) e folha (e), D (f), altura total (g) e volume (h). Mais de 90% dos dados estão apresentados nos gráficos de dispersão e frequência do ER% das variáveis a_p (92%), W_R (93%), W_S (91%), W_F (99%), altura total (99%) e volume (96%).









Fonte: Elaborada pela autora.

Para o parâmetro n_p o modelo da rede de melhor desempenho foi o que considerou as mesmas variáveis usadas pelo 3-PG para estimá-lo (p_2 e p_{20}). Esse parâmetro já é necessário para rodar o 3-PG, com o acréscimo dos dados de clima (precipitação pluviométrica e temperatura média) e índice de área foliar (A_f).

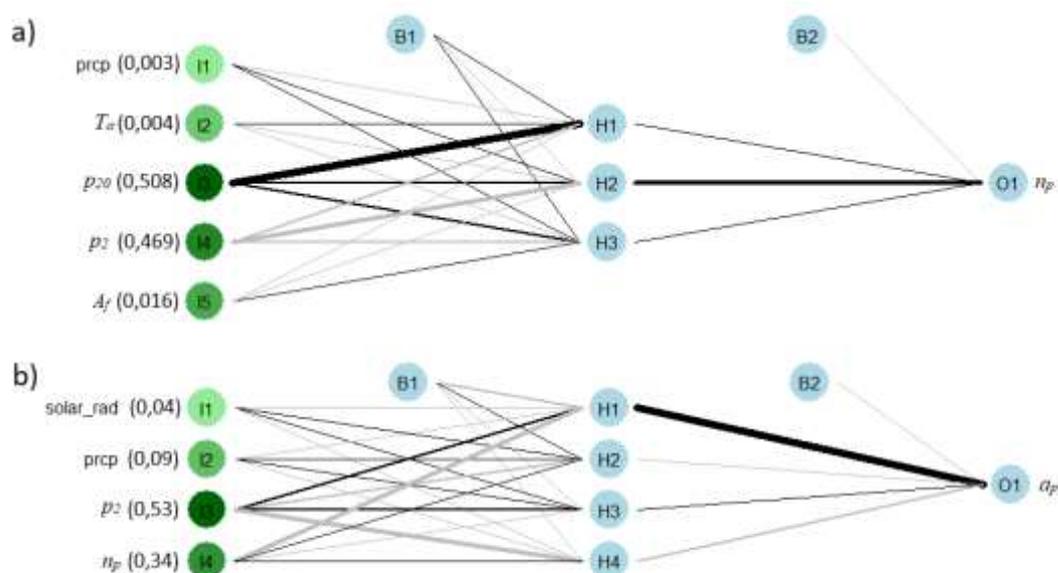
Pela classificação de Garson, os parâmetros p_2 e p_{20} apresentaram as maiores importâncias relativas ao predizer n_p , seguidos do índice de área foliar (A_f), temperatura média e precipitação pluviométrica (Figura 14 a). A rede mais eficiente para predição do parâmetro a_p foi a que tinha p_2 e n_p , o mesmo usado no modelo 3-PG. O algoritmo de Garson apontou o parâmetro p_2 como o de maior importância relativa em comparação às outras entradas da rede, junto das variáveis n_p , precipitação pluviométrica e radiação solar (Figura 14 b).

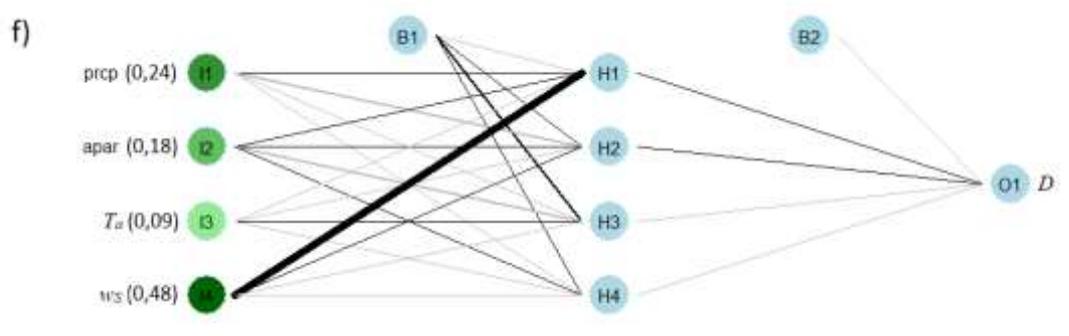
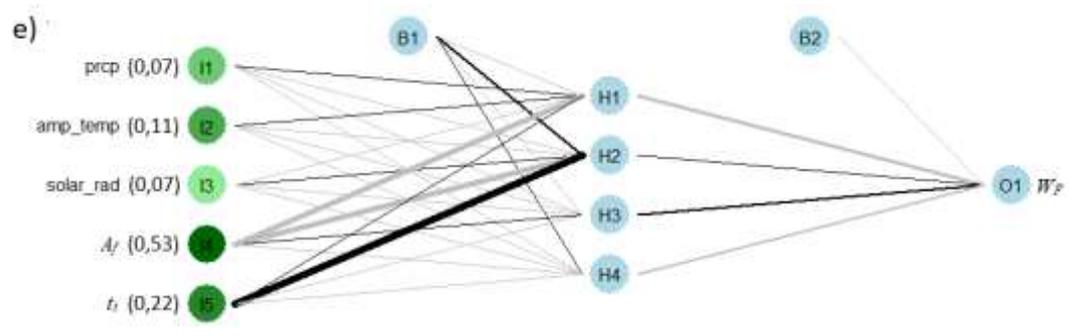
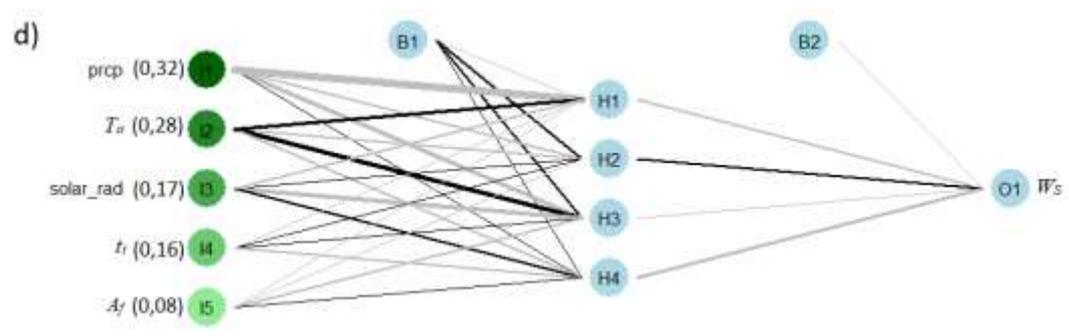
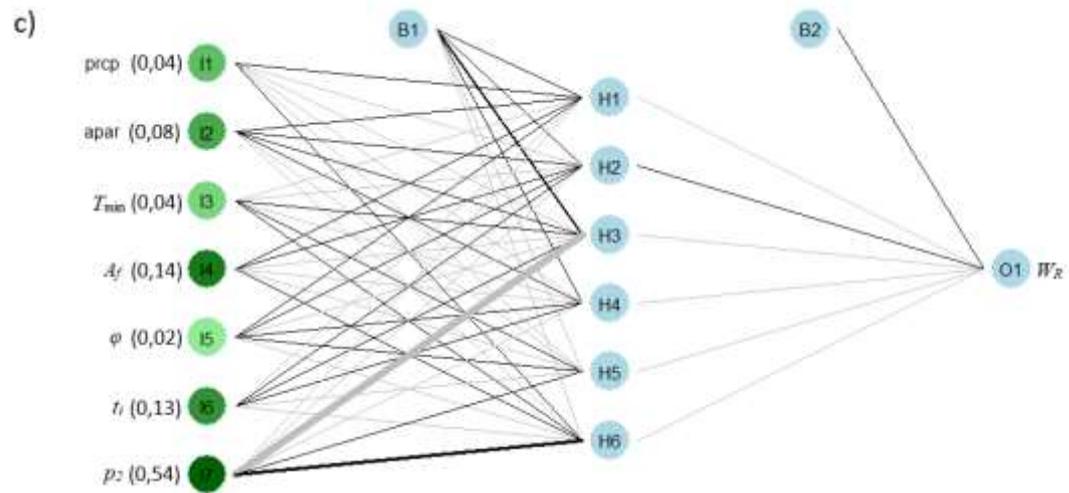
A RNA treinada para predição de biomassa de raízes teve o maior número de variáveis de entrada (7), com a p_2 apresentando a maior importância relativa, seguido pelo A_f , idade e as variáveis climáticas, radiação fotossinteticamente ativa absorvida (RFAA), precipitação pluviométrica e temperatura mínima. Para a

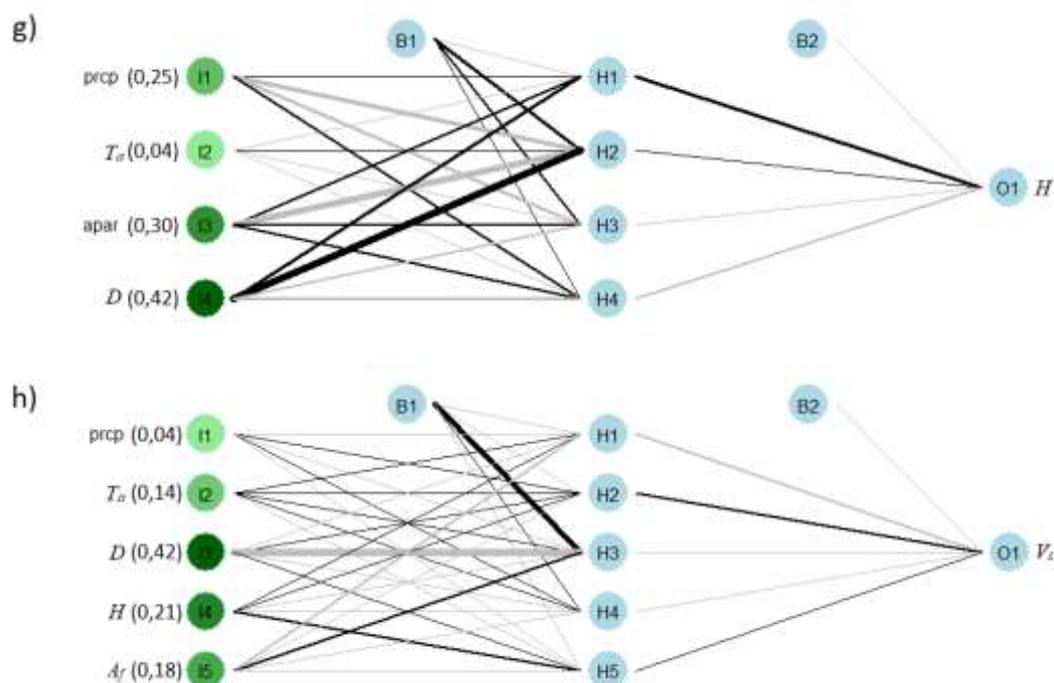
biomassa de fuste a ordem de importância relativa das variáveis de entrada foi: precipitação pluviométrica, temperatura média, radiação solar, idade e A_f . E para a biomassa de folha o A_f foi a variável de maior importância relativa, seguido da idade, amplitude entre temperaturas, precipitação pluviométrica e radiação solar (Figura 14 c, d, e).

Nas redes treinadas para prever as variáveis D , altura total e volume a biomassa de fuste, RFAA, temperatura média e precipitação pluviométrica foram, nesta ordem, as variáveis de maior importância relativa para prever o D (Figura 14 f). Para a altura total foram o D , RFAA, precipitação pluviométrica e a temperatura média e para prever o volume foram o D , altura total, temperatura média e precipitação pluviométrica a ordem das variáveis de maior importância relativa (Figura 14 g, h).

Figura 14 - Diagrama de interpretação neural (DIN) das redes selecionadas associado ao valor de importância relativa das variáveis de entrada pelo algoritmo de Garson (gradiente na cor verde: mais escuro = maior importância relativa) para as variáveis n_p (a), a_p (b), biomassas de raiz (c), fuste (d) e folha (e), D (f), altura total (g) e volume (h). No DIN as linhas pretas representam pesos positivos e as linhas cinzas pesos negativos, a espessura das linhas representa o valor dos pesos, quanto mais espessa maior.







n_p = potência da função que estima a fração de biomassa a ser alocada para folha/fuste;
 a_p = intercepto da função que estima a fração de biomassa a ser alocada para folha/fuste;
 p_2 = fração de biomassa alocada para folha/fuste para um $D = 2$ cm; p_{20} = fração de biomassa alocada para folha/fuste para um $D = 20$ cm; $prcp$ = precipitação pluviométrica (mm); T_a = temperatura média ($^{\circ}\text{C}$); T_{\min} = temperatura mínima ($^{\circ}\text{C}$); amp_temp = amplitude entre as temperaturas mínima e máxima ($^{\circ}\text{C}$); $solar_rad$ = radiação solar ($\text{MJ m}^{-2} \text{ dia}^{-1}$); $apar$ = radiação fotossinteticamente ativa absorvida ($\text{MJ m}^{-2} \text{ dia}^{-1}$); A_f = índice de área foliar ($\text{m}^2 \text{ m}^{-2}$); φ = modificador fisiológico; W_s = biomassa de fuste (Mg ha^{-1}); w_s = biomassa média de fuste (kg árv.^{-1}); W_R = biomassa de raiz (Mg ha^{-1}); W_F = biomassa de folha (Mg ha^{-1}); D = diâmetro à altura do peito (cm); H = altura total (m); V_s = volume do povoamento sem casca ($\text{m}^3 \text{ ha}^{-1}$); t_i = idade (anos).

Fonte: Elaborada pela autora.

Nas regiões de Curvelo e Itacambira em MG a aplicação dos modelos das redes para prever os parâmetros n_p e a_p , apesar do resultado significativo do teste F_{H0} para os dois clones, apresentaram erros relativamente baixos, especialmente para o clone 3334, com as previsões próximas dos valores usados por Borges (2009), com correlação forte (0,99) nas previsões dos dois parâmetros, e RQEM abaixo de 10% (Figura 15).

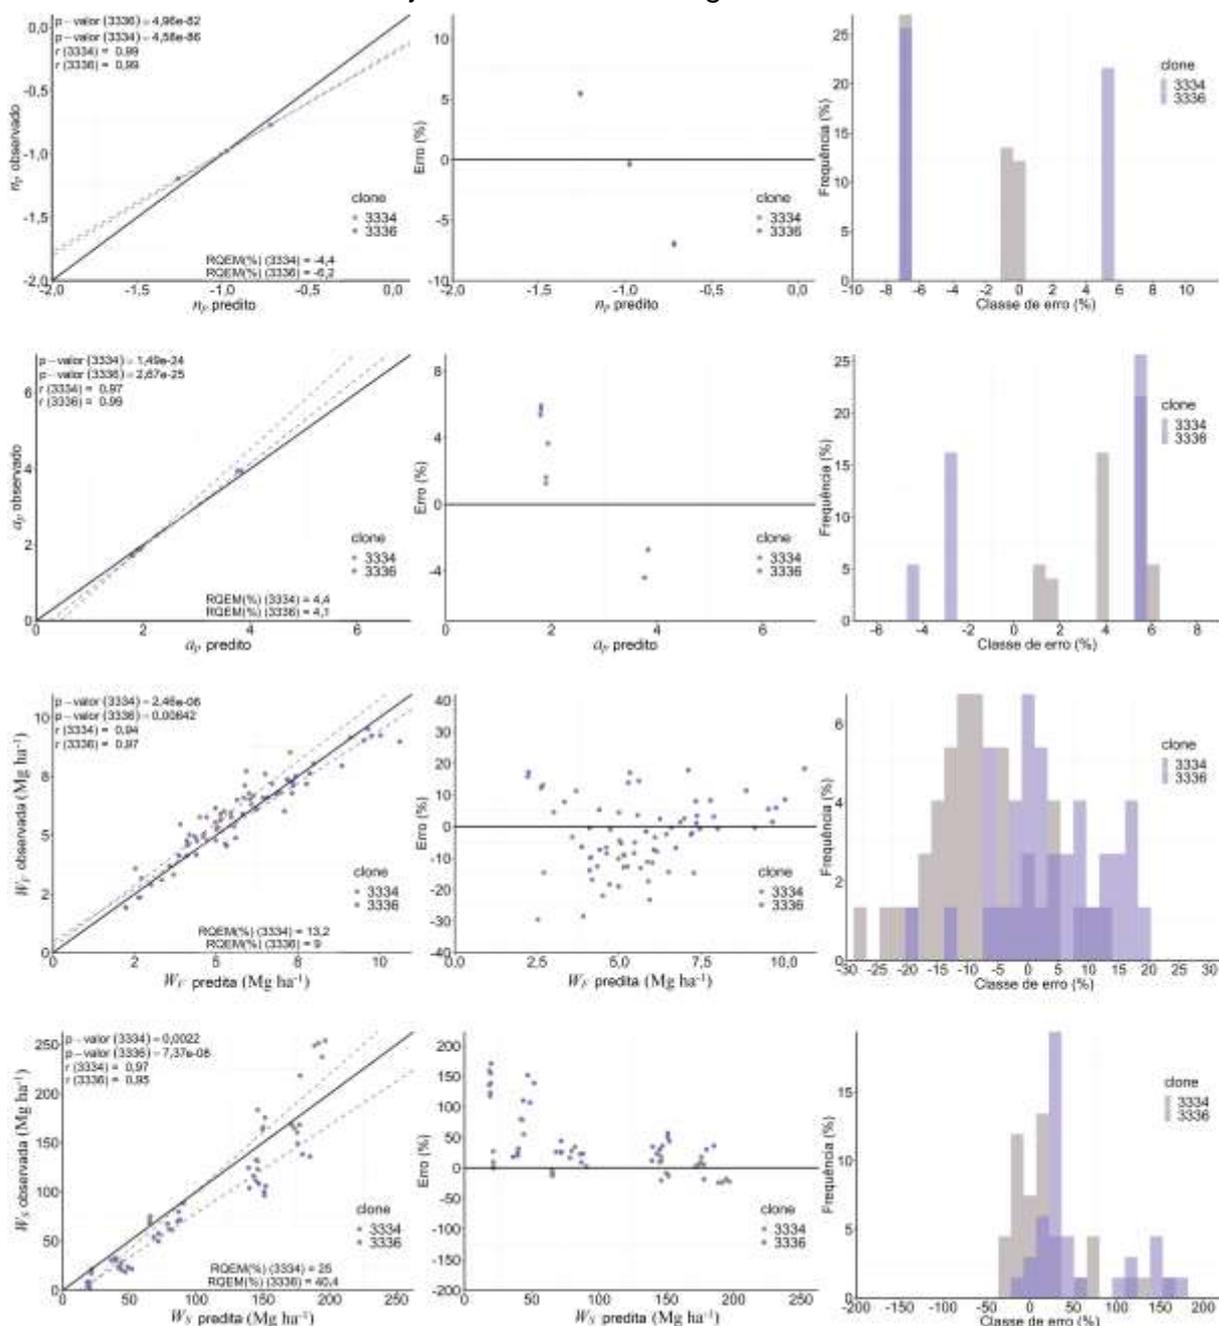
Para as previsões de biomassa de folha, o teste F_{H0} também foi significativo e houve diferença no comportamento entre clones, com tendência em subestimar os valores para o clone 3334, porém o desempenho geral da rede foi satisfatório, com

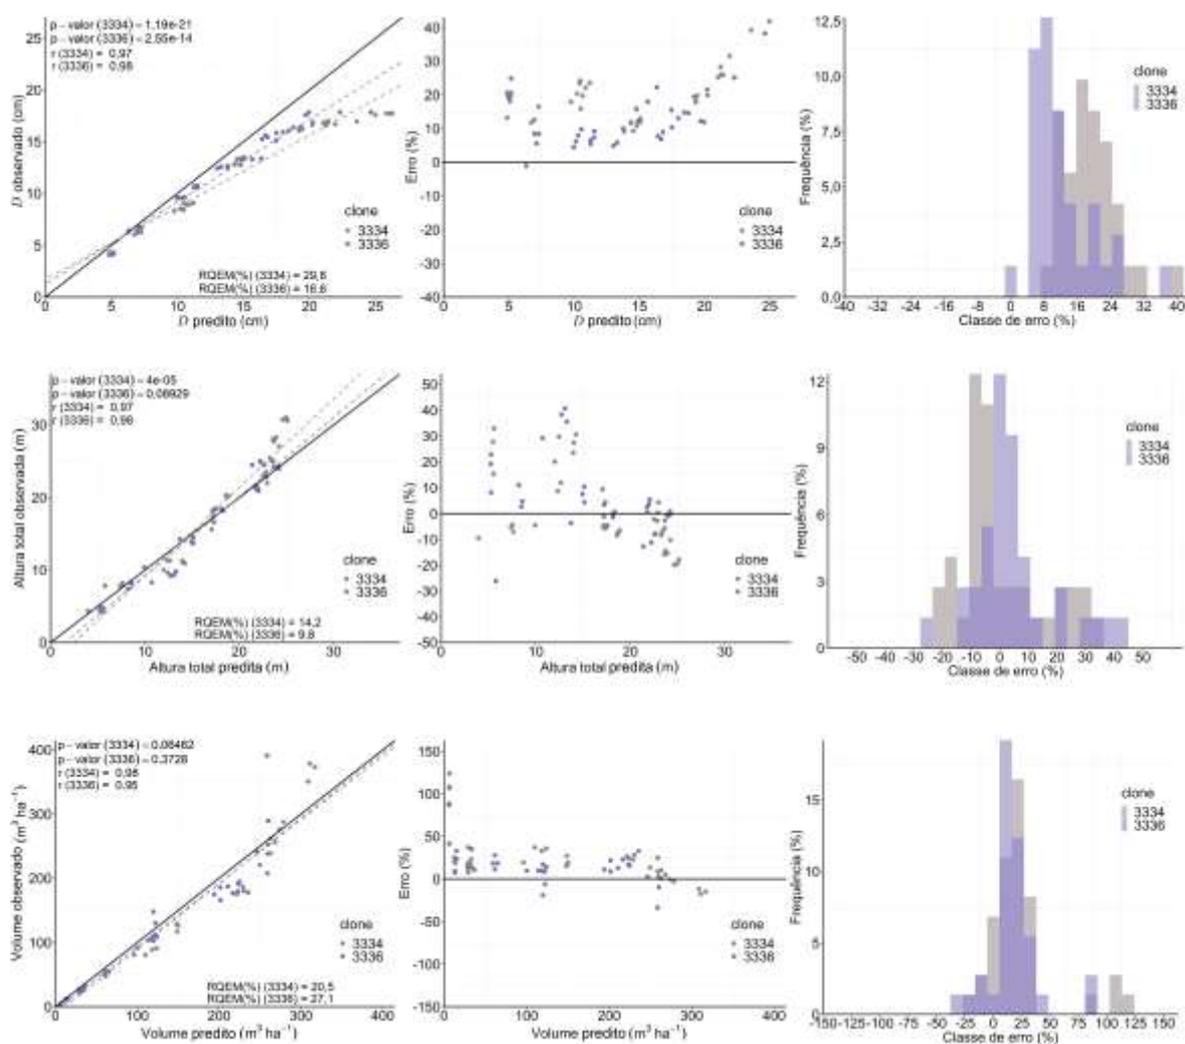
erros baixos, concentrados entre +20 e -30%, correlações acima de 0,9 e RQEM de 14,8% para o clone 3334 e de 8,9% para o clone 3336. Nas predições de biomassa de fuste houve maior dispersão dos dados, erros altos nas menores idades e teste F_{H0} significativo, com a mesma tendência de subestimativa para o clone 3334 e correlações acima de 0,9 (Figura 15).

As predições de D apresentaram erros concentrados entre -8 e +40% com tendência a superestimar valores para os dois clones, principalmente o clone 3334. Os p-valores do teste F_{H0} foram significativos, as correlações altas, porém os valores de RQEM foram elevados, sendo maior para o clone 3334 (30,7%) e menor para o clone 3336 (18,5%).

Para a altura total, apesar de a maior parte dos erros terem ficado entre $\pm 30\%$, em geral, houve tendência em superestimar os valores, principalmente nas menores idades, o p-valor foi não significativo apenas para o clone 3336, as correlações acima de 0,9 com RQEM maior para o clone 3334 (14,2%) e de 9,8% para o clone 3336. Os valores de volume foram superestimados ao longo do tempo para os dois clones, mesmo com p-valor não significativo no teste F_{H0} e correlações elevadas, os valores de RQEM foram altos com 20,5 e 27,1%, para os clones 3334 e 3336, respectivamente (Figura 15).

Figura 15 - Dispersão dos valores preditos pela RNA e observados, das regiões de Curvelo e de Itacambira em Minas Gerais, erros relativos percentuais e percentagem dos casos por classe de erro relativo percentual, para os clones 3334 e 3336, com as previsões dos parâmetros n_p e a_p , das biomassas de folha (W_F) e de fuste (W_S) e das variáveis D , altura total e volume. A linha sólida, nos gráficos de correlação, representa a linha 1:1 e as linhas tracejadas as linhas da regressão de cada clone.

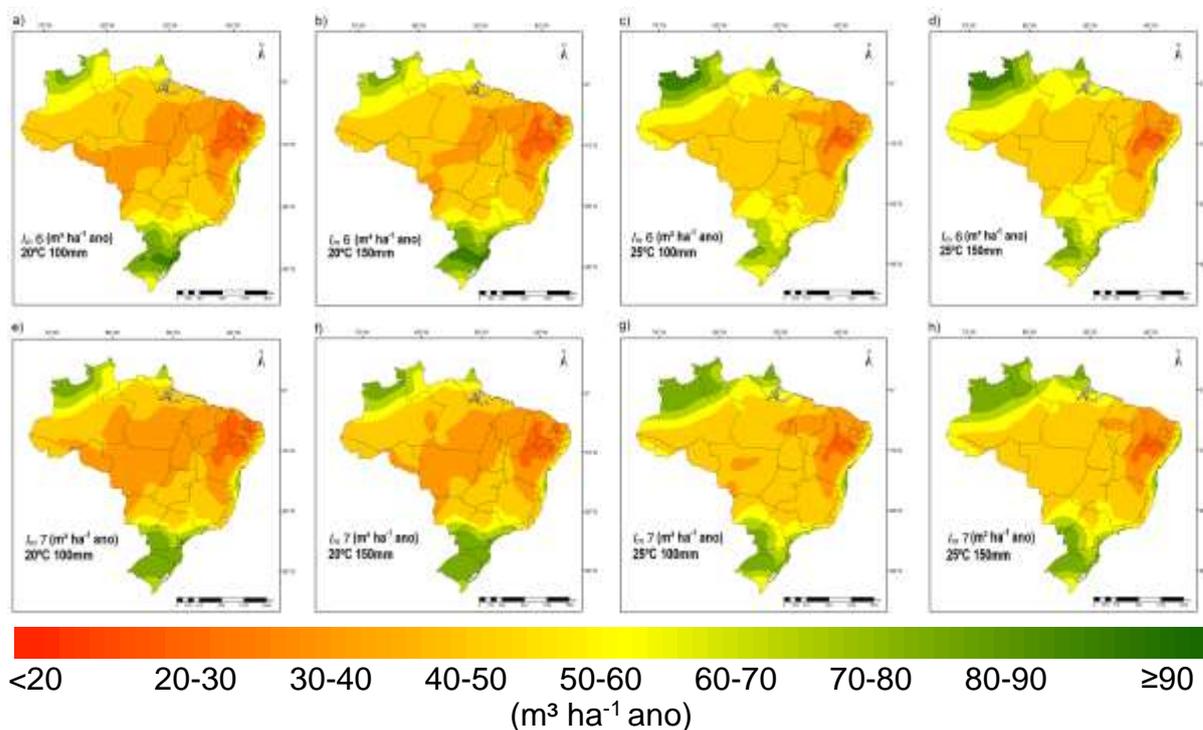


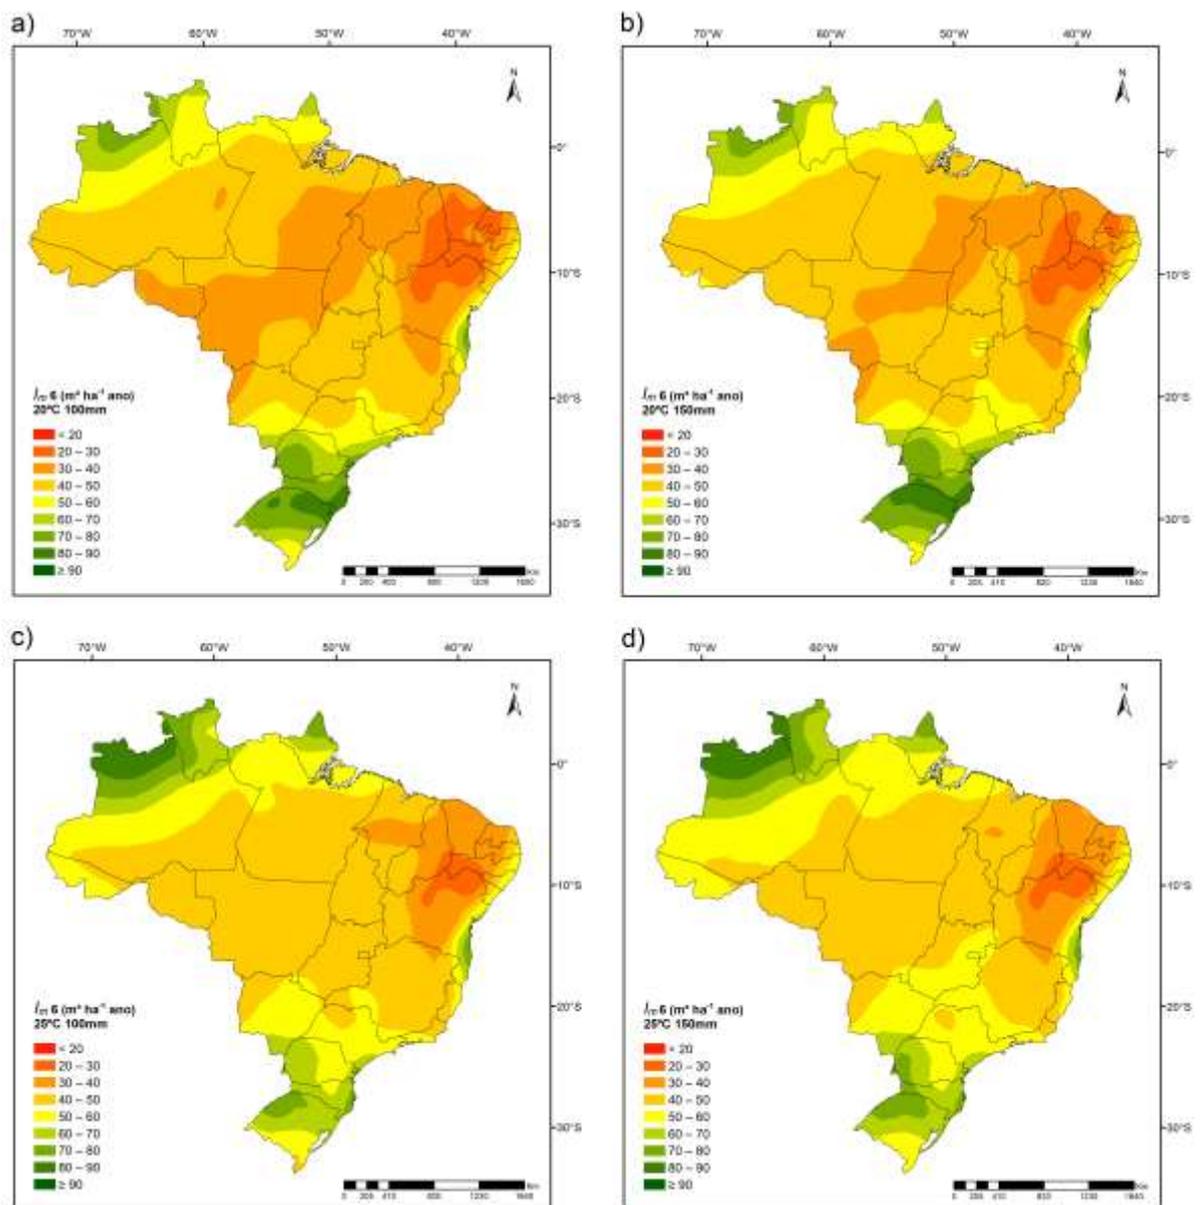


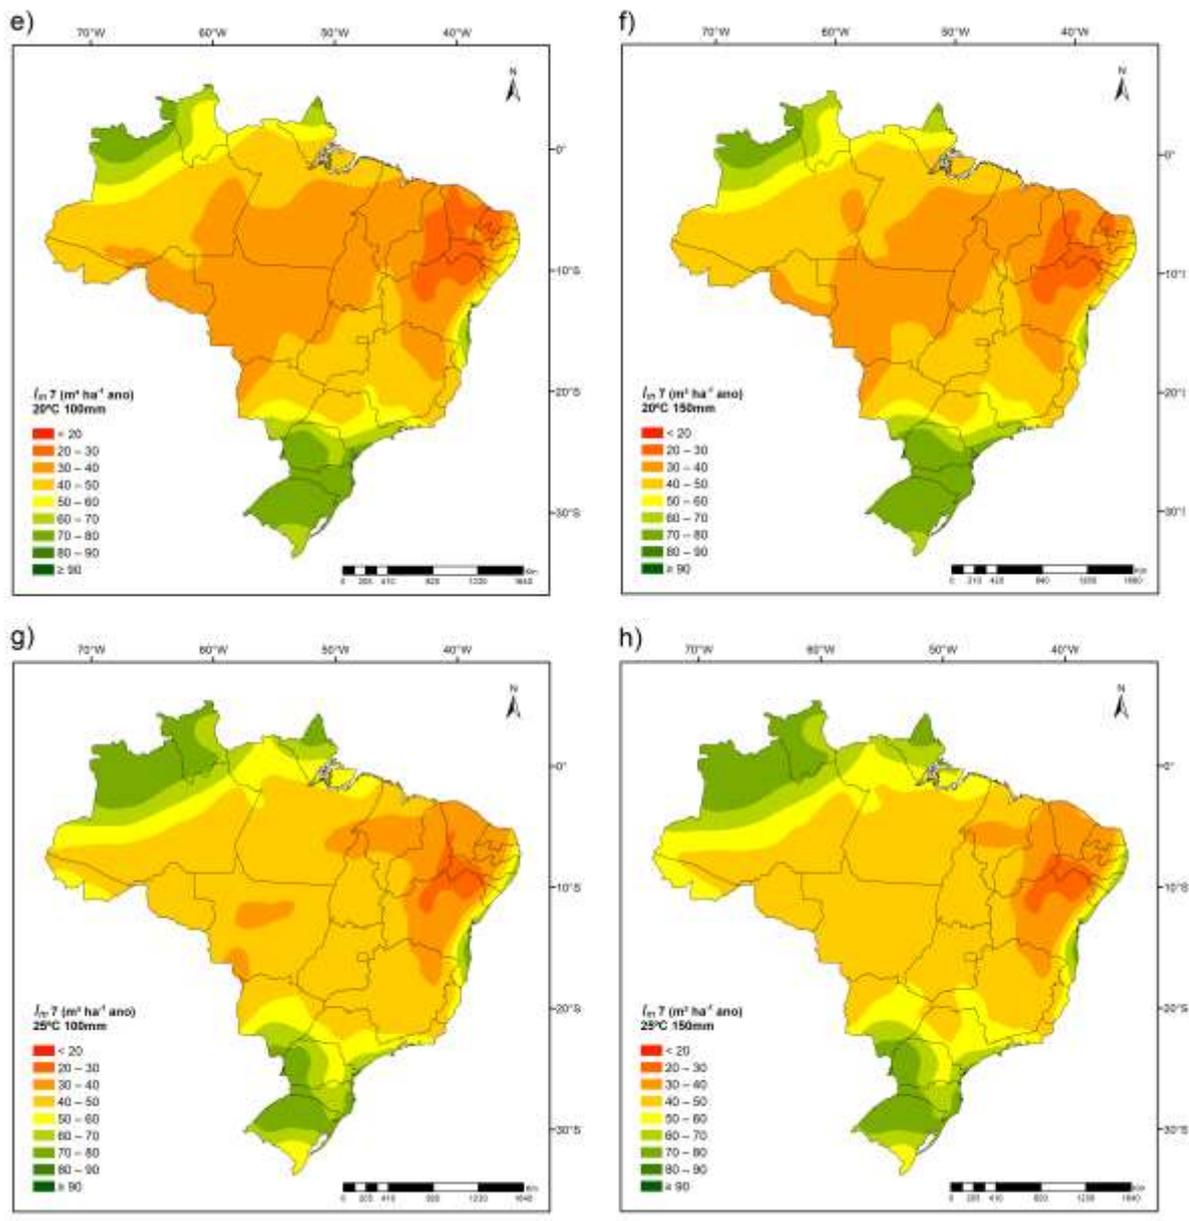
Fonte: Elaborada pela autora.

Os mapas gerados pelas estimativas do 3-PG + RNA apresentaram a maior parte das produtividades potenciais entre 40 e 50 $m^3 ha^{-1}$ ano, em todos os casos. Porém, a distribuição variou conforme as condições de temperatura ótima e em função da quantidade máxima de água disponível no solo (Figura 16).

Figura 16 - Mapas de produtividade potencial (I_m) aos 6 anos considerando 20 °C como temperatura ótima e o máximo de água disponível no solo de 100 mm (a) e 150 mm (b), temperatura ótima de 25 °C e o máximo de água disponível no solo de 100 mm (c) e 150 mm (d). Produtividade potencial aos 7 anos considerando 20 °C como temperatura ótima e o máximo de água disponível no solo de 100 mm (e) e 150 mm (f), 25 °C como temperatura ótima e o máximo de água disponível no solo de 100 mm (g) e 150 mm (h). A primeira parte da figura contém todos os mapas em conjunto e em seguida os mapas em tamanho maior.







Fonte: Elaborada pela autora.

4 DISCUSSÃO

Por meio de parametrizações do modelo 3-PG encontradas na literatura, simulamos o crescimento de povoamentos de eucalipto em diferentes condições climáticas. Estas informações foram usadas para testar a contribuição das redes neurais artificiais no modelo 3-PG. Isto foi feito assumindo que o aprendizado de máquina permite relacionar diferentes tipos de variáveis, sendo uma alternativa adequada para flexibilizar o modelo 3-PG e aumentar a exatidão de suas estimativas. A premissa era de que a exatidão poderia ser aumentada por existirem relações processuais não lineares, que podem ser melhor explicadas com a inclusão de variáveis climáticas, fisiológicas e edáficas, além de variáveis de povoamento.

4.1 Processamento com o modelo 3-PG

As simulações de crescimento em biomassa pelo modelo 3-PG apresentaram variabilidade de acordo com o genótipo e as características climáticas de cada região. As regiões ao norte do país apresentaram produções mais baixas de biomassa de fuste, principalmente no sul do Amapá. Essas regiões possuem temperaturas médias de aproximadamente 7°C acima da temperatura ótima considerada para eucalipto (20°C) (BINKLEY *et al.*, 2020), sendo um dos fatores influentes nesse resultado. Além disso, possuem precipitação pluviométrica anual elevada, mas com distribuição irregular ao longo do ano, passando por período de baixas precipitações e conseqüentemente reduções nas taxas de crescimento, que já eram baixas.

Os sítios com as maiores produções de biomassa de fuste foram aqueles localizados na Argentina, sul e sudeste do Brasil, são regiões com temperaturas médias mais próximas do ótimo. Nos sítios localizados na Argentina e no sul do Brasil a precipitação pluviométrica é distribuída de forma regular, com pelo menos 90 mm mês⁻¹. Por serem regiões de clima subtropical, o fator mais limitante ao crescimento foi a temperatura, havendo quedas nas taxas de crescimento em períodos de temperatura baixa (15 e 14°C) ou muito elevada (24,5 e 26,5°C), sendo esta responsável pelas maiores taxas de redução do crescimento nessas regiões. Em São Paulo, no sudeste do Brasil, o sítio encontra-se em região de clima tropical, com período seco de junho a agosto (precipitações em torno de 30 mm mês⁻¹),

portanto, nos períodos de queda na precipitação pluviométrica ocorreram quedas nas taxas de crescimento, caracterizando o principal fator limitante nessas regiões.

O comportamento das estimativas de biomassa ao longo do tempo variaram conforme o clima e a parametrização utilizada, de modo que mesmo sítios mais próximos, como aqueles localizados no RS e SP, apresentassem diferentes produções de biomassa.

As oscilações do modelo 3-PG ao longo do tempo são consequência de variações climáticas, especialmente daqueles fatores mais limitantes para um determinado sítio. Nas regiões de clima tropical a queda na precipitação pluviométrica corresponderam a quedas na taxa de crescimento, enquanto em sítios de clima subtropical, onde não houve déficit hídrico, quedas e aumentos significativos da temperatura foram os fatores mais limitantes, causando redução nas taxas de crescimento nesses períodos. Quando esses fenômenos ocorrem de forma extrema, por exemplo, os períodos de seca na região central de Minas Gerais, forma-se uma descontinuidade da curva de crescimento do modelo, o que não foi observado em regiões tropicais com chuvas mais abundantes e bem distribuídas ao longo do ano, bem como regiões subtropicais sem amplas variações de temperatura. Essa tendência foi observada por Elli *et al.* (2020), em que a menor disponibilidade de água no solo foi o principal fator limitante da produtividade em regiões de clima tropical, enquanto em regiões temperadas foi a variação sazonal da temperatura. Em plantios de eucalipto no estado de São Paulo, Attia *et al.* (2019) verificaram que o efeito da seca e da precipitação pluviométrica foram os fatores climáticos mais importantes na restrição do crescimento do eucalipto na região estudada.

Ao analisar o crescimento da área transversal do fuste em plantios de eucalipto, pinus e em povoamentos inequiâneos, em diferentes condições climáticas, Campoe *et al.* (2016) observaram que o crescimento foi diretamente correlacionado com a variação sazonal do regime hidrológico em regiões tropicais, e em regiões subtropicais as variações de temperatura foram mais influentes no crescimento transversal. Além disso, os autores ressaltaram a semelhança na forma como o crescimento responde à sazonalidade do clima, sempre de forma proporcional ao fator mais limitante. Tal fato foi descrito de forma consistente pelo modelo 3-PG em nosso estudo, com realismo biológico e sensibilidade às variações climáticas de cada região.

Sobre as mudanças determinadas por parte dos parâmetros utilizados em regiões próximas, verificamos diferenças nas tendências da distribuição da biomassa entre os compartimentos, causado principalmente por diferentes valores dos parâmetros ligados a alocação de biomassa e eficiência quântica máxima do dossel, que dependem, por exemplo, do clone cultivado. Ao comparar o crescimento de diferentes genótipos de *Eucalyptus grandis* no Espírito Santo, Almeida, Landsberg e Sands (2004) observaram que as diferenças entre as produções foram causadas, principalmente, por diferenças na partição da biomassa e na condutância estomática.

O gradiente climático afeta os fluxos de biomassa de forma significativa, fazendo com que o aumento da temperatura reduza a quantidade de biomassa produzida e o déficit hídrico aumente a quantidade de biomassa alocada para as raízes, mas materiais genéticos diferentes podem apresentar padrões de alocação de biomassa diferentes, ainda que produzam mesma quantidade de biomassa bruta (CAMPOE *et al.*, 2020).

Em geral, houve tendência de redução da produtividade média aos 7 anos (I_m 7) com o aumento da temperatura e da latitude. Elli *et al.* (2020) observaram aumentos de $0,91 \text{ m}^3 \text{ ha}^{-1} \text{ ano}^{-1}$ no I_m potencial, em diferentes sítios, a cada 1° de aumento na latitude, o que indiretamente reflete os efeitos da redução da temperatura média.

Estudos recentes, contemplando diferentes condições de solo, clima e genótipo ao longo do Brasil, observaram que apesar dos efeitos da precipitação pluviométrica e da temperatura sobre a produtividade do eucalipto serem dependentes, os plantios responderam de forma mais significativa aos efeitos da temperatura, que apresentou diferença estatística mínima em relação ao seu efeito em conjunto com a precipitação pluviométrica (BINKLEY *et al.*, 2017; CAMPOE *et al.*, 2020). Aumentos em 1°C na temperatura média reduziu $2,9 \text{ Mg ha}^{-1} \text{ ano}^{-1}$ na produtividade de biomassa de fuste e acréscimos de 100 mm ano^{-1} na precipitação pluviométrica aumentaram a produtividade em $1,5 \text{ Mg ha}^{-1} \text{ ano}^{-1}$ (BINKLEY *et al.*, 2017). Aumentos em 100 mm ano^{-1} na precipitação pluviométrica geraram incrementos de $2,3 \text{ Mg ha}^{-1} \text{ ano}^{-1}$ na produção primária líquida em plantios de eucalipto na região nordeste do Brasil (STAPE; BINKLEY; RYAN, 2004). Campoe *et al.* (2020) verificaram reduções de $4,8 \text{ Mg ha}^{-1} \text{ ano}^{-1}$ na produção de biomassa de

fuste a cada 1 °C de aumento na temperatura, bem como reduções de 127 g C m⁻² ano⁻¹ em biomassa total abaixo do solo.

Usualmente é considerado 25 °C como temperatura ótima de crescimento do eucalipto, para os genótipos mais plantados no Brasil (*Eucalyptus grandis* x *Eucalyptus urophylla*), porém, conforme descoberto recentemente por pesquisadores, a temperatura ótima está em torno de 20 °C. Isso representa uma nova abordagem para entender os efeitos das variações sazonais e mudanças climáticas.

A compreensão dos efeitos da temperatura e da sua interação com os demais fatores do ambiente é importante para que a melhor combinação possível entre clima, solo, genótipo e práticas silviculturais sejam alcançadas. Esses efeitos de aumento da temperatura no crescimento da floresta, envolvem mudanças a nível de membrana, afetando a fotossíntese, respiração, fenologia, alocação, *turnover* e decomposição da serapilheira (MONTANÉ *et al.*, 2011). São efeitos que variam com a interação entre esses fatores, conforme a magnitude e duração da flutuação da temperatura, e podem ser mais acentuados no período de seca e alta irradiância da luz solar direta, causando aumento da temperatura da folha e danos nas membranas e enzimas, além de gerar desbalanceamento entre os processos de respiração e de fotossíntese (ÖRDÖG; ZOLTÁN, 2011).

Os efeitos podem variar de acordo com as condições climáticas. Crous *et al.* (2018) identificaram que espécies de eucalipto provenientes de regiões de clima tropical e subtropical reduziram a taxa fotossintética com o aumento da temperatura de crescimento, devido a reduções na concentração de nitrogênio e da enzima Rubisco nas folhas, enquanto em procedências de clima temperado, a taxa fotossintética aumentou. Binkley *et al.* (2017) observaram quedas de até 40% na produção de biomassa de fuste com o aumento da temperatura acima do nível ótimo considerado (20°C).

As tendências de redução da produtividade com o aumento da temperatura foram adequadamente representadas pelo modelo, e o efeito positivo da precipitação pluviométrica foi observado apenas quando desconsiderada a região norte do país, o que pode, em parte, representar o efeito limitante da alta temperatura mesmo associado a precipitações elevadas.

É importante destacar, que o efeito da radiação solar também tem importante influência na produtividade florestal. Ela é responsável por fornecer a energia que

será absorvida e utilizada pelas árvores para produzir a biomassa bruta. Mas a quantidade de radiação solar disponível tende a variar conforme a latitude, topografia e declividade do local, que pode influenciar a exposição ao sol, e de acordo com a variação sazonal (COOPS; COGGINS; KURZ, 2007). Silva *et al.* (2013) realizaram uma modificação no submodelo de balanço hídrico do 3-PG para melhorar o processo de transpiração em relação ao controle estomático, regulado pela temperatura, déficit de pressão de vapor e balanço de energia. A variação na radiação solar em função da inclinação do terreno foi considerada no cálculo da transpiração.

No trabalho de Borges (2012), depois da precipitação pluviométrica, a radiação solar foi o fator climático que mais influenciou a produtividade potencial do eucalipto no Brasil. Além da quantidade de radiação solar incidente, a eficiência do uso da luz é responsável por causar grandes diferenças na produção de biomassa de fuste entre sítios (BINKLEY *et al.*, 2017).

Os ajustes do modelo sigmoide aos dados gerados para cada parametrização permitiram avaliar e compreender o desenvolvimento volumétrico estimado pelo 3-PG ao longo do tempo, seguindo os desenvolvimentos de Cordido (2019). Na sua pesquisa, os pontos de crescimento da curva sigmoide foram utilizados para interpretar o comportamento de plantios de eucalipto separado em duas condições. A primeira constituída por áreas mais produtivas e a segunda referente a áreas menos produtivas. Essa separação foi feita por meio da extração das fronteiras de limite superior e inferior do banco de dados, com as quais foram feitos os ajustes do modelo sigmoide logístico. Com esses ajustes, foi possível avaliar as tendências de crescimento em relação ao acúmulo de biomassa aérea e ao acúmulo dos nutrientes N, P, K, Mg e Ca no tronco, lenho e parte aérea ao longo do tempo.

Ao aplicar essa abordagem em nossa pesquisa, observou-se que em sítios com a máxima aceleração do crescimento ocorrendo mais cedo, as demais fases do crescimento também tenderam a ocorrer mais cedo. Isto faz com que o período de rotação silvicultural aconteça antes dos 6 ou 7 anos, as idades de rotação geralmente adotadas pelas empresas. Esse comportamento foi observado em sítios que atingiram a idade de máxima taxa de crescimento (t_2) antes dos três anos, correspondente a 11 das 16 parametrizações usadas. As consequências dessa dinâmica de crescimento é que haverá perda de produtividade ao manter o plantio por mais tempo que o necessário (HELFENSTEIN, 2020).

Três sítios se comportaram de forma diferente, com idade de máxima aceleração do crescimento (t_1) aos 1,2 meses, máxima taxa de crescimento (t_2) após três anos e com idade de máximo I_m próximo dos 7 anos, pelas parametrizações de Stahringer (2017) e Stape, Ryan e Binkley (2004). Em ambos os casos, o comportamento da curva é o mesmo, com tendência sigmoideal menos acentuada e com diferenças apenas na produção total, segundo as características climáticas de cada região.

Na parametrização de Lemos (2012), o valor de t_1 também foi de 1,2 meses e as demais fases do crescimento ocorreram em menores idades, exceto a máxima desaceleração do crescimento que ocorreu próximo dos 7 anos. Nesse caso, a tendência de crescimento sigmoide foi a menos acentuada, com crescimento quase linear no intervalo inicial.

Como na maior parte das parametrizações a idade de máxima taxa de crescimento ocorreu antes dos 3 anos, seria interessante verificar se o modelo processual tende a estimar precocemente a idade de máxima aceleração do crescimento e suas possíveis causas.

Outra questão, é que nas três condições onde a máxima aceleração do crescimento ocorreu muito cedo, o comportamento biológico não foi conforme o esperado. Pode ser, que no presente estudo, algum parâmetro considerado como padrão não tenha sido o valor utilizado pelos autores em suas pesquisas. Outra explicação seria a configuração inicial aqui adotada que pode ter causado esse comportamento nas estimativas desses sítios. Diante disso, percebeu-se que por meio do ajuste de um modelo sigmoide às estimativas de um modelo processual, é possível verificar se a parametrização ou a calibração do modelo deve ser revisada, em casos onde o comportamento da curva não segue o comportamento esperado.

Além do efeito do genótipo, as taxas de crescimento tendem a variar com a idade e conforme as interações com os fatores do ambiente (ALMEIDA *et al.*, 2007). Entre estes, os autores ressaltam mudanças no índice de área foliar (A_f) como um importante fator para explicar estas variações. Conhecer esses pontos é importante para o planejamento na rotação florestal, em termos ecofisiológicos e de nutrição do solo, o que permite interpretações práticas para o manejo de uma floresta. Por exemplo, no planejamento da adubação, é importante que o nutriente esteja disponível para a planta antes que ocorra a mudança de fase do crescimento (CORDIDO, 2019). E as fases de crescimento vão diferir segundo as condições de

crescimento da floresta, como espaçamento, genótipo e capacidade produtiva do lugar (HELFENSTEIN, 2020).

Como as saídas do modelo 3-PG são fornecidas mensalmente, existe uma maior segurança e detalhes nas informações geradas, porém, a descontinuidade da curva dificulta a interpretação sobre os aspectos biológicos do crescimento. O ajuste de uma função contínua sobre esses dados é uma alternativa simples e eficiente para suavizar a curva e analisar o comportamento das taxas de crescimento, acrescentando interpretações sobre as estimativas do 3-PG, e não apenas da produção final estimada por ele. O mesmo é válido para análises sobre diferentes cenários de crescimento, como variação nas taxas de fertilidade, água disponível no solo, entre outros fatores, e como eles afetam a aceleração e desaceleração do crescimento.

Diante do exposto, as estimativas feitas pelo modelo 3-PG apresentaram comportamento de acordo com as tendências esperadas, com realismo biológico e consistência bem definidos, na maior parte dos casos, para representar o crescimento do eucalipto em diferentes regiões climáticas e com isso, geraram informações adequadas para estudo sobre o uso das redes neurais artificiais no modelo 3-PG.

4.2 Eficiência das redes neurais artificiais

As redes selecionadas apresentaram resultados estatísticos satisfatórios e bom desempenho na validação, com destaque para as redes que predizeram os parâmetros a_p e n_p e as variáveis biomassa de folha, D , altura total e volume. Cada combinação utilizada foi composta por variáveis climáticas, de inventário, biomassa (ou fração), índice de área foliar ou algum tipo de modificador do crescimento. Todas estas informações fazem parte do conjunto de dados já necessários para o uso do 3-PG e alguns já estão presentes na rotina de levantamentos de uma empresa, como os dados de clima e de inventário florestal.

Na validação, as relações entre as predições da rede e os valores simulados pelo 3-PG foram consistentes, sobrepondo a linha 1:1, com correlações acima de 0,9 e considerados semelhantes pelo teste F_{H0} (GRAYBIL, 1976), com exceção dos parâmetros n_p e a_p e o volume. Esta exceção se deve a presença de viés, que em casos como esses, onde a correlação é muito alta ($\approx 100\%$) e os dados se

concentram sobre a reta 1:1, qualquer pequena variação nas predições, especialmente para variáveis com valores baixos, como no caso dos parâmetros, faz com que o resultado do teste seja significativo, pois a baixa variância residual diminui o denominador do teste F ($2 \cdot \text{RMS}$) aumentando o valor de F e a chance de se rejeitar H_0 (LEITE; OLIVEIRA, 2002).

Na RNA treinada para a predição do parâmetro n_p houve um viés gerado por um valor igual a -2,35 que foi predito como -2,31, uma pequena diferença. No treinamento dessa rede, o erro médio foi de -0,027% e o erro máximo de -1,42%, portanto, esse viés não impede a aplicação dessa rede. Na predição do parâmetro a_p o erro foi mais elevado, com valores de até 130%, fazendo com que o valor de 0,13 fosse predito como $\approx 0,30$. Além disso, houve um desbalanceamento dos dados, com maior concentração de erros em intervalo específico e com tendência de superestimativa, esta tendência foi observada também nos resíduos da rede para volume.

Graficamente e por meio das demais análises estatísticas é possível perceber que a causa desses resultados no teste F foi a alta correlação e a baixa variância residual. A análise conjunta das estatísticas e dos gráficos é muito importante para a tomada de decisão em trabalhos de modelagem, assim como conhecer o comportamento das variáveis estudadas e a abrangência dos dados. Nessas redes, as RQEM foram baixas e a dispersão dos dados adequada, portanto, o uso dessas redes não causariam perdas na precisão das predições, já que os demais erros foram relativamente baixos.

Os parâmetros a_p e n_p fazem parte da equação alométrica que estima a proporção da biomassa total líquida a ser alocada para a parte aérea (folha/fuste), logo após a determinação da proporção de biomassa a ser alocada para as raízes. Trata-se de um modelo potencial simples que descreve bem a relação entre o D e a p_{FS} . Nessa relação o a_p determina o deslocamento da curva e o n_p a taxa de decréscimo da proporção entre folha e fuste com o aumento do D (concavidade), o que o torna mais importante para a definição precisa desse comportamento.

Além disso, esses parâmetros refletem efeitos genéticos, especialmente o valor da potência, pois ele considera a relação entre a partição da biomassa em idade jovem e adulta. Cabe ressaltar, que a p_{FS} não varia apenas em função do tamanho da árvore, mas também depende das condições do ambiente (SANDS;

LANDSBERG, 2002), tornando a RNA uma alternativa para relacionar estas variáveis.

Os demais modelos de RNA também apresentaram desempenho adequado, principalmente para prever as variáveis D , altura total, volume e a biomassa de folha, já as previsões para as biomassas de raiz e de fuste, apesar de consistentes, tiveram maior variabilidade.

Embora a alocação de biomassa seja determinada, em parte, pelo genótipo, existe também a influência do ambiente, em que condições adversas, como a baixa disponibilidade de água e nutrientes no solo, fazem com que a quantidade de biomassa alocada para a raiz aumente e para fuste diminua (ZHAO *et al.*, 2009). Esta relação entre a alocação de biomassa e o ambiente podem ser representadas pela rede por meio do uso de variáveis climáticas, e o maior erro e dispersão dessas previsões podem ser corrigidos com o acréscimo de variáveis edáficas, como propriedades físicas do solo ligadas a permeabilidade, densidade e porosidade, que ajudam a descrever o fluxo de água e oxigênio e a disponibilidade de nutrientes, tornando-se importantes indicativos de produtividade (CAVALLI *et al.*, 2020). Outra alternativa seria o uso da variável teor de argila, sendo uma informação geralmente disponível.

Em geral, houve tendência de superestimativa dos menores valores, com maiores diferenças apenas nas redes de biomassas de raiz e de fuste, e na maior parte dos casos para as menores previsões, entre 1 e 5 Mg ha⁻¹ para raiz e entre 1 e 14 Mg ha⁻¹ para fuste, correspondente ao período de até um ano. Nas demais redes, esses erros não ocorreram ou foram em menor quantidade e com menores valores de ER%.

O banco de dados gerado pelo modelo 3-PG, contemplou diferentes condições climáticas, partindo dos 3 meses. No entanto, nesse período de crescimento inicial, os efeitos e tendências de cada sítio ainda não são refletidas no crescimento da floresta de forma clara. Nesse período, a variância é baixa, de modo que, para uma mesma idade, os valores de biomassa são próximos, sem distinção nas tendências de crescimento de cada região. Isto pode fazer com que o processo de aprendizado da rede seja prejudicado e ocorram maiores erros neste intervalo. Realizar o treino das redes com dados em idades acima de um ano podem reduzir esses erros e melhorar a precisão dos resultados.

Ao associar o teste de Garson ao diagrama de interpretação neural (DIN) foi possível interpretar a relação entre as variáveis de entrada e saída de cada rede. De modo geral, as variáveis que apresentaram relação direta com as variáveis de saída, obtiveram maiores valores de importância relativa que as variáveis climáticas.

As redes treinadas para prever os parâmetros a_p e n_p foram melhores ao manter as variáveis fração de biomassa da parte aérea com 2 e 20 cm de D , conforme adotado pelo modelo 3-PG. Na predição do parâmetro n_p o acréscimo das variáveis precipitação pluviométrica, temperatura média e A_f também contribuíram para a rede.

A área foliar tende a decrescer com a idade, devido à redução na condutância estomática e na condutividade hidráulica (LANDSBERG; WARING, 1997). Mas, além disso, o sistema fotossintético, representado pelo A_f no modelo, também é determinado pela qualidade do sítio (MEGOWN; WEBSTER; JACOBS, 1999). O A_f tem forte relação com a precipitação pluviométrica anual média (ELLIS; HATTON, 2008), é responsável pela determinação da condutância do dossel (WARING; LANDSBERG, 2011) e também pode ser influenciada pela altitude (RODY *et al.*, 2016). Dessa forma, sua variação no tempo e espaço pode colaborar na predição das variáveis.

Para o parâmetro a_p , as variáveis radiação solar e precipitação pluviométrica apresentaram 13% de importância relativa. Nas redes para predição dos parâmetros a_p e n_p , como a relação entre as frações de biomassa da parte aérea com os parâmetros já é muito bem definida, e por ser uma característica específica do clone ou espécie, o peso se torna maior, porém a variável climática permite prever os parâmetros com maior segurança quando se tratar de áreas com diferenças climáticas mais amplas.

O uso da RNA para prever a biomassa de raiz necessitou de maior número de variáveis de entrada (7 variáveis), em particular aquelas ligadas a efeitos adversos do ambiente, como o φ , que representa o modificador dependente do déficit de pressão de vapor e da quantidade de água disponível no solo, considerando aquele que for mais limitante, e o modificador dependente da idade. São fatores do ambiente que em condições desfavoráveis ao crescimento, aumentam a quantidade de biomassa alocada para raízes no modelo 3-PG, além do decréscimo natural com o aumento da idade. A taxa de fertilidade do solo também é considerada nesse cálculo.

No caso dessa rede, o p_2 apresentou maior importância relativa e foi essencial na redução do erro da rede, este parâmetro tem relação inversa com a biomassa de raiz, e é de fácil obtenção, o A_f e a idade também apresentaram importância relativa mais alta em relação as demais variáveis. O A_f é interessante, pois varia em função de alguns fatores do ambiente, e pode ser referência sobre as características de fertilidade do solo, além de ser de fácil acesso via sensoriamento remoto (COOPS; WARING; HILKER, 2012; POTITHEP; ENDO; TAKEUCHI, 2009).

A maior parte das variáveis usadas na rede de biomassa de fuste foram climáticas, a precipitação pluviométrica apresentou a maior importância relativa. Como já observado, o aumento da precipitação pluviométrica tende a aumentar a quantidade de biomassa produzida, que junto a condições favoráveis de nutrição do solo, tendem a aumentar a alocação para o fuste, portanto exerce importante influência na predição da biomassa de fuste. A temperatura média apresentou o segundo maior valor de importância relativa, e ao estar presente na rede pode refletir os efeitos positivos, quando próximo à temperatura ótima, ou negativos quando acima do ótimo.

A rede para prever a biomassa de folha teve como variáveis de maior importância o A_f e a idade. A biomassa foliar é uma variável muito importante por ser a base dos modelos processuais, pois representa o tamanho do sistema fotossintético, a partir do qual se define a radiação fotossinteticamente ativa absorvida pelo dossel. Nesse sentido, o A_f pode ser uma forma mais simples de estimá-la. A amplitude entre as temperaturas foi a variável de maior importância relativa entre as variáveis climáticas, isso pode ser explicado pela sensibilidade que a biomassa foliar tem às variações sazonais, expressa nesse caso, pela amplitude entre as temperaturas, que junto às demais variáveis ajuda a explicar a variação na biomassa foliar. Drake *et al.* (2015) observaram que o acúmulo da área foliar total é um importante preditor das respostas do crescimento ao aumento da temperatura. Além disso, existe uma relação muito clara entre biomassa de folha e idade, com tendência de redução na taxa de crescimento ao longo do tempo, por isso a idade também pode ser um importante preditor da biomassa foliar.

A rede para prever o D apresentou resultados precisos com o uso da biomassa média de fuste, com maior importância relativa, seguida pelas variáveis RFAA, temperatura média e precipitação pluviométrica. No modelo 3-PG o D é estimado a partir do rearranjo da função potencial entre a biomassa de fuste média

por árvore (w_s) e o D , ou seja, no ajuste original considera-se o inverso da relação e não um ajuste direto com D como variável dependente (GONZALEZ-BENECKE *et al.*, 2014). Além disso, os parâmetros presentes nessa função, especialmente o n_s , geralmente causam alta sensibilidade em algumas saídas do modelo, como o A_f (ESPREY; SANDS; SMITH, 2004), biomassa de folha, D e área basal (ALMEIDA; LANDSBERG; SANDS, 2004; PÉREZ-CRUZADO *et al.*, 2011). Ao substituir a relação alométrica original pela RNA, o D passa a ser estimado diretamente e se elimina a preocupação sobre os cuidados na estimativa do parâmetro n_s .

A altura total estimada apenas em função do D nem sempre gera resultados precisos, pois depende também de outros fatores, como o sítio, e só é recomendado para pequenas áreas homogêneas (CAMPOS; LEITE, 2017). A rede selecionada integra o D , de maior importância relativa, e as variáveis de clima RFAA, precipitação pluviométrica e temperatura média, tornando o modelo mais completo e representativo das condições do sítio.

Os trabalhos desenvolvidos com as redes neurais para prever altura total demonstram outras possibilidades de entradas na rede, como altura dominante, solo, genótipo e idade, que podem trazer benefícios como alta precisão, ausência de tendências, redução no esforço amostral e conseqüentemente no custo (BINOTI; BINOTI; LEITE, 2013). Junto às informações climáticas, informações como regime de corte, espaçamento inicial e diâmetro máximo do povoamento são outras opções interessantes de variáveis que podem ser adicionadas a rede, além de outras variáveis categóricas (CAMPOS; LEITE, 2017).

Na predição do volume, o D e a altura total foram as variáveis mais importantes em relação as demais, estas são as variáveis usualmente empregadas nos modelos de regressão, porém no modelo 3-PG é considerado apenas o D , ou o cálculo pode ser realizado a partir da densidade básica da madeira. Almeida *et al.* (2010) verificaram tendência de superestimativa do I_m em menores idades e subestimativa em maiores idades, um dos fatores apontados como causa foi o cálculo do volume ser baseado na densidade básica da madeira. Esses autores consideraram um valor constante de densidade, que recebia incremento anual, porém esta variável é sensível a mudanças na umidade e fertilidade do ambiente. Como o volume tem alta sensibilidade em relação à densidade da madeira (ESPREY; SANDS; SMITH, 2004) e o 3-PG não considera efeitos importantes do

sítio em sua variabilidade, apenas a idade, o uso de um modelo mais completo para prever o volume seria uma forma de solucionar essa questão.

Mesmo que no presente trabalho tenha sido considerado o cálculo do volume com base na densidade da madeira, para utilizar parametrizações que não forneciam os parâmetros da regressão do volume = $f(D)$, a combinação de variáveis aqui sugerida pode ser aplicada no treino da rede, usando como saída o volume fornecido pelo inventário florestal, com forte possibilidade de gerar previsões consistentes. Com o modelo da RNA foi possível integrar o D e a altura total, importantes para a previsão do volume, além das variáveis A_f , temperatura média e precipitação pluviométrica, que no presente estudo apresentaram melhor desempenho. É também interessante testar as variáveis área basal, altura dominante ou índice de sítio para prever o volume do povoamento com maior consistência.

As pesquisas com o uso de redes neurais artificiais para a previsão do volume individual de árvores ou para a produtividade do povoamento apresentaram resultados estatísticos muito satisfatórios. Para volume individual de árvores, uma única rede utilizando as variáveis D , altura total, idade, espaçamento, clone e projeto, apresentaram resultados muito próximos do modelo Schumacher e Hall ajustado para 53 estratos (BINOTI; BINOTI; LEITE, 2014). Tanto no processo de previsão quanto projeção da produção florestal, a RNA integrada por variáveis climáticas, edáficas, espaçamento, ciclo de corte e tipo de solo predominante apresentaram resultados consistentes, possibilitando a aplicação da rede para prever a produção de todo estado de MG (ALCANTRA *et al.*, 2018). O mesmo foi observado por Freitas *et al.* (2020) para a modelagem da produção de eucalipto em algumas regiões de MG, o uso de variáveis edáficas, climáticas, genótipo e espaçamento contribuíram para gerar previsões com alto grau de exatidão.

As experiências com as pesquisas na área colaboram para reforçar o potencial da técnica e as muitas possibilidades de uso, por permitir a adição de diferentes categorias de variáveis de forma simples. Podendo ser usada em conjunto com o modelo 3-PG ou de forma individual.

Além da rede possibilitar a inclusão de variáveis categóricas, existe a vantagem de redução no tempo e esforço amostral, visto que a rede é capaz de extrair informações dos dados com facilidade, desde que tenham a variabilidade adequada (COSENZA *et al.*, 2017). Além disso, o uso da rede em substituição às

relações alométricas do D , altura total e volume, aumentam o potencial do 3-PG como ferramenta de manejo florestal e não só para fins de planejamento e pesquisa.

Com as redes testadas neste trabalho foi possível aprimorar a parte do modelo onde são realizados os cálculos dendrométricos e a predição dos parâmetros a_p e n_p . Porém, é também possível considerar diferentes combinações, tanto entre o 3-PG + RNA quanto apenas RNA. Por exemplo, prever diretamente a biomassa de fuste e em seguida, o D , altura total e volume ou prever as biomassas de raiz, fuste e folha diretamente e em seguida o D , altura total e volume.

Outra possibilidade para uso do modelo 3-PG + RNA seria gerar as saídas das variáveis dendrométricas, a partir das suas distribuições de probabilidade diante de diferentes cenários. Ou ainda, considerar maior amplitude de dados amostrados, visto que os ganhos em produtividade não têm aumentado como em anos anteriores, para entender e buscar a estabilidade da produtividade florestal.

A partir da aplicação das redes em duas regiões de Minas Gerais, apesar dos erros relativamente baixos em relação aos valores observados, houveram algumas tendências entre os resultados obtidos.

Como se manteve uma configuração comum para o tipo de solo e a quantidade de água disponível, as predições das redes foram superiores aos dados observados. Na configuração usada por Borges (2009), a textura de solo considerada para a região foi o *Clay*, que tende a gerar uma menor produtividade em relação ao *Sand Loam*, usado para gerar o banco de dados de treinamento da rede. Dessa forma, como algumas condições não foram representadas de forma totalmente consistente com o sítio, isso pode ter sido um dos fatores que geraram essas diferenças.

As predições dos parâmetros a_p e n_p por clone apresentaram resultados muito próximos dos valores utilizados por Borges (2009). A rede para biomassa foliar também apresentou erros relativos baixos e distribuídos de forma mais homogênea em relação as demais variáveis, porém houve diferença entre clones, com tendência a subestimar os valores do clone 3334. Em geral, houve diferença entre clones, mas na predição do volume do povoamento essa diferença foi menor.

O uso do modelo 3-PG + RNA para gerar os mapas de produtividade, em que a RNA foi usada para os cálculos da altura total e do volume, representaram as produtividades aos 6 e 7 anos ao longo do Brasil de forma coerente com o gradiente climático do país. Apesar das redes não terem sido treinadas em todas essas

condições de temperatura ótima e quantidade de água disponível no solo, a representação do efeito na mudança desses fatores foi muito consistente.

É possível perceber que ao alterar a temperatura ótima para 25 °C, as produtividades na região sul do Brasil reduziram e na região central aumentaram. Foi também refletido o efeito da maior disponibilidade hídrica, mais expressiva nas regiões menos produtivas, este fato ajuda a comprovar a capacidade de generalização da rede. A única limitação foi o uso de mesmo FR (0,8) para gerar o banco de dados, que pode ter influenciado a amplitude dos resultados de produtividade potencial, porém essa questão pode ser solucionada ao utilizar redes que contemplem informações de solo ou realizar o treinamento das redes com um banco de dados com informações observadas de inventário florestal.

Nas explicações sobre o funcionamento do modelo 3-PG, Sands (2004) reforça que para uma parametrização adequada do modelo é preferível o uso de dados observados e que contemplem os diferentes sítios, idades, espaçamentos e ainda diferentes condições de crescimento como em casos de presença e ausência de limitações hídricas e de fertilidade.

Dessa forma, a contribuição da técnica de RNA para o modelo 3-PG, além de trazer ganhos em exatidão, é uma forma de facilitar o uso de modelos processuais, principalmente em regiões muito amplas que contemplem diferentes tipos de genótipo, espaçamento, fertilização, planos silviculturais, solo, clima, entre outros. Portanto, o esforço amostral e a necessidade de dados experimentais para a parametrização e calibração do modelo podem ser reduzidos por meio do uso da RNA, o que traria redução de custo, tempo e esforço amostral.

A flexibilidade também pode ser conferida ao modelo, pois com a possibilidade de se obter informações que antes eram de difícil acesso, as redes podem ser uma alternativa para adicioná-las ao modelo 3-PG ou outro modelo processual. Esta seria uma forma mais eficiente de inserir e relacionar essas variáveis no modelo, o que com o uso da regressão seria mais difícil, por exigir maior esforço amostral. A análise de causa e efeito ficaria mais ampla, assim como a simulação de cenários para avaliar técnicas silviculturais e de manejo ou alterações climáticas. Outras técnicas de aprendizado de máquina podem e devem ser testadas em outros estudos, por exemplo as redes profundas (*deep learning*).

5 CONCLUSÕES

- a) Parâmetros e saídas do modelo 3-PG podem ser preditos com eficiência empregando redes neurais artificiais;
- b) O emprego de RNA permite representar o comportamento das biomassas de raiz, fuste e folha e das variáveis dendrométricas D , altura total e volume, de modo consistente, em um expressivo gradiente climático;
- c) A rede foi capaz de representar as tendências da produtividade potencial em diferentes condições de forma coerente;
- d) Maior flexibilidade e generalismo podem ser conferidos ao 3-PG por meio da inclusão de variáveis ambientais e ecofisiológicas integradas por uma RNA;
- e) O ajuste de um modelo sigmoide às estimativas de volume do modelo 3-PG gera uma função contínua, a partir da qual se torna possível avaliar biologicamente as diferentes etapas do crescimento em diferentes cenários.

REFERÊNCIAS

- ALCANTRA, A. E. M. de; SANTOS, A. C. de A.; MAYRA, L. M. da S.; BINOTI, D. H. B. Use of artificial neural networks to assess yield projection and average production of eucalyptus stands. **African Journal of Agricultural Research**, Nairobi, v. 13, n. 42, p. 2285-2297, 2018.
- ALMEIDA, A. C.; BRUCE, J.; SIGGINS, A.; LERICHE, A.; BATTAGLIA, M. Use of a spatial process-based model to quantify forest plantation productivity and water use efficiency under climate change scenarios. *In: WORLD IMACS CONGRESS AND MODSIM09 INTERNATIONAL CONGRESS ON MODELLING AND SIMULATION: INTERFACING MODELLING AND SIMULATION WITH MATHEMATICAL AND COMPUTATIONAL SCIENCES*, 18., 2009, Cairns. **Proceedings [...]**. Cairns: IAMCS, 2009. p. 1816-1822.
- ALMEIDA, A. C.; LANDSBERG, J. J.; SANDS, P. J. Parameterisation of 3-PG model for fast-growing *Eucalyptus grandis* plantations. **Forest Ecology and Management**, Amsterdam, v. 193, n. 1/2, p. 179-195, 2004.
- ALMEIDA, A. C.; SIGGINS, A.; BATISTA, T. R.; BEADLE, C.; FONSECA, S.; LOOS, R. Mapping the effect of spatial and temporal variation in climate and soils on *Eucalyptus* plantation production with 3-PG, a process-based growth model. **Forest Ecology and Management**, Amsterdam, v. 259, n. 9, p. 1730-1740, 2010.
- ALMEIDA, A. C.; SOARES, J. V.; LANDSBERG, J. J.; REZENDE, G. D. Growth and water balance of *Eucalyptus grandis* hybrid plantations in Brazil during a rotation for pulp production. **Forest Ecology and Management**, Amsterdam, v. 251, n. 1/2, p. 10-21, 2007.
- ALVARES, C. A.; STAPE, J. L.; SENTELHAS, P. C.; GONÇALVES, J. L. de M.; SPAROVEK, G. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, Berlin, v. 22, n. 6, p. 711-728, 2013.
- ATTIA, A.; NOUVELLON, Y.; CUADRA, S.; CABRAL, O.; LACLAU, J. P.; GUILLEMOT, J.; CAMPOE, O.; STAPE, J. L.; GALDOS, M.; LAMPARELLI, R. Modelling carbon and water balance of *Eucalyptus* plantations at regional scale: effect of climate, soil and genotypes. **Forest Ecology and Management**, Amsterdam, v. 449, p. 117460, July 2019.
- AUGUSTYNCZIK, A. L. D.; HARTIG, F.; MINUNNO, F.; KAHLE, H. P.; DIACONU, D.; HANEWINKEL, M.; YOUSEFPOUR, R. Productivity of *Fagus sylvatica* under climate change: a Bayesian analysis of risk and uncertainty using the model 3-PG. **Forest Ecology and Management**, Amsterdam, v. 401, p. 192-206, 2017.
- AZEVEDO, G. B. de; TOMIAZZI, H. V.; AZEVEDO, G. T. de O. S.; TEODORO, L. P. R.; TEODORO, P. E.; SOUZA, M. T. P. de; BATISTA, T. S.; EUFRADE-JUNIOR, H. de J.; GUERRA, S. P. S. Multi-volume modeling of *Eucalyptus* trees using regression and artificial neural networks. **PLoS ONE**, San Francisco, v. 15, n. 9, p. 1-17, Sept. 2020.

BAESSO, R. C. E. R. C. E.; RIBEIRO, A.; SILVA, M. P. Impacto das mudanças climáticas na produtividade do eucalipto na região norte do Espírito Santo e sul da Bahia. **Ciência Florestal**, Santa Maria, v. 20, n. 2, p. 335-344, 2010.

BEHLING, M.; PIKETTY, M. G.; MORELLO, T. F.; BOUILLET, J. P.; LACLAU, J. P.; MESQUITA NETO, F. Eucalyptus plantations and the steel industry in Amazonia: a contribution from the 3-pg model. **Bois et Forêts des Tropiques**, Paris, v. 65, n. 309, p. 37-49, 2011.

BINKLEY, D.; CAMPOE, O. C.; ALVARES, C. A.; CARNEIRO, R. L.; CEGATTA, I.; STAPE, J. L. The interactions of climate, spacing and genetics on clonal Eucalyptus plantations across Brazil and Uruguay. **Forest Ecology and Management**, Amsterdam, v. 405, p. 271-283, Sept. 2017.

BINKLEY, D.; CAMPOE, O. C.; ALVARES, C. A.; CARNEIRO, R. L.; STAPE, J. L. Variation in whole-rotation yield among Eucalyptus genotypes in response to water and heat stresses: the TECHS project. **Forest Ecology and Management**, Amsterdam, v. 462, p. 117953, Feb. 2020.

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

BINOTI, D. H. B.; DUARTE, P. J.; SILVA, M. L. M. da; SILVA, G. F. da; LEITE, H. G.; MENDONÇA, A. R. de; ANDRADE, V. C. L. de; VEGA, A. E. D. Estimation of height eucalyptus trees with neuroevolution of augmenting topologies (NEAT). **Revista Árvore**, Viçosa, MG, v. 41, n. 3, p. 1-8, 2017.

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

BORGES, J. S. **Modulador edáfico para uso em modelo ecofisiológico e produtividade potencial de povoamentos de eucalipto**. 2012. 70 p. Tese (Doutorado em Solos e Nutrição de Plantas) - Departamento de Solos, Universidade Federal de Viçosa, Viçosa, MG, 2012.

BORGES, J. S. **Parametrização, calibração e validação do modelo 3-PG para eucalipto na região do cerrado de Minas Gerais**. 2009. 77 p. Dissertação (Mestrado em Solos e Nutrição de Plantas) - Departamento de Solos, Universidade Federal de Viçosa, Viçosa, MG, 2009.

CALDEIRA, D. R. M.; ALVARES, C. A.; CAMPOE, O. C.; HAKAMADA, R. E.; GUERRINI, I. A.; CEGATTA, I. R.; STAPE, J. L. Multisite evaluation of the 3-PG model for the highest phenotypic plasticity Eucalyptus clone in Brazil. **Forest Ecology and Management**, Amsterdam, v. 462, p. 117989, Feb. 2020.

CAMPOE, O. C.; ALVARES, C. A.; CARNEIRO, R. L.; BINKLEY, D.; RYAN, M. G.; HUBBARD, R. M.; STAHL, J.; MOREIRA, G.; MORAES, L. F.; STAPE, J. L. Climate and genotype influences on carbon fluxes and partitioning in Eucalyptus plantations.

Forest Ecology and Management, Amsterdam, v. 475, May 2020. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0378112720312147?via%3Dihub>. Acesso em: 10 mar. 2021.

CAMPOE, O. C.; MUNHOZ, J. S. B.; ALVARES, C. A.; CARNEIRO, R. L. Meteorological seasonality affecting individual tree growth in forest plantations in Brazil. **Forest Ecology and Management**, Amsterdam, v. 380, p. 149-160, 2016.

CAMPOS, J. C. C.; LEITE, H. G. **Mensuração florestal: perguntas e respostas**. 5. ed. Viçosa, MG: Editora UFV, 2017. 636 p.

CAVALLI, J. P. **Produtividade de Eucalyptus saligna com base nas propriedades físico-hídricas do solo e parametrização do modelo ecofisiológico 3-PG**. 2017. 149 p. Tese (Doutorado em Engenharia Florestal) - Universidade Federal de Santa Maria, Santa Maria, 2017.

CAVALLI, J. P.; REICHERT, J. M.; RODRIGUES, M. F.; ARAÚJO, E. F. de. Composition and functional soil properties of arenosols and acrisols: effects on eucalyptus growth and productivity. **Soil & Tillage Research Journal**, Amsterdam, v. 196, Sept. 2020. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0167198719302053?via%3Dihub>. Acesso em: 10 mar. 2021.

COOPS, N. C.; COGGINS, S. B.; KURZ, W. A. Mapping the environmental limitations to growth of coastal Douglas-fir stands on Vancouver Island, British Columbia. **Tree Physiology**, Victoria, v. 27, n. 6, p. 805-815, 2007.

COOPS, N. C.; WARING, R. H. A process-based approach to estimate lodgepole pine (*Pinus contorta* Dougl.) distribution in the Pacific Northwest under climate change. **Climatic Change**, Dordrecht, v. 105, n. 1, p. 313-328, 2011.

COOPS, N. C.; WARING, R. H.; HILKER, T. Prediction of soil properties using a process-based forest growth model to match satellite-derived estimates of leaf area index. **Remote Sensing of Environment**, New York, v. 126, p. 160-173, 2012.

COOPS, N. C.; WARING, R. H.; LANDSBERG, J. J. Assessing forest productivity in Australia and New Zealand using a physiologically-based model driven with averaged monthly weather data and satellite-derived estimates of canopy photosynthetic capacity. **Forest Ecology and Management**, Amsterdam, v. 104, n. 1/3, p. 113-127, 1998.

CORDIDO, J. P. de B. R. **Eficiências nutricionais máximas e mínimas em povoamentos de eucalipto**. 2019. 86 p. Tese (Doutorado em Solos e Nutrição de Plantas) - Departamento de Solos, Universidade Federal de Viçosa, Viçosa, MG, 2019.

CORTE, A. P. D.; SOUZA, D. V.; REX, F. E.; SANQUETTA, C. R.; MOHAN, M.; SILVA, C. A.; ZAMBRANO, A. M. A.; PRATA, G.; ALMEIDA, D. R. A. de; TRAUTENMÜLLER, J. W.; KLAUBERG, C.; MORAES, A. de; SANQUETTA, M. N.; WILKINSON, B.; BROADBENT, E. N. Forest inventory with high-density UAV-Lidar:

machine learning approaches for predicting individual tree attributes. **Computers and Electronics in Agriculture**, New York, v. 179, p. 1-14, Apr. 2020.

COSENZA, D. N.; SOARES, A. A. V.; ALCÂNTARA, A. E. M. de; SILVA, A. A. L. da; RODE, R.; SOARES, V. P.; LEITE, H. G. Classificação de sítio para povoamentos de eucalipto disturbance utilizando redes neurais artificiais baseada em variáveis ambientais e de manejo. **Cerne**, Lavras, v. 23, n. 3, p. 310-320, 2017.

CROUS, K. Y.; DRAKE, J. E.; ASPINWALL, M. J.; SHARWOOD, R. E.; TJOEKLER, M. G.; GHANNOUM, O. Photosynthetic capacity and leaf nitrogen decline along a controlled climate gradient in provenances of two widely distributed Eucalyptus species. **Global Change Biology**, Oxford, v. 24, n. 10, p. 4626-4644, 2018.

DRAKE, J. E.; ASPINWALL, M. J.; PFAUTSCH, S.; RYMER, P. D.; REICH, P. B.; SMITH, R. A.; CROUS, K. Y.; TISSUE, D. T.; GHANNOUM, O.; TJOELKER, M. G. The capacity to cope with climate warming declines from temperate to tropical latitudes in two widely distributed Eucalyptus species. **Global Change Biology**, Oxford, v. 21, n. 1, p. 459-472, 2015.

ELLI, E. F.; SENTELHAS, P. C.; HUTH, N.; CARNEIRO, R. L.; ALVARES, C. A. Gauging the effects of climate variability on Eucalyptus plantations productivity across Brazil: a process-based modelling approach. **Ecological Indicators**, London, v. 114, p. 106325, Oct. 2020.

ELLIS, T. W.; HATTON, T. J. Relating leaf area index of natural eucalypt vegetation to climate variables in southern Australia. **Agricultural Water Management**, Amsterdam, v. 95, n. 6, p. 743-747, 2008.

ESPREY, L. J.; SANDS, P. J.; SMITH, C. W. Understanding 3-PG using a sensitivity analysis. **Forest Ecology and Management**, Amsterdam, v. 193, n. 1/2, p. 235-250, 2004.

FONTES, L.; BONTEMPS, J. D.; BUGMANN, H.; OIJEN, V. van; GRACIA, C.; KRAMER, K.; LINDNER, M.; RÖTZER, T.; SKOVSGAARD, J. P. Models for supporting forest management in a changing environment. **Forest Systems**, Berlin, v. 3, n. 4, p. 8, 2010.

FORRESTER, D. I.; TANG, X. Analysing the spatial and temporal dynamics of species interactions in mixed-species forests and the effects of stand density using the 3-PG model. **Ecological Modelling**, Amsterdam, v. 319, p. 233-254, 2016.

FREITAS, E. C. S. de; PAIVA, H. N. de; NEVES, J. C. L.; MARCATTI, G. E.; LEITE, H. G. Modeling of eucalyptus productivity with artificial neural networks. **Industrial Crops and Products**, London, v. 146, p. 112149, Jan. 2020.

FRITSCH, S.; GUENTHER, F.; GUENTHER, M. F. **Package 'neuralnet'**: training of neural networks. Bonn: German Research Foundation, 2019.

GOH, A. T. C. Back-propagation neural networks for modeling complex systems. **Artificial Intelligence in Engineering**, Ashurst, v. 9, n. 3, p. 143-151, 1995.

GONÇALVES, J. L. de M.; STAPE, J. L.; LACLAU, J. P.; SMETHURST, P.; GAVA, J. L. Silvicultural effects on the productivity and wood quality of eucalypt plantations. **Forest Ecology and Management**, Amsterdam, v. 193, p. 45-61, 2004.

GONZALEZ-BENECKE, C. A.; JOKELA, E. J.; CROPPER, W. P.; BRACHO, R.; LEDUC, D. J. Parameterization of the 3-PG model for *Pinus elliottii* stands using alternative methods to estimate fertility rating, biomass partitioning and canopy closure. **Forest Ecology and Management**, Amsterdam, v. 327, p. 55-75, 2014.

GRAYBILL, F. A. **Theory and application of the linear model**. Belmont: Duxbury, 1976.

HELFENSTEIN, G. O. **Produtividade e estrutura horizontal de povoamentos clonais de eucalipto em diferentes sítios e espaçamentos de plantio**. 2020. 96 p. Dissertação (Mestrado em Solos e Nutrição de Plantas) - Universidade Federal de Viçosa, Viçosa, MG, 2020.

JARDIM, J. M.; JARDIM, C. M.; COLODETTE, J. L. Understanding the pulping and bleaching performances of eucalyptus woods affected by physiological disturbance. **Tappi Journal**, Atlanta, v. 17, n. 11, p. 633-642, 2018.

KEITH, H.; GORSEL, E. van; JACOBSEN, K. L.; CLEUGH, H. A. Agricultural and forest meteorology dynamics of carbon exchange in a Eucalyptus forest in response to interacting disturbance factors. **Agricultural and Forest Meteorology**, Amsterdam, v. 153, p. 67-81, 2012.

KLIPPEL, V. H. **Modelagem ecofisiológica de cultivos de eucalipto em regiões subtropicais do Brasil**. 2015. 89 p. Tese (Doutorado em Meteorologia Agrícola) - Universidade Federal de Viçosa, Viçosa, MG, 2015.

LANDSBERG, J. Modelling forest ecosystems: state of the art, challenges, and future directions. **Canadian Journal of Forest Research**, Ottawa, v. 33, n. 3, p. 385-397, 2003a.

LANDSBERG, J. Physiology in forest models: history and the future. **FBMIS**, Oxford, v. 1, p. 49-63, Jan. 2003b.

LANDSBERG, J. J.; WARING, R. H. A generalised model of forest productivity using simplified concepts of radiation-use efficiency, carbon balance and partitioning. **Forest Ecology and Management**, Amsterdam, v. 95, n. 3, p. 209-228, 1997.

LEITE, H. G.; OLIVEIRA, F. H. T. de. Statistical procedure to test identity between analytical methods. **Communications in Soil Science and Plant Analysis**, New York, v. 3624, p. 1105-1118, 2002.

LEITE, H. G.; SILVA, M. L. M. da; BINOTI, D. H. B.; FARDIN, L.; TAKIZAWA, F. H. Estimation of inside-bark diameter and heartwood diameter for *Tectona grandis* Linn. trees using artificial neural networks. **European Journal of Forest Research**, Georgetown, v. 130, n. 2, p. 263-269, 2011.

LEITE, R. V.; AMARAL, C. H. do; PIRES, R. de P.; SILVA, C. A.; SOARES, C. P. B.; MACEDO, R. P.; SILVA, A. A. L. da; BROADBENT, E. N.; MOHAN, M.; LEITE, H. G. Estimating stem volume in eucalyptus plantations using airborne LiDAR: a comparison of area- and individual tree-based approaches. **Remote Sensing**, Basel, v. 12, n. 9, p. 1513, 2020.

LEMOS, C. C. Z. de. **Aprimoramentos, teste e uso do modelo 3-PG em plantios clonais de Eucalyptus no nordeste do estado de São Paulo**. 2012. 175 p. Tese (Doutorado em Recursos Florestais) - Universidade de São Paulo, Escola Superior de Agricultura "Luiz de Queiroz", Piracicaba, 2012.

LIM, H.; ALVARES, C. A.; RYAN, M. G.; BINKLEY, D. Assessing the cross-site and within-site response of potential production to atmospheric demand for water in Eucalyptus plantations. **Forest Ecology and Management**, Amsterdam, v. 464, p. 118068, Mar. 2020.

LONDERO, E. K.; SCHUMACHER, M. V.; SZYMCZAK, D. A.; ARAÚJO, E. F. Calibração do modelo 3-PG para *Eucalyptus saligna* Smith NA região de Guaíba - RS. **Ciencia Florestal**, Santa Maria, v. 25, n. 2, p. 293-305, 2015.

LÓPEZ, D. M. S.; ARTURI, M. F.; GOYA, J. F.; PÉREZ, C. A.; FRANGI, J. L. Eucalyptus grandis plantations: effects of management on soil carbon, nutrient contents and yields. **Journal of Forestry Research**, London, v. 31, p. 601-611, Nov. 2018.

LU, Y.; COOPS, N. C.; WANG, T.; WANG, G. A process-based approach to estimate Chinese fir (*Cunninghamia lanceolata*) distribution and productivity in Southern China under climate change. **Forests**, Basel, v. 6, n. 2, p. 360-379, 2015.

MÄKELÄ, A.; LANDSBERG, J.; EK, A. R.; BURK, T. E.; TER-MIKAELIAN, M.; AGREN, G. I.; OLIVER, C. D.; PUTTONEN, P. Process-based models for forest ecosystem management: current state of the art and challenges for practical implementation. **Tree Physiology**, Victoria, v. 20, n. 5/6, p. 289-298, 2000.

MEGOWN, R. A.; WEBSTER, M.; JACOBS, S. **Using Landsat TM imagery to estimate LAI in a Eucalyptus plantation**. 1999. Disponível em: http://fred.csiro.au/www/ffp/research/RS_LAI_paper.pdf. Acesso em: 10 mar. 2020.

MIGUEL, E. P.; MOTA, F.; TÉO, S. J.; GERONI, R. Artificial intelligence tools in predicting the volume of trees within a forest stand. **African Journal of Agricultural Research**, Nairobi, v. 11, n. 21, p. 1914-1923, 2016.

MONTANÉ, F.; FORTIN, M. J.; COLOMBO, S.; TER-MIKAELIAN, M.; CHEN, J. Quantifying the response of forest carbon balance to future climate change in Ontario boreal forests. In: COST EP0603, 2011, Kaprun. **Proceedings** [...]. Vienna:

University of Natural Resources and Life Sciences, 2011. p. 99-105.

NIGHTINGALE, J. M.; COOPS, N.; WARING, R. H.; HARGROVE, W. Comparison of MODIS gross primary production estimates for forests across the U.S.A. with those generated by a simple process model, 3-PGS. **Remote Sensing of Environment**, New York, v. 109, n. 4, p. 500-509, 2007.

OLIVEIRA, C. M. M. de; DELGADO, R. C.; ARAÚJO, E. J. G. de; ALMEIDA, A. Q. de; ROSA, T. C.; OLIVEIRA JÚNIOR, J. F. de. Modelo 3-PG na previsão do potencial produtivo de áreas para plantios comerciais de Eucalyptus spp. **Ciência Florestal**, Santa Maria, v. 28, n. 1, p. 249-262, 2018.

ÖRDÖG, V.; ZOLTÁN, M. **Plant physiology**. Debrecen: Debreceni Egyetem, 2011. 115 p.

PÉREZ-CRUZADO, C.; MUÑOZ, F.; BASURCO, F.; RIESCO, G. Combining empirical models and the process-based model 3-PG to predict eucalyptus nitens plantations growth in Spain. **Forest Ecology and Management**, Amsterdam, v. 262, n. 6, p. 1067-1077, 2011.

PIÑEIRO, G.; PERELMAN, S.; GUERSCHMAN, J. P.; PARUELO, J. M. How to evaluate models: observed vs. predicted or predicted vs. observed? **Ecological Modelling**, Amsterdam, v. 216, n. 3/4, p. 316-322, 2008.

PONTES, M. da S. **Parametrização do modelo 3-PG para Teca (Tectona grandis L.f.) e dos sistemas Ferti-UFV e Nutri-UFV para subsidiar o seu manejo nutricional**. 2011. 79 p. Dissertação (Mestrado em Solos e Nutrição de Plantas) - Universidade Federal de Viçosa, Viçosa, MG, 2011.

POTITHEP, S.; ENDO, T.; TAKEUCHI, W. Coupling remote sensing with spatial 3-PG model for gross primary productivity estimation in deciduous broadleaf forest: Hokkaido, Japan. **Seisan Kenkyu**, Tokyo, v. 61, n. 4, p. 755-759, 2009.

R CORE TEAM. **R: a language and environment for statistical computing**. Vienna: R Foundation for Statistical Computing, 2020. Disponível em: <https://www.R-project.org/>. Acesso em: 10 out. 2020.

RASCON, N. J. L. **Modelagem ecofisiológica do desenvolvimento do eucalipto na Amazônia**. 2012. 93 f. Dissertação (Mestrado em Meteorologia Agrícola) - Universidade Federal de Viçosa, Viçosa, MG, 2012.

RIEDMILLER, M.; BRAUN, H. A direct adaptive method for faster backpropagation learning: the RPROP algorithm. *In: IEEE INTERNATIONAL CONFERENCE ON NEURAL NETWORKS*, 1993, San Francisco. **Proceedings** [...]. San Francisco: IEEE, 1993.

RODY, Y. P.; RIBEIRO, A.; OLIVEIRA, A. S. de; LEITE, F. P. Modeling and simulation of relief influence on eucalyptus forests: interaction between solar irradiance and productivity. **Revista Árvore**, Viçosa, MG, v. 40, n. 2, p. 319-327, 2016.

SANDS, P. **Adaptation of 3-PG to novel species**: guidelines for data collection and parameter assignment. Hobart: CSIRO, 2004. (Technical report, 141).

SANDS, P. J. **3PG PJS user manual**. Taroon: [s. n.], 2010. 27 p.

SANDS, P. J.; LANDSBERG, J. J. Parameterisation of 3-PG for plantation grown *Eucalyptus globulus*. **Forest Ecology and Management**, Amsterdam, v. 163, n. 1/3, p. 273-292, 2002.

SILVA, G. G. C. da. **Nutrição, crescimento e sua modelagem em povoamentos de eucalipto em resposta à disponibilidade de água e nutrientes**. 2006. 102 p. Tese (Doutorado em Solos e Nutrição de Plantas) - Departamento de Solos, Universidade Federal de Viçosa, Viçosa, MG, 2006.

SILVA, I. N. da; SPATTI, D. H.; FLAUZINO, R. A. **Redes neurais artificiais para engenharia e ciências aplicadas**: fundamentos teóricos e aspectos práticos. 2. ed. São Paulo: Artliber, 2016. 431 p.

SILVA, W. C. M.; RIBEIRO, A.; NEVES, J. C. L.; BARROS, N. F. de; LEITE, F. P. Water balance model and eucalyptus growth simulation in the rio doce basin, Brazil. **Acta Scientiarum**. Agronomy, Maringá, v. 35, n. 4, p. 403-412, 2013.

SMETTEM, K. R. J.; WARING, R. H.; CALLOW, J. N.; WILSON, M.; MU, Q. Satellite-derived estimates of forest leaf area index in southwest Western Australia are not tightly coupled to interannual variations in rainfall: implications for groundwater decline in a drying climate. **Global Change Biology**, Oxford, v. 19, n. 8, p. 2401-2412, 2013.

STAHRRINGER, N. I. **Parametrização de modelos de produtividade e de balanço nutricional para Pinus e Eucalyptus em Corrientes - Argentina**. 2017. 153 p. Tese (Doutorado em Solos e Nutrição de Plantas) - Departamento de Solos, Universidade Federal de Viçosa, Viçosa, MG, 2017.

STAPE, J. L.; BINKLEY, D.; RYAN, M. G. Eucalyptus production and the supply, use and efficiency of use of water, light and nitrogen across a geographic gradient in Brazil. **Forest Ecology and Management**, Amsterdam, v. 193, n. 1/2, p. 17-31, 2004.

STAPE, J. L.; RYAN, M. G.; BINKLEY, D. Testing the 3-PG process-based model to simulate Eucalyptus growth with an objective approach to the soil fertility rating parameter. **Forest Ecology and Management**, Amsterdam, v. 193, p. 219, 2004.

TAVARES JÚNIOR, I. da S.; ROCHA, J. L. C. da; EBLING, A. A.; CHAVES, A. de S.; ZANUNCIO, J. C.; FARIAS, A. A.; LEITE, H. G. Artificial neural networks and linear regression reduce sample intensity to predict the commercial volume of eucalyptus clones. **Forests**, Basel, v. 10, p. 2-16, 2019.

TICKLE, P. K.; COOPS, N. C.; HAFNER, S. D. Assessing forest productivity at local scales across a native eucalypt forest using a process model, 3PG-SPATIAL. **Forest Ecology and Management**, Amsterdam, v. 152, n. 1/3, p. 275-291, 2001.

TROTSIUK, V.; HARTIG, F.; FORRESTER, D. I. r3PG - an R package for simulating forest growth using the 3-PG process-based model. **Methods in Ecology and Evolution**, London, v. 11, n. 11, p. 1470-1475, Aug. 2020.

VIEIRA, G. C.; MENDONÇA, A. R. de; SILVA, G. F. da; ZANETTI, S. S.; SILVA, M. M. da; SANTOS, A. R. dos. Prognoses of diameter and height of trees of eucalyptus using artificial intelligence. **Science of the Total Environment**, Amsterdam, v. 619/620, p. 1473-1481, 2018.

WANG, S. C. **Interdisciplinary computing in Java programming**. Berlin: Springer Science & Business Media, 2003.

WARING, R. H.; LANDSBERG, J. J. Generalizing plant-water relations to landscapes. **Journal of Plant Ecology**, Oxford, v. 4, n. 1/2, p. 101-113, 2011.

WATERWORTH, R. M.; RICHARDS, G. P.; BRACK, C.; EVANS, D. M. W. A generalised hybrid process-empirical model for predicting plantation forest growth. **Forest Ecology and Management**, Amsterdam, v. 238, n. 1/3, p. 231-243, 2007.

ZHAO, M.; XIANG, W.; PENG, C.; TIAN, D. Simulating age-related changes in carbon storage and allocation in a Chinese fir plantation growing in southern China using the 3-PG model. **Forest Ecology and Management**, Amsterdam, v. 257, n. 6, p. 1520-1531, 2009.

CAPÍTULO III - AS REDES NEURAS ARTIFICIAIS PODEM AUXILIAR NO PROCESSO DE PARAMETRIZAÇÃO DO MODELO 3-PG

RESUMO: A compreensão de como os processos fisiológicos das árvores são afetados pelo ambiente ou práticas silviculturais é importante para o manejo florestal, e isto requer o emprego de modelos processuais. Esses modelos têm sido cada vez mais utilizados nos últimos anos, em parte, devido às preocupações sobre os impactos das mudanças climáticas na produtividade florestal. A possibilidade de avaliar o crescimento de uma floresta sob diferentes cenários é uma das vantagens que a aplicação de um modelo processual oferece. O modelo 3-PG faz parte de um grande número de modelos processuais já desenvolvidos, mas o seu uso foi mais difundido por se tratar de um modelo gratuito, mais simples em relação aos demais, pelo menor número de parâmetros, e aplicação em linguagem acessível. É o modelo processual de maior interesse para o manejo florestal, visto que, permite o uso de equações alométricas para o cálculo de variáveis de interesse nesta área como o diâmetro médio à 1,30 m de altura (D), altura total e volume do povoamento. A etapa de parametrização do modelo 3-PG é fundamental para garantir seu bom desempenho, porém, em alguns casos, quando não se tem disponíveis dados observados, é utilizada a literatura ou é realizada a calibração. Em geral, existe uma mistura dessas alternativas em uma mesma parametrização, mas alguns dos parâmetros geram maior sensibilidade em algumas saídas do modelo. No presente trabalho, analisamos a eficiência das redes neurais artificiais para a predição de alguns dos parâmetros apontados na literatura como de maior importância para o 3-PG, utilizando variáveis climáticas e de processos. Para isso, foi gerado um banco de dados simulados, com o modelo 3-PG, para diferentes regiões do Brasil, utilizando 16 parametrizações. Esse banco de dados foi associado ao valor dos parâmetros da relação com o D (a_s e n_s), fração mínima e máxima de biomassa alocada para a raiz (η_{Rn} e η_{Rx}) e idade de fechamento do dossel (t_c). As redes foram treinadas utilizando o banco de dados com a repetição dos parâmetros ao longo do tempo e com a condição média de cada sítio. No segundo caso o treinamento foi realizado com 100% dos dados e a validação foi feita com banco de dados simulado. A eficiência das redes neurais foi comprovada para a predição dos parâmetros a_s , n_s e η_{Rx} . Para os demais parâmetros, o estudo mostrou a necessidade de mais

investigação científica, incluindo informações e variáveis de entrada como a fertilidade do solo. A possibilidade de parametrização do 3-PG com redes neurais, demonstrada no presente estudo, ou de qualquer técnica de aprendizado de máquina, poderá contribuir para um uso mais amplo desse modelo processual. Além disso, as redes neurais artificiais têm grande potencial para auxiliar no processo de parametrização ou calibração do modelo 3-PG, tornando esse processo mais seguro e eficaz, por integrar condições do ambiente e também permitir a associação entre parâmetros ou outros tipos de variáveis. Recomenda-se a aplicação dessas redes para as condições aqui testadas. Mais pesquisas e testes com outras técnicas de aprendizado de máquina são recomendados.

Palavras-chave: Modelo processual. *Eucalyptus*. Manejo Florestal. Aprendizado de máquina.

ARTIFICIAL NEURAL NETWORKS CAN ASSIST THE 3-PG MODEL PARAMETERIZATION

ABSTRACT: Understanding how the trees physiological processes are affected by the environment or silvicultural practices is important for forest management, and this requires the use of process-based models. These models have been increasingly used in recent years, in part, because of concerns about the impacts of climate change on forest productivity. The possibility of evaluating the growth of a forest under different scenarios is one of the advantages that the application of a process-based model offers. The 3-PG model is part of a large number of process-based models already developed, but its use was more widespread because it is a free and simpler model compared to others, due to the smaller number of parameters and application in a more accessible language. It is the process-based model of greatest interest for forest management, as it allows the use of allometric equations to calculate variables of interest in this area, such as the average diameter at 1.30 m height (D), total height and stand volume. The parameterization step of the 3-PG model is essential to guarantee the good performance of the model, however, in some cases observed data is not available or the literature or calibration process is used. In general, there is a mixture of these alternatives in the same parameterization, but some of the parameters generate greater sensitivity in some outputs or change according to the site characteristics. In the present work, we analyzed the artificial neural networks efficiency for the prediction of some of the parameters pointed out in the literature as being of greatest importance for 3-PG, using climate and process predictor variables (inputs). For this, a simulated database was generated with the 3-PG model for different regions of Brazil, using 16 parameterizations. The parameters values of the parameters of D function (a_s and n_s), minimum and maximum fraction of biomass allocated to the root (η_{Rn} and η_{Rx}) and age at full canopy cover (t_c) was associated with this database. The ANNs were trained using the database with parameters repetition over time and with each site average condition. In the second case, training was performed with 100% of the data and validation was performed with simulated database. The efficiency of neural networks was proven to predict the parameters a_s , n_s and η_{Rx} . For the other parameters, the study showed the need for more scientific investigation including information and input variables such as soil fertility. The possibility of parameterizing 3-PG with neural networks, demonstrated in this study, or any machine learning

technique, may contribute to a broader use of this process-based model. In addition, artificial neural networks have great potential to assist in the parameterization or calibration process of the 3-PG model, making this process safer and more efficient, by integrating environmental conditions and also allowing the association between parameters. The application of these networks is recommended for the conditions tested here. Further research and testing with other machine learning techniques is recommended.

Keywords: Process-based model. *Eucalyptus*. Forest management. Machine learning.

1 INTRODUÇÃO

A modelagem é uma técnica que há anos possibilita a realização mais adequada do manejo de florestas. A partir de observações de campo, toda a informação adquirida para a tomada de decisões no manejo, é baseada no uso de ferramentas matemáticas capazes de abstrair o funcionamento de um processo ou fenômeno natural (BURKHART; TOMÉ, 2012). É o crescimento da floresta o fenômeno que orienta as atividades de manejo dentro de uma empresa. Dessa forma, a modelagem do crescimento e da produção florestal deve ser realizada com cautela, sempre adotando técnicas que melhor atendam ao objetivo final e garantam a sustentabilidade produtiva, econômica, social e ambiental (SKOVSGAARD; VANCLAY, 2008).

Definir o melhor momento para a colheita de um plantio florestal é uma das principais etapas, porém, chegar em resultados próximos ao ideal, depende da compreensão de como a floresta irá refletir os efeitos das técnicas de manejo, silviculturais, genótipo e ambiente (CAMPOS, 1970; SKOVSGAARD; VANCLAY, 2008). A interação entre esses fatores é o que gera a produtividade de uma floresta, e manter um nível elevado de produtividade esbarra em incertezas, principalmente sobre o fator ambiente. Nesse caso, uma discussão que se intensifica no momento é sobre quais seriam os impactos, e em qual intensidade as mudanças climáticas podem afetar a produtividade florestal.

Como os efeitos do clima não podem ser controlados, cabe ao engenheiro florestal buscar formas de adaptação. Algumas estratégias seriam o planejamento a longo prazo envolvendo cenários sobre a mudança do clima, conhecer o potencial produtivo de diferentes áreas, encontrar genótipo adequado para cada região e realizar o manejo florestal com base em modelos de crescimento e de produção que permitam associar variáveis de causa.

Modelos desse tipo são chamados modelos processuais, e aqueles com potencial de uso no manejo florestal possuem caráter híbrido, devido a sua capacidade de quantificar o carbono fixado pelo dossel de uma floresta, realizar a alocação da biomassa para raízes, fuste e folhas, e calcular os componentes estruturais diâmetro médio, altura total e volume do povoamento (FONTES *et al.*, 2010).

O modelo processual mais usado é o 3-PG - *Physiological Principles Predicting Growth* (LANDSBERG; WARING, 1997). Para a sua aplicação na versão original, é necessário determinar 63 parâmetros, divididos de acordo com os processos simulados por ele: absorção e conversão da radiação solar, produção e alocação de biomassa, balanço hídrico, mortalidade, cálculos dendrométricos e *turnover* de folhas e raízes (SANDS, 2004). O valor a ser utilizado para cada parâmetro depende de alguns fatores, como a espécie ou clone, clima e solo da região, portanto dependem de informações observadas.

Alguns parâmetros possuem caráter universal e, geralmente, são utilizados valores padrão, enquanto outros, como aqueles relacionados a partição de biomassa e *turnover*, estrutura e processos do dossel e propriedades da madeira e do povoamento apresentam maior variação por serem específicos da espécie ou clone.

Como já existe uma certa disponibilidade de parametrizações na literatura, os pesquisadores podem utilizar esses valores, caso seja compatível com as suas condições. Existe ainda a possibilidade de calibração do modelo a partir de dados observados, de preferência dados de biomassas de raiz, fuste e folha. Quando estas informações não estão disponíveis, dados de inventário florestal, como *D*, altura total ou volume podem substituir a biomassa de fuste e dados de índice de área foliar podem substituir a biomassa foliar (SANDS, 2004). Na calibração, alguns parâmetros são modificados manualmente e o modelo é rodado algumas vezes até encontrar uma proximidade entre valores observados e valores simulados pelo 3-PG (LANDSBERG; WARING; COOPS, 2003). Esta técnica exige um conhecimento detalhado sobre os parâmetros e funcionamento do modelo para que não haja inconsistências biológicas (SANDS, 2004).

Como alguns parâmetros do modelo tendem a mudar conforme a espécie e com as características do ambiente, e como o 3-PG é um modelo sensível aos efeitos climáticos, possivelmente a adoção de técnicas de aprendizado de máquina poderia contribuir para que a determinação dos parâmetros seja realizada de forma menos empírica. Isso pode ser realizado ao integrar variáveis climáticas, da região para onde se deseja realizar a parametrização ou calibração, e outras variáveis relacionadas aos parâmetros, por meio de uma Rede Neural Artificial (RNA). Dessa forma, a determinação do parâmetro pode se tornar mais fácil e segura em relação ao processo de calibração.

Os modelos de RNA possuem uma estrutura inspirada no sistema nervoso, na forma como ocorre a comunicação entre os neurônios, representados na RNA por unidades de processamento simples, distribuídas em camadas paralelas e conectadas por pesos, os responsáveis por armazenar a informação aprendida no processo de treinamento (HAYKIN, 2009). A capacidade de generalização e de representar relações não lineares complexas, que permitem a inclusão de variáveis com naturezas diferentes, como variáveis climáticas e ecofisiológicas, são os principais benefícios desse tipo de modelo (HAYKIN, 2009; LEK *et al.*, 1996).

Os resultados e conclusões apresentadas por pesquisas na área florestal com o uso das redes, para diferentes finalidades, espécies e locais no Brasil e no mundo, reforçam a ideia de que esta seja uma alternativa viável para este estudo. Alguns exemplos seriam estudos para a predição do índice de área foliar em floresta de coníferas (ERCANLI *et al.*, 2018); fluxo de carbono em plantios florestais (WEN *et al.*, 2014); modelagem da biomassa acima do solo (DOMINGUES *et al.*, 2020; NANDY *et al.*, 2017; VAHEDI, 2016) e predição de variáveis dendrométricas, como altura total (BAYAT *et al.*, 2020; BINOTI *et al.*, 2017) e volume (BINOTI; BINOTI; LEITE, 2014; DANTAS *et al.*, 2020; NISKA *et al.*, 2010; SILVA *et al.*, 2021).

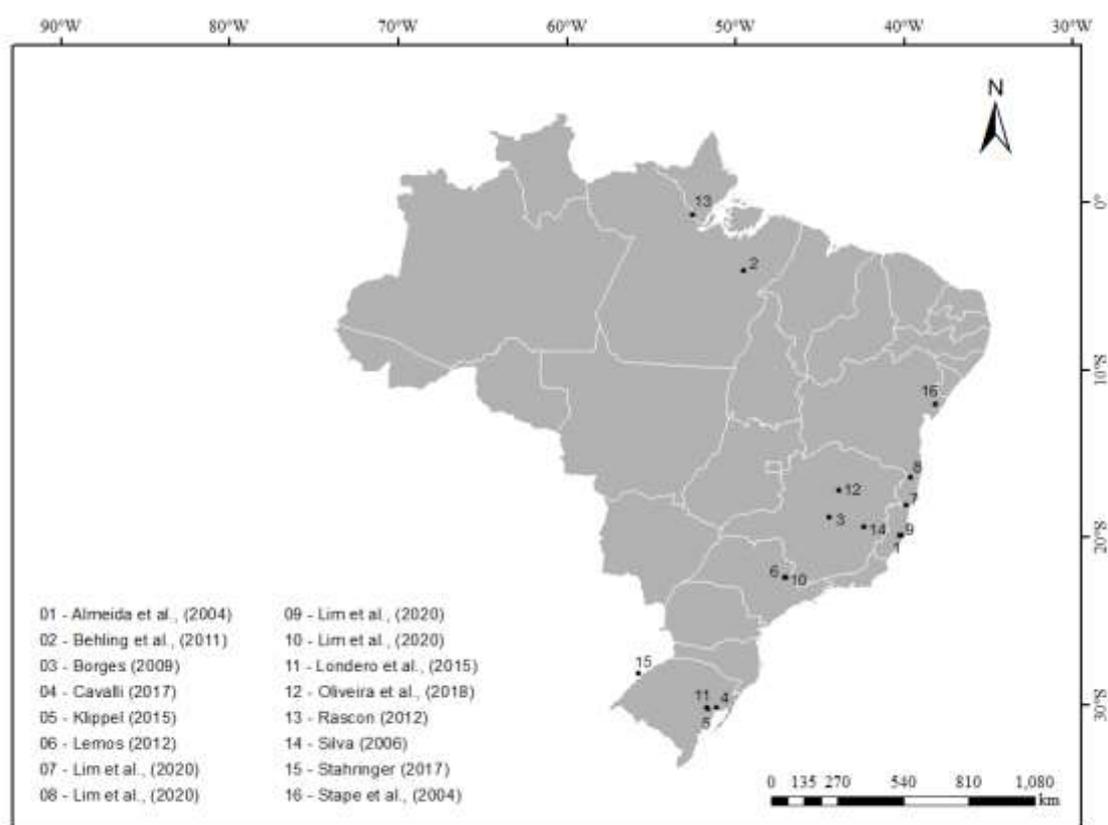
Nesse contexto, o objetivo desse trabalho foi avaliar o uso da RNA para prever parâmetros do modelo 3-PG, que tendem a gerar maior sensibilidade em algumas das saídas do modelo e que apresentam maior variação.

2 MATERIAL E MÉTODOS

2.1 Obtenção dos dados

Foram selecionadas na literatura 16 parametrizações do modelo 3-PGpjs2.7 para eucalipto, em diferentes regiões climáticas do Brasil e em uma localização na Argentina (Figura 1). Com estas parametrizações, foi gerado um banco de dados, usado para treinar as Redes Neurais Artificiais (RNA).

Figura 1 - Localização das parametrizações selecionadas para eucalipto. O ponto externo refere-se à parametrização realizada na Argentina.



Fonte: Elaborada pela autora.

Os dados climáticos foram provenientes da base da Organização Meteorológica Mundial para a América do Sul, com resolução de 0,5° de latitude e de longitude, o modelo foi processado a partir de normais climatológicas de temperaturas mínima e máxima (°C), precipitação pluviométrica (mm), radiação solar ($\text{MJ m}^{-2} \text{ dia}^{-1}$) e dias com geada.

As 16 parametrizações foram rodadas considerando características semelhantes de solo (textura média) e dados para inicialização do modelo (Tabela 1). O processamento foi realizado no *software* R (R CORE TEAM, 2020) pelo pacote r3PG (TROTSIUK; HARTIG; FORRESTER, 2020). Alteramos o valor de temperatura ótima das parametrizações para 20 °C, com base em resultados obtidos por Binkley *et al.* (2020) que verificaram maiores produtividades de eucalipto em temperaturas médias entre 19 °C e 20 °C.

Tabela 1 – Configurações de sítio para a inicialização dos processamentos do 3-PG.

Características para inicialização	Valor
Classe de solo	SL
Quantidade mínima de água no solo (mm)	0
Quantidade máxima de água no solo (mm)	150
Quantidade inicial de água no solo (mm)	150
Taxa de fertilidade do solo (FR)	0,8
Valor de f_N quando FR = 0	0,5
Número inicial de fustes	1111
Biomassas iniciais de fuste, folha e raiz (Mg ha ⁻¹)	1/1/1
CO ₂ atmosférico (ppm)	350
Idade final (anos)	7

SL = *Sandy Loam* (Areno-siltoso).

Fonte: Elaborada pela autora.

O banco de dados final foi composto pelas saídas do modelo 3-PG mais o valor de cada parâmetro analisado, associado a parametrização correspondente. Dessa forma, dentro das variações de clima e das demais saídas do modelo ao longo do tempo, o valor do parâmetro permanecia constante, repetindo sempre o mesmo valor.

Para verificar se esse comportamento poderia ser prejudicial ao processo de aprendizado da rede, foi testado o uso do banco de dados completo (com repetições) e um banco de dados reduzido em 16 observações, constituído pelas médias dos valores de clima e das demais variáveis do banco de dados. Isto foi feito para investigar se o processo de aprendizado da rede iria ser mais eficiente em algum desses casos.

2.2 Configuração e treinamento das Redes Neurais Artificiais

Os parâmetros a_s e n_s da relação $D = f(w_s)$ (3), frações mínima (η_{Rn}) e máxima (η_{Rx}) de biomassa alocada para a raiz e idade de fechamento do dossel (t_c), alguns dos parâmetros apontados na literatura por causar alta sensibilidade em saídas do modelo (ALMEIDA; LANDSBERG; SANDS, 2004; ESPREY; SANDS; SMITH, 2004; PÉREZ-CRUZADO *et al.*, 2011; SONG *et al.*, 2012), foram selecionados para serem preditos por meio das Redes Neurais Artificiais (RNA).

$$D = \left(\frac{w_s}{a_s} \right)^{1/n_s} \quad (3)$$

em que: D = diâmetro à 1,30 m de altura (cm); a_s e n_s = parâmetros da relação alométrica; w_s = biomassa média de fuste (kg árvore^{-1}).

Apesar da influência genética, existe correlação significativa entre esses parâmetros e algumas variáveis climáticas (Figura 2), levantando a hipótese de que o uso de variáveis climáticas, junto a outras variáveis relacionadas, pode colaborar no processo de predição dos parâmetros analisados.

Figura 2 - Correlação entre as variáveis climáticas e os parâmetros das 16 parametrizações selecionadas na literatura (a); p-valor de cada correlação ($\alpha = 0,05$) (b); tmp_max = temperatura máxima ($^{\circ}\text{C}$); tmp_min = temperatura mínima ($^{\circ}\text{C}$); tmp_ave = temperatura média ($^{\circ}\text{C}$), prcp = precipitação pluviométrica (mm m-ês^{-1}), srad = radiação solar ($\text{MJ m}^{-2} \text{dia}^{-1}$) e frost_days = dias com geada. Os parâmetros analisados estão em destaque e as descrições na Tabela 2.

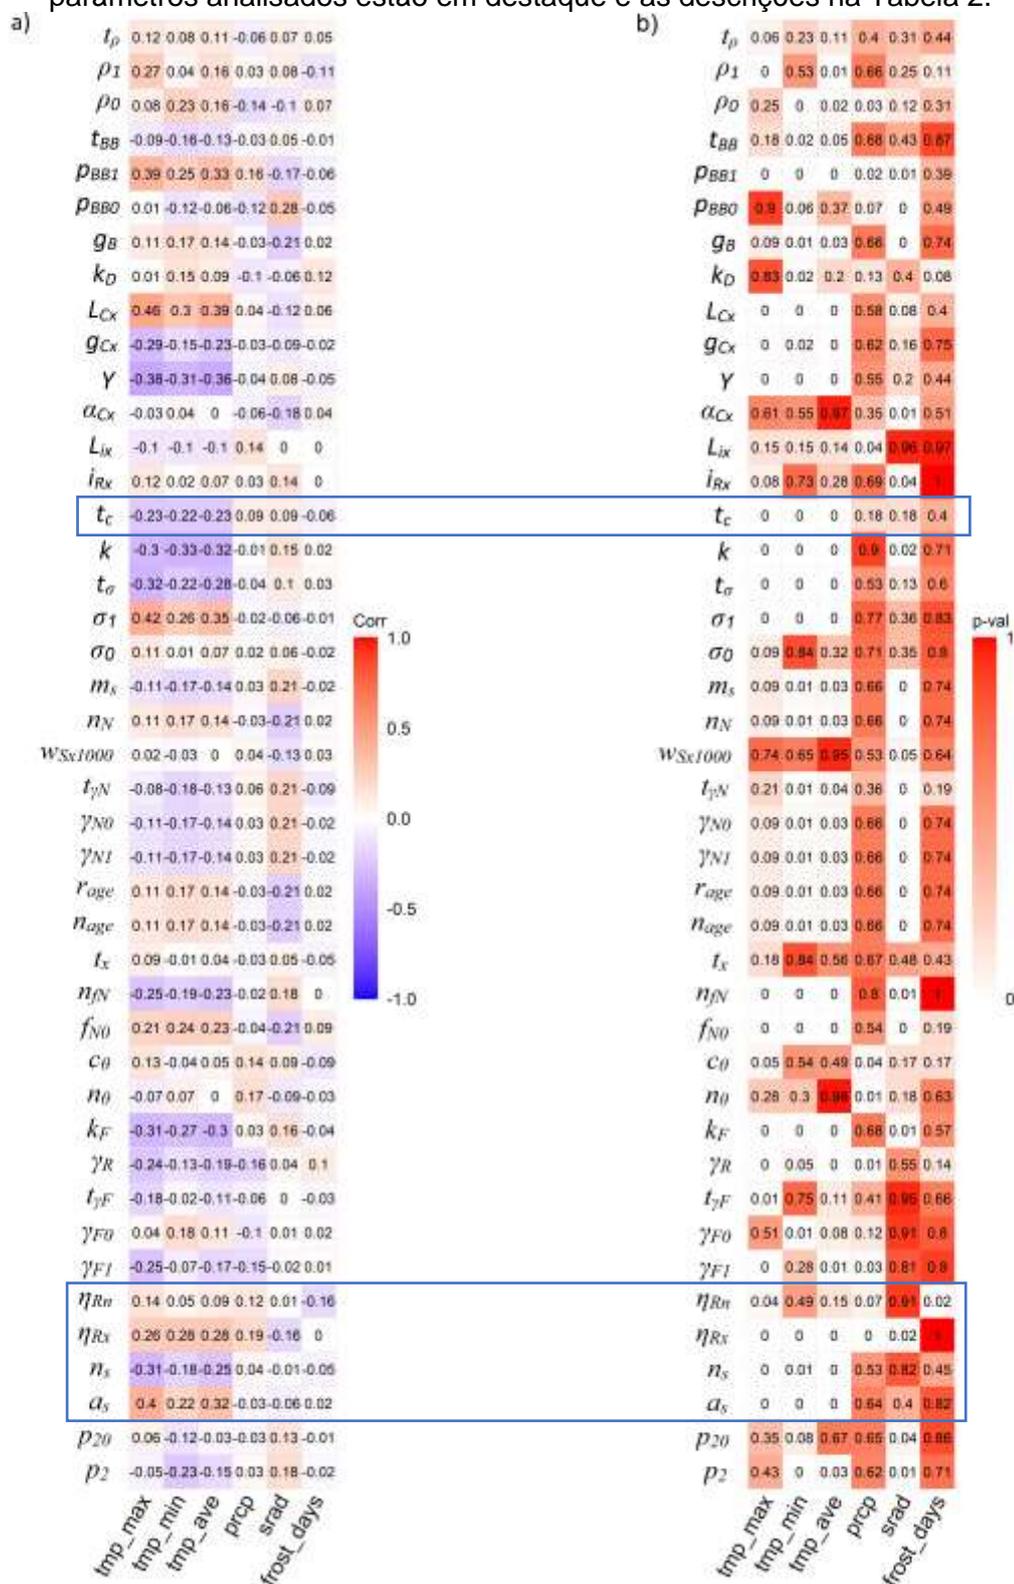


Tabela 2 - Categorias, descrições e símbolos dos parâmetros do 3-PG presentes na Figura 2.

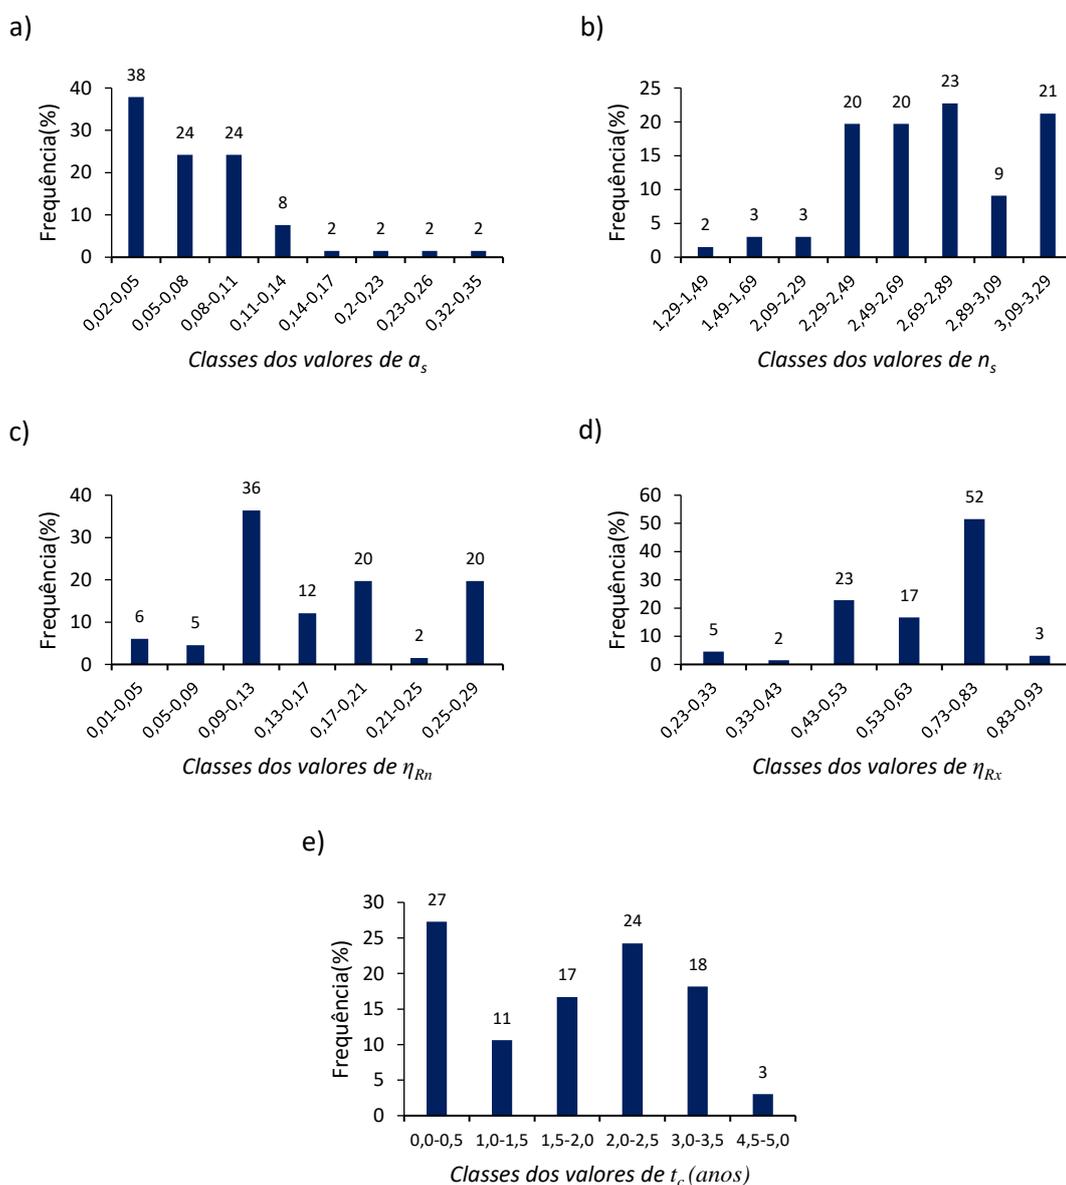
Categoria	Descrição	Símbolo*
Estrutura e processos do dossel	Condutância máxima do dossel (m s^{-1})	g_{Cx}
	A_f para a máxima condutância do dossel ($\text{m}^2 \text{m}^{-2}$)	L_{Cx}
	Condutância da camada limítrofe do dossel (m s^{-1})	g_B
	Interceptação máxima de chuva pelo dossel	i_{Rx}
	A_f para a interceptação máxima de chuva ($\text{m}^2 \text{m}^{-2}$)	L_{ix}
	Coefficiente de extinção para absorção de RFA pelo dossel	k
	Idade na cobertura total dossel (anos)	t_c
	Razão PPL/PPB	Y
	Área foliar específica na idade 0 ($\text{m}^2 \text{kg}^{-1}$)	σ_0
	Área foliar específica para povoamento maduro ($\text{m}^2 \text{kg}^{-1}$)	σ_1
Idade na qual $\sigma = (\sigma_0 + \sigma_1)/2$ (anos)	t_σ	
Eficiência quântica máxima do dossel (mol mol^{-1})	α_{Cx}	
Modificadores do crescimento	Número de dias de produção perdidos por dia de geada	k_F
	Resposta estomática ao DPV (mbar^{-1})	k_D
	Déficit da taxa de umidade em que $f_\theta = 0,5$	c_θ
	Potência do déficit de razão de umidade em f_θ	n_θ
	Idade máxima do povoamento (anos)	t_x
	Potência da idade relativa em f_{age}	n_{age}
	Idade relativa em que $f_{age} = 0,5$	r_{age}
	Valor de f_N quando $FR = 0$	f_{N0}
	Potência de $(1 - FR)$ em f_N	n_{fN}
	Máxima biomassa de fuste por árvore para um $N = 1000$ árvores ha^{-1}	W_{Sx1000}
Potência na lei de auto-desbaste	n_N	
Mortalidade e auto-desbaste	Fração de biomassa de fuste perdida por árvore morta	m_S
	Taxa de mortalidade de mudas em $t = 0$	γ_{N0}
	Taxa de mortalidade para povoamento maduro	γ_{N1}
	Idade na qual $\gamma_N = (\gamma_{N0} + \gamma_{N1})/2$ (anos)	$t_{\gamma N}$
	Taxa de serapilheira em $t = 0$ (mês^{-1})	γ_{F0}
	Taxa de serapilheira para povoamento maduro (mês^{-1})	γ_{F1}
Idade na qual $\gamma_F = (\gamma_{F0} + \gamma_{F1})/2$ (meses)	$t_{\gamma F}$	
Partição de biomassa e turnover	Constante na relação entre a biomassa média de fuste e o D	a_s
	Potência na relação entre a biomassa média de fuste e o D	n_s
	Razão de partição folha/fuste para um $D = 2$ cm	ρ_2
	Razão de partição folha/fuste para um $D = 20$ cm	ρ_{20}
	Fração máxima da PPL alocada para raízes	η_{Rx}
	Fração mínima da PPL alocada para raízes	η_{Rn}
Taxa mensal de <i>turnover</i> de raiz (mês^{-1})	γ_R	
Propriedades da madeira e do povoamento	Fração galho e casca para árvores jovens	p_{BB0}
	Fração galho e casca para árvores maduras	p_{BB1}
	Idade na qual $p_{BB} = (p_{BB0} + p_{BB1})/2$ (anos)	t_{BB}
	Densidade básica da madeira para árvores jovens (t m^{-3})	ρ_0
	Densidade básica da madeira para árvores maduras (t m^{-3})	ρ_1
Idade na qual $\rho = (\rho_0 + \rho_1)/2$ (anos)	t_ρ	

* Todos os símbolos do modelo 3-PG foram padronizados, em toda a tese, conforme Sands (2010).

Fonte: Elaborada pela autora, conforme Sands (2010).

Ao verificar um maior número de parametrizações para eucalipto, de 66 pesquisas realizadas em diferentes países, foram observados os valores mais utilizados desses parâmetros (Figura 3). Para o parâmetro a_s , valores entre 0,02 e 0,11 foram os mais usados (a), valores acima de 2,29 para o parâmetro n_s (b), o η_{Rn} entre 0,09 e 0,13 (d), η_{Rx} entre 0,73 e 0,83 (e) e para o parâmetro t_c valores entre 0 e 0,5 e entre 2,0 e 2,5 anos (f). As 16 parametrizações selecionadas contemplam a maior parte desses intervalos.

Figura 3 - Frequência observada de valores dos parâmetros a_s , n_s , η_{Rn} , η_{Rx} e t_c usados para eucalipto em diferentes regiões do mundo de acordo com levantamento em 66 pesquisas entre artigos, dissertações e teses.



Fonte: Elaborada pela autora.

Diversas combinações entre as variáveis de entrada com diferentes números de neurônios na camada intermediária da rede foram testadas. Os treinos foram realizados no *software* R (R CORE TEAM, 2020) pelo pacote *neuralnet* (FRITSCH; GUENTHER; GUENTHER, 2019) utilizando redes do tipo *Multilayer perceptron* (MLP), com arquitetura *feedforward*, o algoritmo *Resilient Backpropagation* (RIEDMILLER; BRAUN, 1993) e a função de ativação logística (4). A base de dados foi normalizada para valores entre 0 e 1, pelo método de mínimos e máximos (5), e separada em 70% para treino e 30% para validação. O banco de dados reduzido em 16 observações foi treinado com 100% dos dados e a validação das redes foi realizada a partir de um banco de dados simulado.

$$g(u) = 1 / (1 + e^{-bu}) \quad (4)$$

$$Y_{norm} = \frac{Y - \min(Y)}{\max(Y) - \min(Y)}(1 - 0) + 0 \quad (5)$$

em que: $g(u)$ = sinal de saída do neurônio após a aplicação da função de ativação logística; b = constante real associada ao nível de inclinação da função logística frente ao seu ponto de inflexão; u = potencial de ativação resultante da combinação linear entre o limiar de ativação, os pesos sinápticos e as variáveis de entrada; Y = variável na unidade original; Y_{norm} = valor normalizado; $\min(Y)$ = valor mínimo da variável em unidade original; $\max(Y)$ = valor máximo da variável em unidade original.

As redes foram analisadas pelas estatísticas raiz quadrada do erro quadrático médio absoluto e percentual (6 e 7), correlação de Pearson entre valores observados e preditos pela RNA (8) com os gráficos de dispersão e frequência dos erros relativos percentuais entre valores preditos pela RNA e observados (9) e da correlação. Foi também aplicado o teste F, conforme Graybill (1976) (10) para avaliar a validação e treino das redes, sob a hipótese $H_0: [b_0 \quad b_1] = [0 \quad 1]$, com $Y = \beta_0 + \beta_1 Y_{RNA} + \varepsilon$ (PIÑEIRO *et al.*, 2008), sendo Y a variável de interesse. Na Figura 4 está apresentado um resumo de todo o processamento.

$$RQEM = n^{-1} \sum_{i=1}^n (Y_i - Y_{RNA_i})^2 \quad (6)$$

$$RQEM(\%) = 100\bar{Y}^{-1}RQEM \quad (7)$$

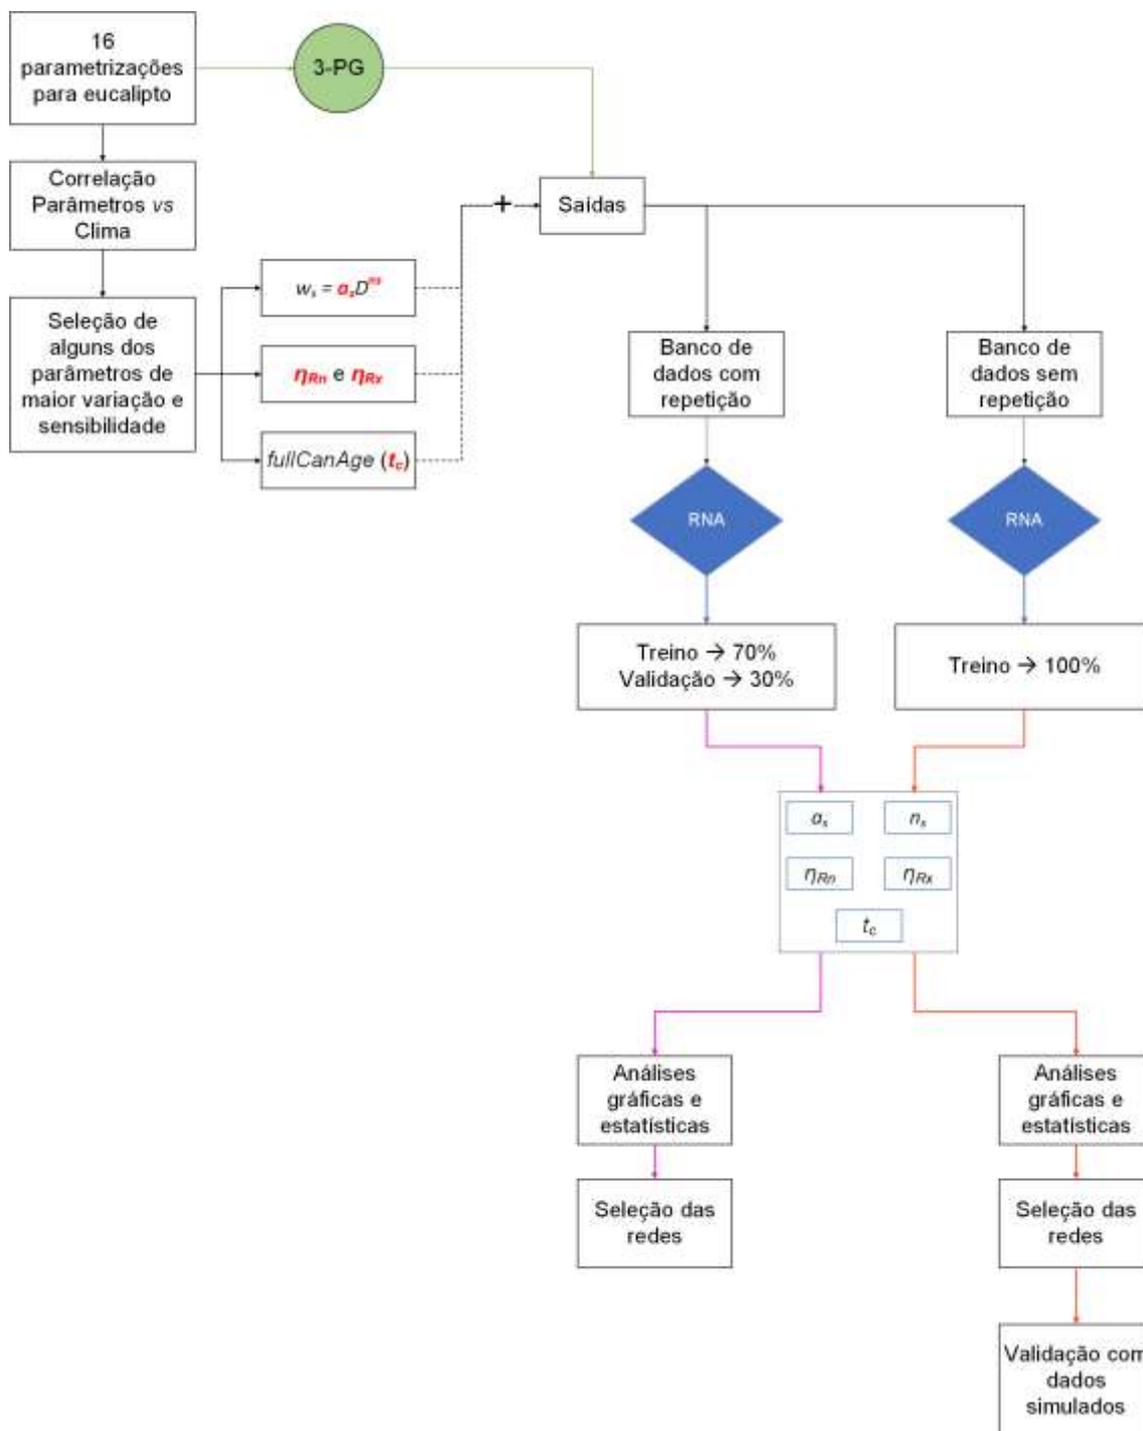
$$r = \frac{\sum_{i=1}^n (Y_i - \bar{Y})(Y_{RNA_i} - \bar{Y}_{RNA})}{\sqrt{\sum_{i=1}^n (Y_i - \bar{Y})^2 \sum_{i=1}^n (Y_{RNA_i} - \bar{Y}_{RNA})^2}} \quad (8)$$

$$ER\% = 100n^{-1} \sum_{i=1}^n (Y_{RNA_i} - Y_i) Y_i^{-1} \quad (9)$$

$$F(H_0) = \frac{\left[(\beta_0 - 0)n + (\beta_1 - 1) \sum_{i=1}^n Y_{RNA_i} \right] (\beta_0 - 0) + \left[(\beta_0 - 0) \sum_{i=1}^n Y_{RNA_i} + (\beta_1 - 1) \sum_{i=1}^n Y_{RNA_i}^2 \right] (\beta_1 - 1)}{2RMS} \sim F_{\alpha}(2, n-1 \text{ g.l.}) \quad (10)$$

em que: Y_i = i-ésimo valor do parâmetro; Y_{RNA_i} = i-ésimo valor predito pela RNA; n = número de observações; \bar{Y} = média dos valores dos parâmetros; \bar{Y}_{RNA} = média dos valores preditos pela RNA; β_0 e β_1 = parâmetros da regressão linear simples; RMS = quadrado médio da regressão; α = nível de significância do teste (0,05); *g.l.* = graus de liberdade.

Figura 4 - Fluxograma com a seqüência dos processamentos realizados nesta pesquisa.



Fonte: Elaborada pela autora.

3 RESULTADOS

3.1 Treinamento com o banco de dados completo

Ao realizar o treino das redes com todo o conjunto de dados, mantendo o parâmetro repetido ao longo do tempo, foram selecionadas as seguintes redes:

$$a_s = f[g(n_s, solar_rad, T_a)]$$

$$n_s = f[g(prcp, T_a, solar_rad, A_f)]$$

$$\eta_{Rn} = f[g(amp_temp, solar_rad, prcp)]$$

$$\eta_{Rx} = f[g(\eta_{Rn}, p_2, prcp, T_a, f_D, A_f)]$$

$$t_c = f[g(p_{20}, T_a, solar_rad)]$$

em que: $prcp$ = precipitação pluviométrica mensal (mm); T_a = temperatura média (°C); $solar_rad$ = radiação solar ($MJ\ m^{-2}\ dia^{-1}$); A_f = índice de área foliar ($m^2\ m^{-2}$); a_s e n_s = parâmetros da relação funcional para estimar o D médio; η_{Rn} = fração mínima de biomassa alocada para a raiz; η_{Rx} = fração máxima de biomassa alocada para a raiz; amp_temp = amplitude entre temperaturas máxima e mínima (°C); p_2 = fração de biomassa entre folha e fuste para um $D = 2$ cm; f_D = modificador do crescimento dependente do déficit de pressão de vapor; p_{20} = fração de biomassa entre folha e fuste para um $D = 20$ cm.

As redes dos parâmetros da relação com o D (a_s e n_s) e a fração máxima de biomassa alocada para a raiz (η_{Rx}) apresentaram RQEM abaixo de 10% no treino e na validação. As correlações entre valores observados e preditos foram acima de 0,5 em todas as redes, com as maiores correlações nos parâmetros a_s , η_{Rx} e t_c com 0,99; 0,98 e 0,91 na validação, respectivamente (Tabela 3).

Todas as redes apresentaram p-valor do teste F_{H0} não significativo no treino e na validação, exceto o parâmetro η_{Rx} no treino. Nas redes para os parâmetros fração mínima de biomassa alocada para a raiz (η_{Rn}) e idade de fechamento do

dossel (t_c) os valores de RQEM foram mais elevados, porém apresentaram F_{H0} não significativo no treino e na validação (Tabela 3).

Tabela 3 – Estatísticas dos conjuntos de validação e treino das redes selecionadas para prever os parâmetros do modelo 3-PG.

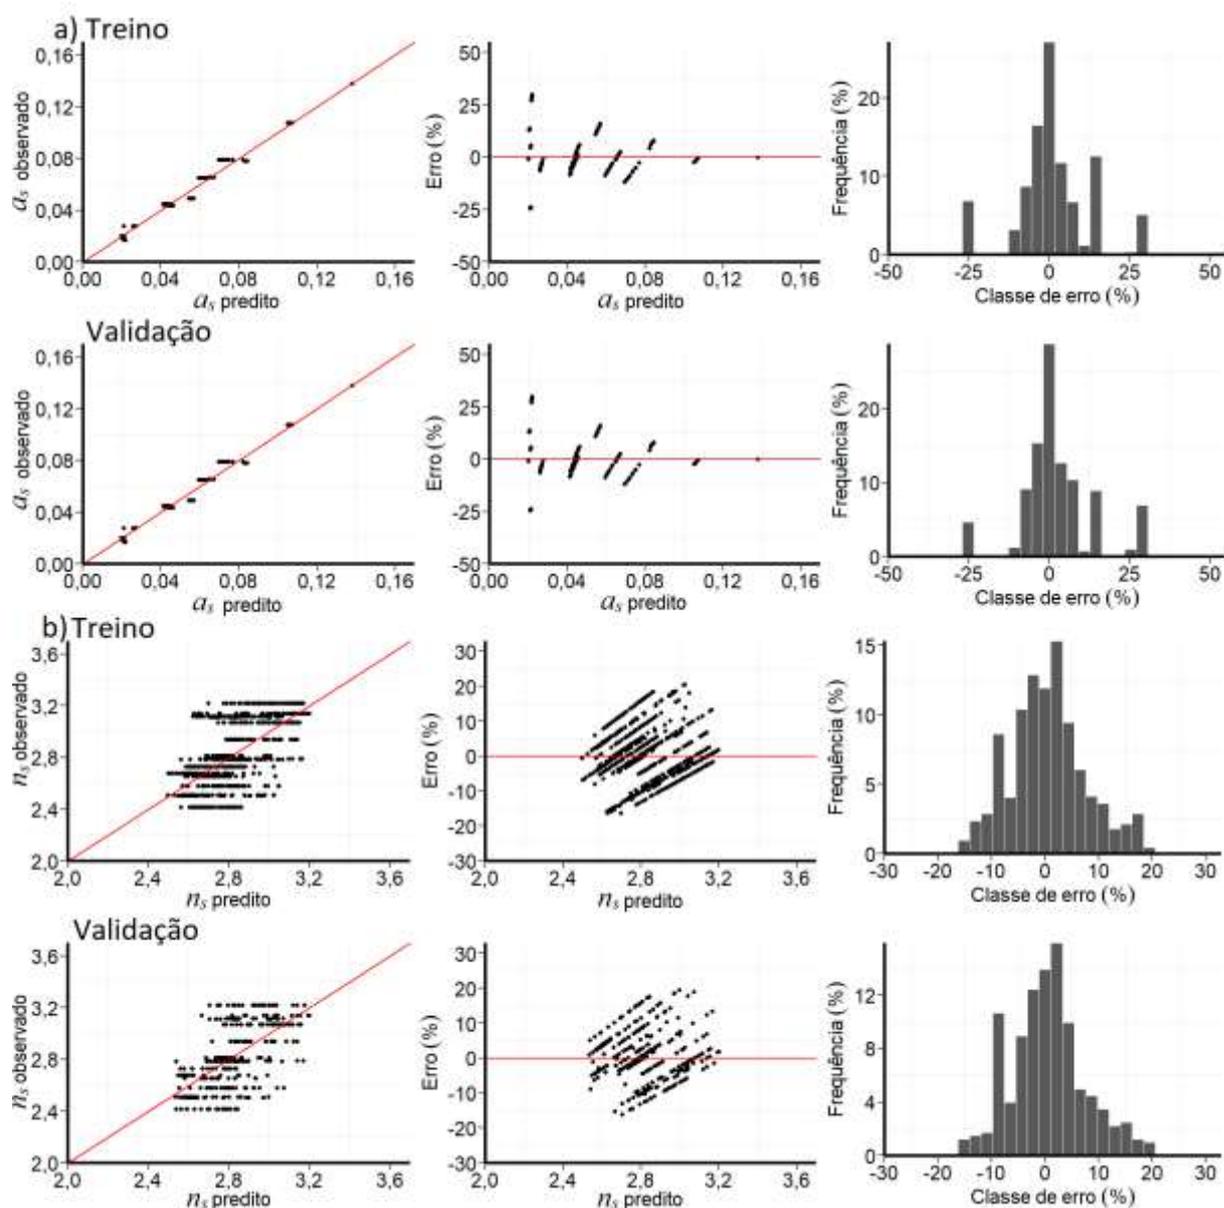
Parâmetro	E-I-S	Validação				Treino			
		$r_{\hat{Y}Y}$	RQEM	RQEM (%)	p-valor	$r_{\hat{Y}Y}$	RQEM	RQEM (%)	p-valor
a_s	3-4-1	0,9942	0,004	6,9	0,063	0,9936	0,004	7,2	0,9521
n_s	4-4-1	0,6038	0,194	6,9	0,874	0,6121	0,198	7,0	0,9074
η_{Rn}	3-4-1	0,5913	0,060	51,7	0,409	0,5753	0,060	50,5	0,9815
η_{Rx}	6-5-1	0,9848	0,026	4,8	0,057	0,9907	0,022	4,0	0,0000
t_c	3-4-1	0,9090	0,478	23,9	0,058	0,9014	0,459	23,4	0,1338

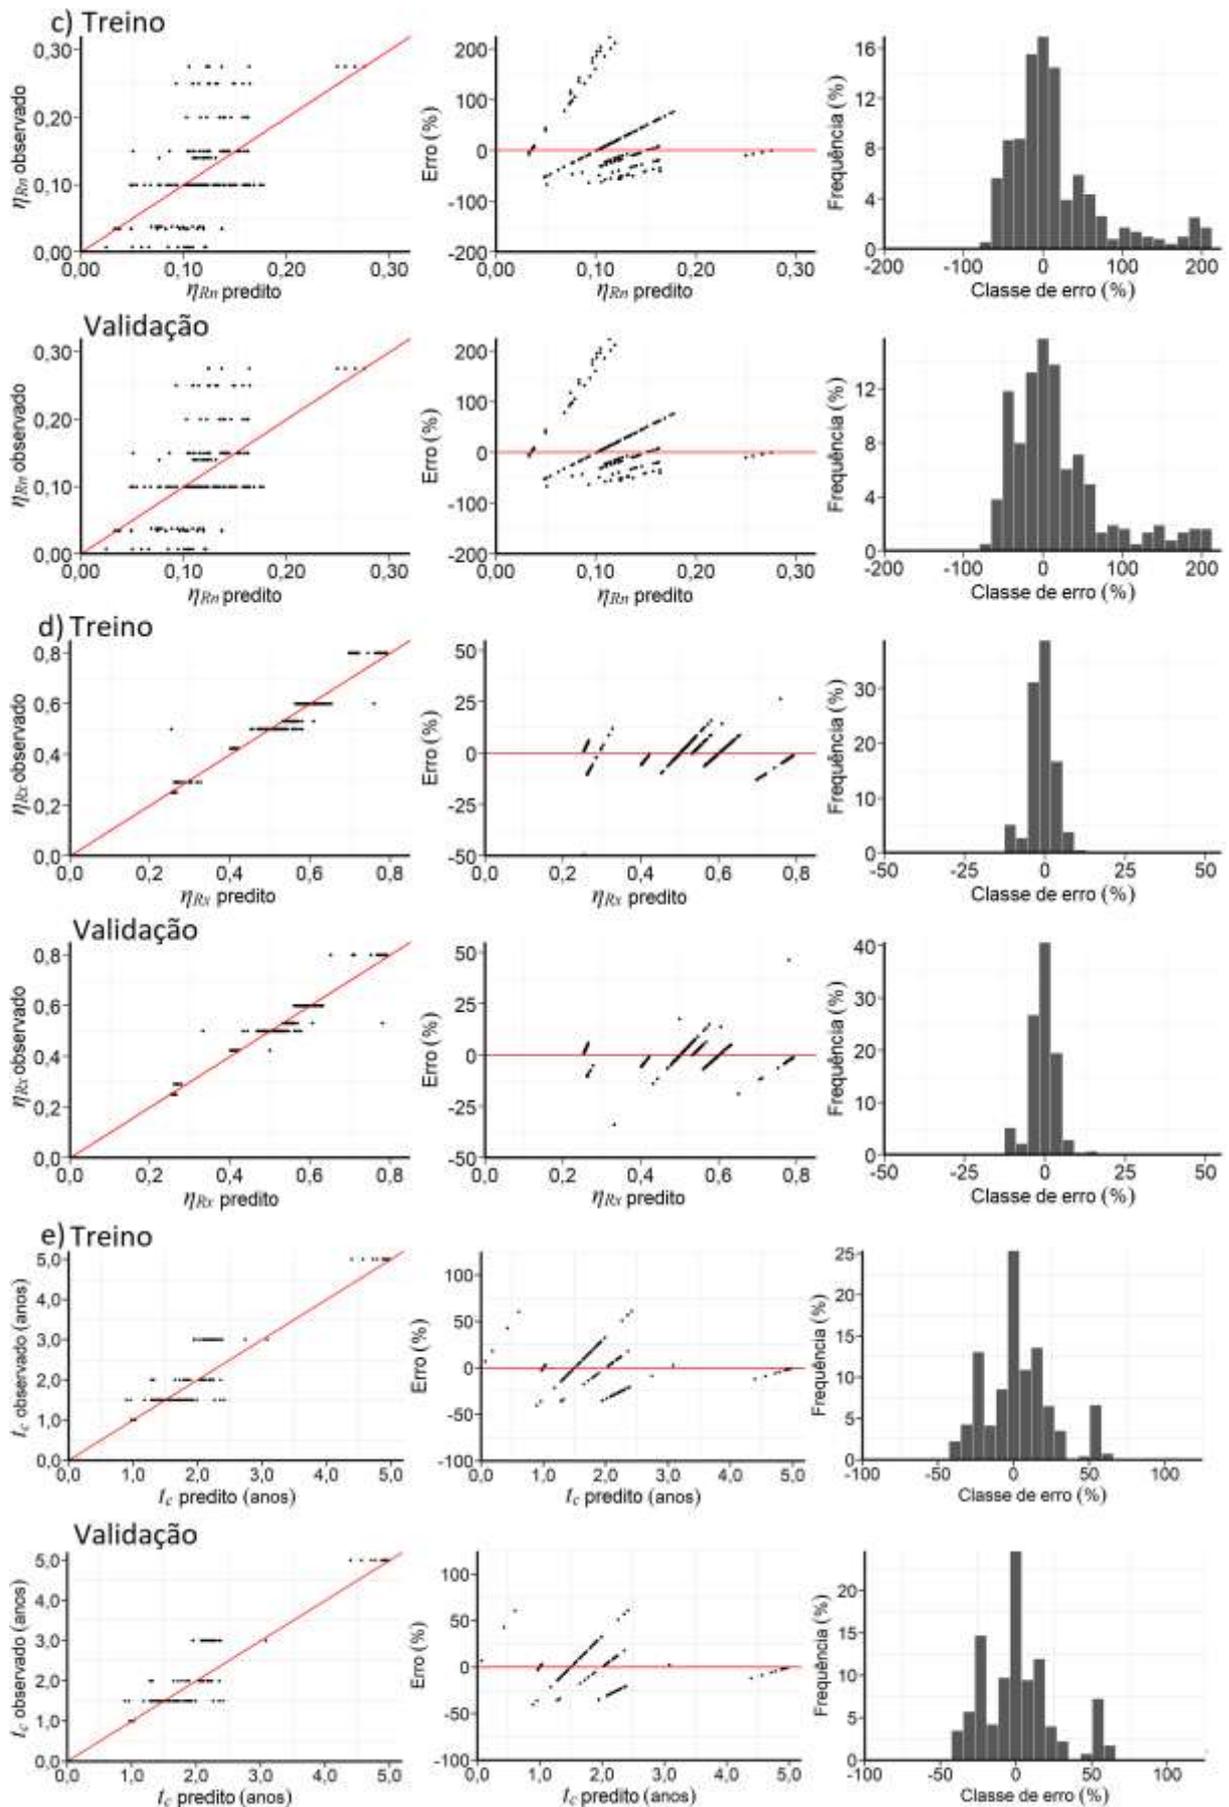
E; I; S = topologia da rede com número de neurônios nas camadas de entrada, intermediária e saída, respectivamente; p-valor do teste F de Graybill ($\alpha = 0,05$); RQEM = Raiz quadrada do erro quadrático médio; $r_{\hat{Y}Y}$ = correlação entre valores preditos pela RNA e observados; a_s = constante da relação para estimar o D ; n_s = potência da relação para estimar o D ; η_{Rn} = fração mínima de biomassa alocada para raízes; η_{Rx} = fração máxima de biomassa alocada para raízes; t_c = idade de fechamento do dossel.

Fonte: Elaborada pela autora.

Graficamente é possível perceber o comportamento da dispersão dos dados com um padrão causado pela repetição de um mesmo valor observado do parâmetro para diferentes condições (Figura 5). Porém, a maior parte dos erros relativos percentuais, entre valores observados e preditos pela RNA, se concentraram entre $\pm 30\%$ em todas as redes na validação e no treino, exceto para o parâmetro η_{Rn} , que apresentou 45% dos erros relativos percentuais na validação e 48% no treino concentrados neste intervalo (Figura 5).

Figura 5 - Dispersão dos valores preditos pela RNA e observados, erros relativos percentuais e percentagem dos casos por classe de erro relativo percentual, dos conjuntos de treino e de validação. Parâmetro a_s (a), parâmetro n_s (b), frações mínima (c) e máxima (d) de biomassa alocada para raiz e idade de fechamento do dossel (e).



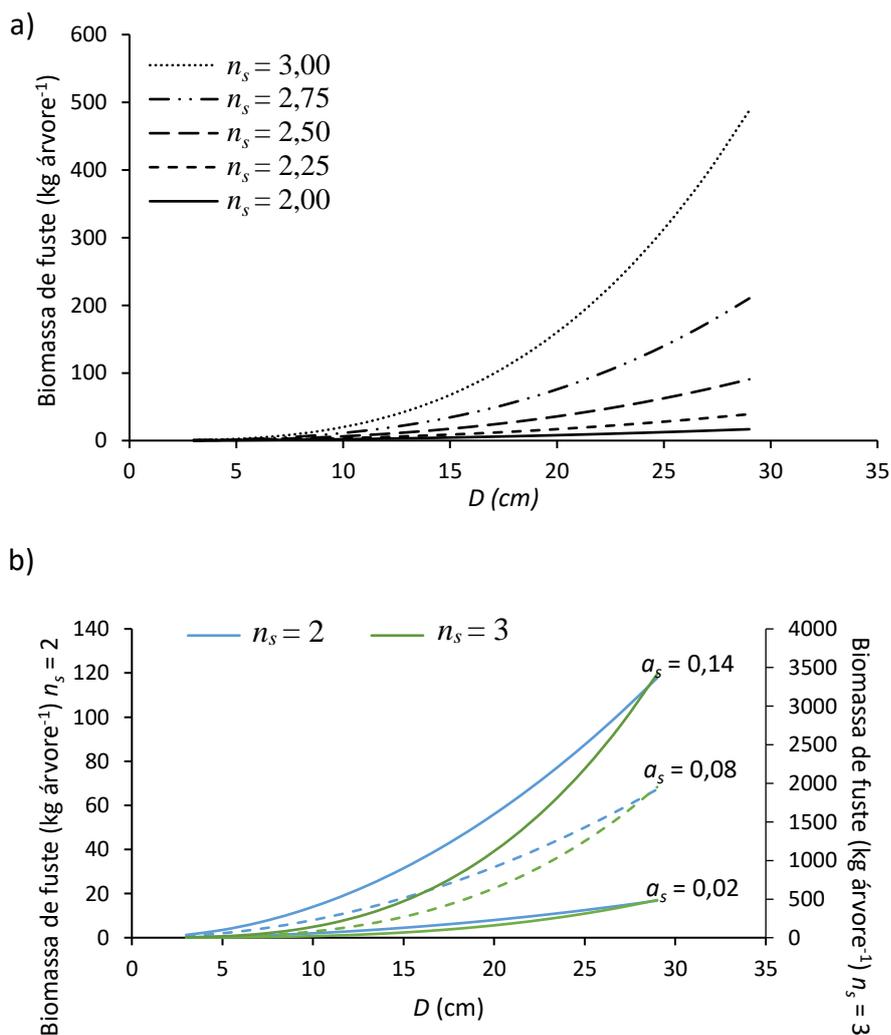


Fonte: Elaborada pela autora.

Ao considerar o intervalo dos parâmetros a_s e n_s usados no treino das redes, foi observada a tendência do comportamento da curva ao modificar os seus valores. O parâmetro n_s de fato pode causar maior sensibilidade em algumas saídas, visto que a concavidade da curva muda de forma relativamente ampla a cada 0,25 unidades de diferença, mas essa mudança cresce em valores mais altos, acima de 2,5 (Figura 6 a).

No parâmetro a_s , que representa o deslocamento da curva, essa mudança é menos expressiva em relação ao n_s . Para diferentes valores de n_s , o deslocamento muda em menor intensidade, sendo necessário variações mais amplas desse parâmetro para causar mudanças mais expressivas (Figura 6 b).

Figura 6 – Resultado de simulações feitas com os parâmetros n_s para um $a_s = 0,02$ (a); e com o parâmetro a_s para $n_s = 2$ e 3 (b); de acordo com os intervalos dos valores obtidos nas 16 parametrizações selecionadas.



Fonte: Elaborada pela autora.

3.2 Treinamento sem repetição (16 observações)

Ao reduzir o banco de dados e considerar a média dos valores, ou seja, condições médias, as melhores combinações entre variáveis se manteve a mesma para a rede dos parâmetros da relação com o D (a_s e n_s) e da fração mínima alocada para a raiz (η_{Rn}). Na rede para prever o parâmetro t_c , a quantidade de variáveis aumentou, e para o parâmetro η_{Rx} diminuiu. As redes selecionadas foram definidas pelas seguintes relações funcionais:

$$a_s = f[g(n_s, solar_rad, T_a)]$$

$$n_s = f[g(prcp, T_a, solar_rad, A_f)]$$

$$\eta_{Rn} = f[g(amp_temp, solar_rad, prcp)]$$

$$\eta_{Rx} = f[g(\eta_{Rn}, p_2, prcp, amp_temp)]$$

$$t_c = f[g(T_a, apar, prcp, f_D)]$$

em que: $prcp$ = precipitação pluviométrica mensal (mm); T_a = temperatura média (°C); $solar_rad$ = radiação solar ($MJ\ m^{-2}\ dia^{-1}$); A_f = índice de área foliar ($m^2\ m^{-2}$); a_s e n_s = parâmetros da relação funcional para estimar o D médio; η_{Rn} = fração mínima de biomassa alocada para a raiz; η_{Rx} = fração máxima de biomassa alocada para a raiz; amp_temp = amplitude entre temperaturas máxima e mínima (°C); p_2 = fração de biomassa entre folha e fuste para um $D = 2$ cm; f_D = modificador do crescimento dependente do déficit de pressão de vapor.

Estatisticamente houve uma melhora nas redes dos parâmetros n_s e η_{Rn} , as demais redes apresentaram uma pequena diferença em relação ao uso do banco de dados com repetição. Os valores de RQEM do parâmetro η_{Rn} passou de 50,5% no treino para 38,1% nesta abordagem e o n_s de 7% para 3%. As correlações entre valores observados e preditos pelas redes foram acima de 0,8 e todos os p-valores do teste F_{H0} não significativos (Tabela 4).

Tabela 4 – Estatísticas do treino com 100% dos dados, em condições médias, das redes selecionadas para predizer os parâmetros do modelo 3-PG.

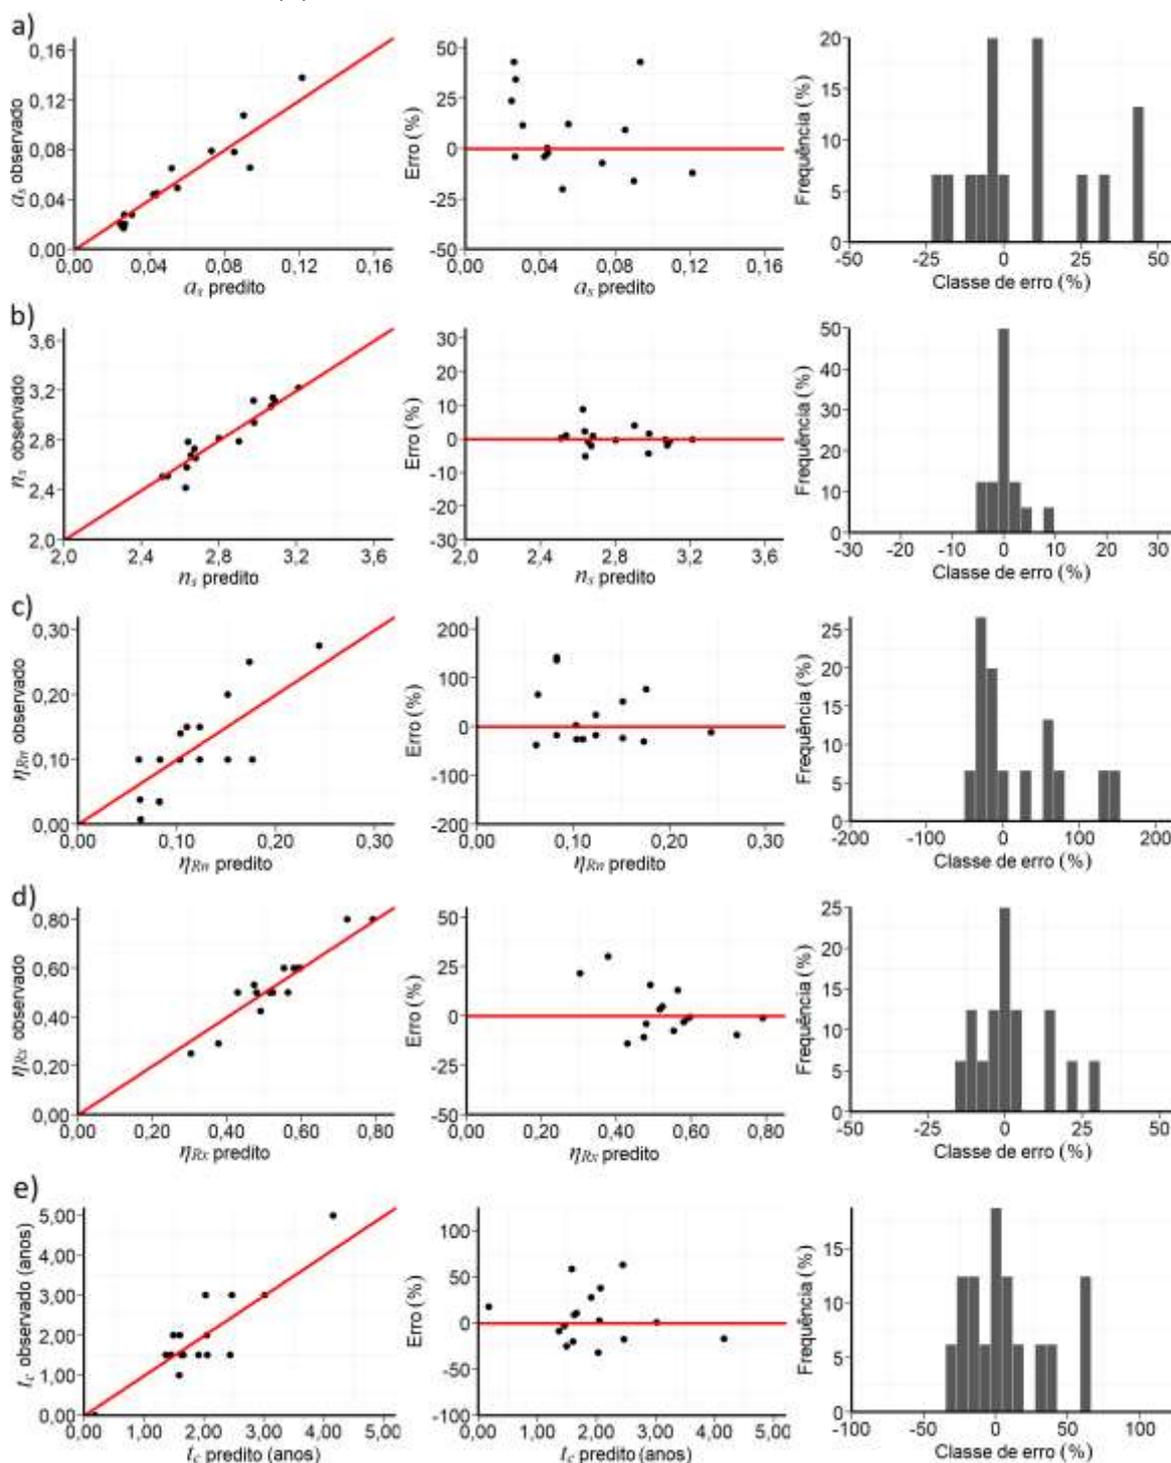
Parâmetro	E-I-S	Treino (16 observações)			
		$r_{\hat{Y}Y}$	RQEM	RQEM (%)	p-valor
a_s	3-2-1	0,9500	0,011	20,7	0,5828
n_s	4-4-1	0,9439	0,084	3,0	0,7661
η_{Rn}	3-2-1	0,8046	0,045	38,1	0,6832
η_{Rx}	4-2-1	0,9569	0,048	8,8	0,3681
t_c	4-3-1	0,8910	0,511	25,9	0,5762

E; I; S = topologia da rede com o número de neurônios nas camadas de entrada, intermediária e saída, respectivamente; p-valor do teste F de Graybill ($\alpha = 0,05$); RQEM = Raiz quadrada do erro quadrático médio; $r_{\hat{Y}Y}$ = correlação entre valores preditos pela RNA e observados; a_s = constante da relação para estimar o D ; n_s = potência da relação para estimar o D ; η_{Rn} = fração mínima de biomassa alocada para raízes; η_{Rx} = fração máxima de biomassa alocada para raízes; t_c = idade de fechamento do dossel.

Fonte: Elabora pela autora.

Em geral, houve redução na dispersão dos erros relativos percentuais entre valores observados e preditos pela RNA, principalmente para os parâmetros n_s e η_{Rn} (Figura 7 b, c). A rede do parâmetro n_s apresentou 100% dos dados entre $\pm 25\%$ e os parâmetros a_s , η_{Rn} , η_{Rx} e t_c com 75; 93,7 e 62,5% dos erros neste intervalo, respectivamente. Porém, o desempenho geral das redes, com o treino usando a média dos valores e mantendo o banco de dados com repetição, mantiveram a mesma tendência, com menor dispersão dos dados. Houve melhora mais significativa para o parâmetro η_{Rn} que obteve menor dispersão dos erros em relação ao banco de dados com repetição (Figura 7 c).

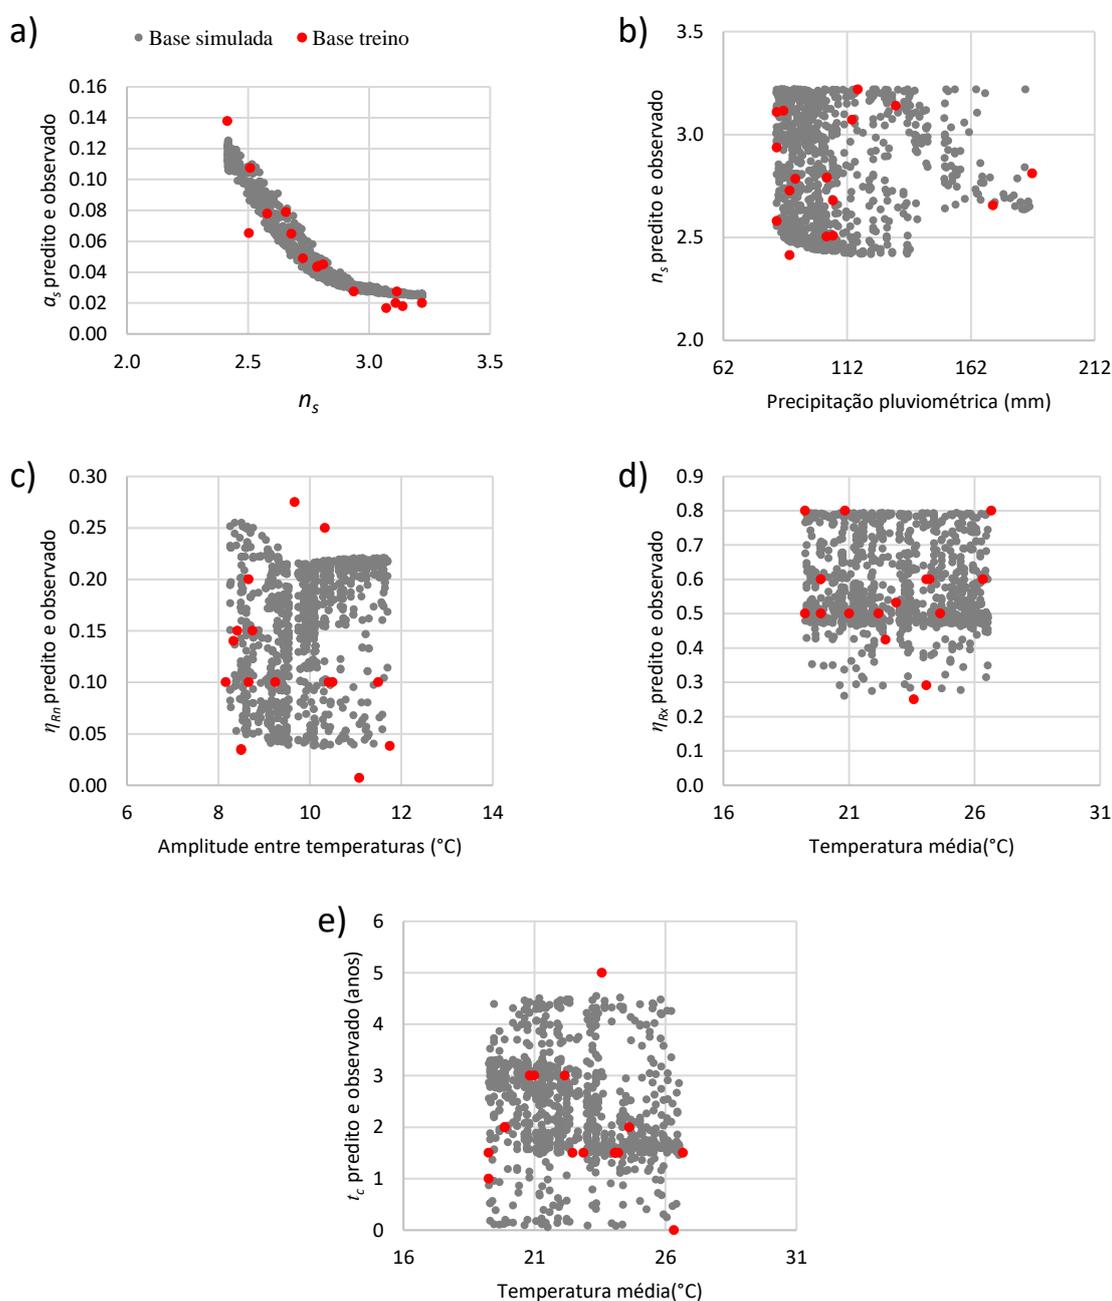
Figura 7 - Dispersão dos valores preditos pela RNA e observados, erros relativos percentuais e percentagem dos casos por classe de erro relativo percentual. Parâmetro a_s (a), parâmetro n_s (b), frações mínima (c) e máxima (d) de biomassa alocada para a raiz e idade de fechamento do dossel (e).



Fonte: Elaborada pela autora.

A aplicação das redes no banco de dados simulado apresentou consistência em relação ao banco de dados usado no treino. Em relação às variáveis de entrada, somente o parâmetro a_s apresentou tendência bem definida em relação ao parâmetro n_s . Nas demais redes, como o valor predito está relacionado com dados climáticos, não houve tendência clara. Apesar disso, os resultados foram coerentes com o comportamento da variável de entrada relacionada com cada parâmetro (Figura 8).

Figura 8 – Resultado da validação das redes com o banco de dados simulado.



Fonte: Elaborada pela autora.

4 DISCUSSÃO

Com o uso de redes neurais artificiais, tentamos mapear as relações funcionais entre variáveis climáticas e de processos para prever parâmetros do modelo 3-PG. Os parâmetros selecionados foram aqueles apontados na literatura como responsáveis por gerar maior sensibilidade em algumas saídas do modelo. A RNA foi escolhida por permitir associar variáveis de diferentes tipos, conferindo maior capacidade de generalização e capacidade de descrever a interação entre essas variáveis.

De modo geral, o modelo 3-PG simula o crescimento e a produção de florestas em função de variações climáticas que afetam o comportamento dos processos fisiológicos das árvores ao longo do tempo. Porém, os parâmetros são mantidos constantes ao longo de todo o processamento, neste trabalho não foi considerado mudança no valor dos parâmetros. Então as mudanças ocorreram a partir das entradas de clima, em passos mensais, que alteram as condições e as saídas do modelo. Com base nessa dinâmica, as variáveis de estado são alteradas a cada mês até o fim do período de processamento, mantendo o valor dos parâmetros. Dessa forma, ao configurar o banco de dados para treino das redes neurais artificiais, as colunas referentes às saídas (valores dos parâmetros) de cada localidade, repetiram ao longo do tempo. Para verificar o efeito dessa configuração, as redes foram treinadas considerando dois conjuntos de dados: com a repetição do parâmetro ao longo do tempo e com as condições médias de cada sítio.

4.1 Eficiência das redes neurais artificiais com o banco de dados completo

Nessa primeira abordagem, para as condições e variáveis testadas neste trabalho, os resultados estatísticos das redes foram satisfatórios no treino e na validação, exceto para o parâmetro fração mínima de biomassa alocada para raiz (η_{Rn}) e idade de fechamento do dossel (t_c). Acredita-se que nesses casos, faltaram adicionar informações importantes para explicar a variação desses parâmetros.

A rede selecionada para prever o parâmetro a_s foi composta pelas variáveis radiação solar, temperatura média e o parâmetro n_s . Os resultados gráficos e estatísticos dessa rede foi o de melhor desempenho em relação às redes dos

demais parâmetros, na primeira abordagem. Utilizar o n_s na rede foi essencial para reduzir o resíduo no treino e na validação.

Como a_s e n_s são preditos em conjunto para descrever a relação entre o D e a biomassa média de fuste, usar uma rede neural para integrar o valor de n_s com as variáveis climáticas pode promover resultados adequados do parâmetro a_s em um determinado sítio.

O comportamento descrito pelos parâmetros a_s e n_s é uma curva gerada por um modelo exponencial simples, em que a constante é representada pelo a_s , que geralmente apresenta valores próximos a zero, e a potência é representada pelo n_s . Juntos, estes parâmetros incorporam os efeitos da altura e da forma do fuste (LANDSBERG; WARING; COOPS, 2003). Alguns estudos apontam que as saídas D e área basal tem forte sensibilidade ao valor desses parâmetros (PÉREZ-CRUZADO *et al.*, 2011; PÉREZ-CRUZADO; MERINO; RODRÍGUEZ-SOALLEIRO, 2011) e o índice de área foliar tem sensibilidade forte em relação ao parâmetro n_s e moderada em relação ao parâmetro a_s (ESPREY; SANDS; SMITH, 2004). Dessa forma, o uso da rede pode melhorar o processo de predição desses parâmetros, conforme as condições do sítio, reduzindo as incertezas sobre as saídas do modelo.

Para o parâmetro n_s a combinação entre as variáveis precipitação pluviométrica, temperatura média, radiação solar e índice de área foliar foi a que apresentou os melhores resultados gráficos e estatísticos. Nesse caso, as correlações foram baixas ($\approx 0,6$) no treino e na validação, porém os erros relativos percentuais entre valores preditos pela RNA e observados concentraram-se entre $\pm 20\%$. Isto ocorreu, pois, a estrutura do banco de dados com repetição gerou um conjunto de predições em relação a cada único valor observado, para diferentes condições. Esse comportamento fez com que o gráfico apresentasse uma estrutura “retangular”, ou conjunto de filas horizontais de pontos, causando baixa correlação. O mesmo foi observado em todas as redes, com menor intensidade nas redes dos parâmetros a_s e η_{Rx} , pois, nestes dois últimos casos, foram utilizados outros parâmetros como variáveis de entrada, reduzindo a dispersão dos pontos.

As variações climáticas causam mudanças na dinâmica de alocação da biomassa entre os compartimentos das árvores (SANDS; LANDSBERG, 2002; ZHAO *et al.*, 2009), e como as mudanças na biomassa de fuste interferem no

crescimento em D , o uso de variáveis climáticas podem ser importantes indicativos da tendência da curva descrita pelos parâmetros a_s e n_s .

Segundo Landsberg, Waring e Coops (2003) o ideal seria obter os parâmetros a_s e n_s a partir de dados experimentais, sempre que possível, e por serem parâmetros de uma relação não linear, pequenas variações podem causar diferenças significativas nos valores de D , área basal e volume. Esses autores recomendaram que uma vez definidos os valores de a_s e n_s , eles não fossem mais alterados na calibração. Em casos onde não é possível estimá-los com o uso de dados observados, as redes aqui apresentadas podem ser uma alternativa mais adequada. Futuramente, uma comparação com dados observados poderia reforçar o potencial de uso dessa rede, com diferentes combinações ou outras técnicas de aprendizado de máquina.

Os parâmetros η_{Rn} e η_{Rx} representam um intervalo mínimo e máximo de biomassa a ser alocada para as raízes, respectivamente. Apenas a rede para prever o parâmetro η_{Rx} obteve bom desempenho gráfico e estatístico, ao combinar as variáveis precipitação pluviométrica, temperatura média, modificador dependente do déficit de pressão de vapor (f_D), índice de área foliar e os parâmetros η_{Rn} e ρ_2 . Já para a rede da fração mínima, a combinação não foi suficientemente adequada e os resultados foram mais dispersos, gerando maiores erros relativos.

O intervalo definido por η_{Rn} e η_{Rx} está inserido na relação onde é calculada a taxa de biomassa líquida a ser alocada para a raiz (η_R), que depende também da fertilidade do solo e da disponibilidade hídrica. Dessa forma, o acréscimo dessas informações na rede pode promover melhores predições. Apesar disso, os resultados para η_{Rx} foram precisos, possibilitando a aplicação e teste dessa rede no processo de parametrização ou calibração do modelo.

Outra questão, é que se o banco de dados fosse gerado com as condições de solo correspondentes a cada sítio, as predições também poderiam ser mais precisas. É também importante considerar, que dados de biomassa de raiz, raramente estão disponíveis, por ser mais difícil a coleta em campo. Na maior parte dos trabalhos abordados nesta pesquisa, esses parâmetros foram provenientes da literatura, o que mostra uma certa dificuldade em determiná-los a partir de dados observados e o risco de usar valores inadequados. Isso também mostra como a

busca por um banco de dados com maior variabilidade e número de informações, diretas ou indiretas, poderia ajudar na obtenção de uma rede mais abrangente que auxilie os usuários do modelo.

De acordo com Esprey, Sands e Smith (2004), os parâmetros η_{Rn} e η_{Rx} fazem parte do conjunto de parâmetros que requerem determinação mais acurada, pois, geram sensibilidade moderada nas saídas volume e índice de área foliar. Almeida, Landsberg e Sands (2004) observaram que a biomassa de raiz tem forte sensibilidade em relação ao valor do parâmetro η_{Rn} . Portanto, informações ligadas a fertilidade de solo podem promover melhorias na predição desse parâmetro.

A predição do parâmetro idade de fechamento do dossel (t_c) apresentou bom desempenho geral, porém com algumas tendências e RQEM alto em relação às demais redes. As variáveis temperatura média, radiação solar e o parâmetro p_{20} corresponderam a combinação selecionada nesta rede.

O parâmetro t_c também é muito importante para o modelo 3-PG. As primeiras versões do modelo não consideravam a idade de fechamento do dossel, então a estrutura da floresta já era iniciada com o dossel totalmente coberto. A idade de fechamento do dossel é utilizada no cálculo da cobertura do dossel, que em seguida é usada junto com o índice de área foliar, no cálculo da radiação fotossinteticamente ativa interceptada, por meio da lei de Beer. Quando não é utilizada a idade correta de fechamento do dossel, pode haver inconsistência na estimativa do crescimento da floresta nos anos iniciais.

Na pesquisa desenvolvida por Rodríguez-Suárez *et al.* (2010) dois dos parâmetros analisados no presente estudo (t_c e n_s) foram ajustados para plantios de *Eucalyptus globulus* na Espanha. Os autores observaram que mesmo para esta espécie, usada na parametrização padrão do modelo 3-PG, é necessário ajustar alguns parâmetros, em especial a idade de fechamento do dossel e o parâmetro n_s , usado na estimativa do D .

Segundo os autores, mudanças nesses parâmetros alteram as taxas de crescimento do plantio para as condições do ambiente. Em três parcelas analisadas, os autores mediram a projeção da copa até 10 anos para estimar o parâmetro t_c , e encontraram diferentes valores em cada uma delas (3,5; 7,0 e 5,5 anos). Com a obtenção desses valores, as estimativas melhoraram consideravelmente, principalmente nos primeiros anos. E ao ajustar ambos os parâmetros em cada

parcela (t_c e n_s) as estimativas de D e altura total pelo modelo 3-PG foram muito próximos aos valores observados. O teste de sensibilidade também mostrou como a altura total e o D possuem alta sensibilidade às variações desses parâmetros, principalmente nas idades iniciais.

Song *et al.* (2013) verificaram que a biomassa de folha tem forte sensibilidade ao parâmetro n_s , então como o fechamento do dossel ocorre pelo crescimento da copa, a determinação de valores mais apropriados para t_c e n_s é importante para melhor descrever a taxa de crescimento da floresta. Com isso, o uso de variáveis climáticas e do parâmetro p_{20} na predição do t_c , podem ter colaborado ao representar parte dos efeitos do sítio e a proporção entre folha e fuste em idade madura, respectivamente. Porém, o uso de variáveis ligadas a fertilidade do solo pode melhorar a precisão dessa rede. Outra possibilidade é prever diretamente a fração de cobertura do dossel, usando variáveis do sítio e a idade como entradas da rede.

No trabalho desenvolvido por Xie, Wang e Lei (2017) a sensibilidade do parâmetro t_c também foi avaliada, os autores recomendaram que um valor adequado desse parâmetro é fundamental para o ajuste adequado do modelo 3-PG às condições da floresta, o mesmo foi verificado por (CAO *et al.*, 2019).

Oliveira *et al.* (2018) aplicaram o modelo 3-PG para a região norte de MG usando a parametrização realizada para a região de cerrado no norte de MG, porém os resultados não foram representativos do local. Os autores encontraram resultados mais apropriados ao modificarem os parâmetros idade de fechamento do dossel, o parâmetro n_s e os parâmetros das relações alométricas para altura total e volume.

Diante disso, é possível perceber como as condições do ambiente interferem no crescimento da floresta e como o valor do parâmetro deve estar adequado ao se utilizar o modelo 3-PG em diferentes sítios. As redes neurais artificiais podem ser adequadas para o cálculo dos parâmetros ao integrar as condições do ambiente, e outras variáveis importantes, de diferentes tipos, na predição do parâmetro.

4.2 Eficiência das redes neurais artificiais com o banco de dados sem repetição

Com o banco de dados composto pela média dos valores de cada sítio, reduzido em 16 observações, algumas combinações de variáveis foram mantidas e outras reduziram o número de entradas, exceto a rede para prever o parâmetro t_c .

Para prever o parâmetro a_s foi selecionada uma rede com as mesmas variáveis e menor número de neurônios na camada intermediária. Porém, o erro médio foi mais alto ao considerar condições médias (10%). Apesar disso, em ambos os casos o desempenho da rede foi satisfatório, e o teste e aplicação das duas redes é recomendado. Isso porque os valores de a_s são próximos a zero, e o erro máximo obtido foi de 55,7% nesse caso, o que corresponde a um valor observado de 0,02 predito como 0,03. E como analisado neste estudo, para o intervalo considerado, as variações desse parâmetro afetam a tendência da curva de forma menos significativa em relação ao parâmetro n_s .

Com a eliminação do efeito da repetição na dispersão do banco de dados, a rede treinada para o parâmetro n_s apresentou resultados estatísticos melhores em relação ao primeiro treinamento realizado. Nesse caso a topologia da rede e as variáveis de entrada selecionadas foram as mesmas, mas os erros relativos percentuais entre valores observados e preditos pela RNA reduziram o intervalo para -5 a 9%. Portanto, mesmo que o desempenho tenha sido satisfatório nos dois casos, o uso de condições médias promoveu melhor ajuste, devido a não repetição dos valores para diferentes condições. E considerando a importância desse parâmetro no modelo, capaz de causar alta sensibilidade em algumas saídas e importante na representação das taxas de crescimento, esse menor intervalo residual pode tornar a predição de n_s mais segura.

O valor mínimo do intervalo da fração de biomassa alocada para raízes (η_{Rn}) foi a rede que apresentou mudança mais significativa nos resultados estatísticos nessa abordagem de treinamento. Mas, ainda assim, a inclusão da variável fertilidade do solo pode causar maior precisão no ajuste dessa rede.

Por se tratar de valores pequenos, erros mais elevados não causaram amplas diferenças entre valores observados e preditos pela RNA, com 69% dos erros relativos percentuais entre $\pm 50\%$, os maiores erros foram para valores muito pequenos (entre 0,01 e 0,04).

Nas duas abordagens, o parâmetro da fração máxima de biomassa alocada para a raiz (η_{Rx}) obteve bom desempenho. Porém, os resultados estatísticos foram ainda melhores no banco de dados completo. A topologia da rede foi diferente nesse caso, com menor número e variáveis de entrada e neurônios na camada intermediária, mantendo as variáveis precipitação pluviométrica, p_2 e η_{Rn} com o acréscimo da variável amplitude entre as temperaturas mínima e máxima. Como a variação desse parâmetro não foi alta, recomenda-se o teste e aplicação das duas redes.

A rede selecionada para prever a idade de fechamento do dossel apresentou pequena diferença em relação ao banco de dados com repetição. Na primeira abordagem, 40% dos resíduos concentraram-se entre $\pm 10\%$, enquanto nesse caso 31,3% dos resíduos estiveram nesse intervalo. Foi selecionada uma combinação com maior número de variáveis de entrada, porém relativamente mais simples que na primeira abordagem. Recomenda-se o uso das duas redes, lembrando que ainda são necessários testes com uso de outras variáveis, principalmente ligadas a fertilidade do solo para prever este parâmetro. O banco de dados simulado para este estudo considerou $FR = 0,8$ em todos os sítios, por isso, acredita-se que em casos onde características físicas e químicas do solo ou até mesmo análise foliar, estejam disponíveis, pode-se chegar a modelos de RNA muito eficientes.

Ao validar as redes com dados simulados, os resultados foram consistentes com o banco de dados do treino. Apesar de, em alguns casos, não ser observada uma tendência bem definida entre valores preditos e variáveis de entrada, é possível perceber certa semelhança na dispersão dos dados de treino em relação aos dados simulados. Na Figura 8b por exemplo, onde há uma maior concentração de dados da base treino, também ocorre maior concentração das predições feitas com a base simulada, o mesmo pode ser observado nos demais gráficos.

A proposta de validação com dados simulados é uma opção muito eficiente para estudos de modelagem e pode ser testada para diferentes categorias de modelos e objetivos. Futuramente essa ideia pode e deve ser aprimorada por pesquisadores na área.

Nas duas abordagens, para os parâmetros e condições aqui avaliadas, o uso apenas de variáveis climáticas como entradas das redes, não gerou bom

desempenho (resultados não apresentados). Portanto, a perda de precisão pelo uso da RNA em função apenas de variáveis climáticas pode não compensar o trabalho em obter outras variáveis explicativas. Porém, nas redes de melhor desempenho, com excessão dos dados de biomassa, as demais variáveis são de fácil obtenção. Além disso, acredita-se que o uso de dados edáficos simples, como tipo de solo, teor de argila ou outras características físicas do solo, disponíveis para a região, já poderiam ser suficientes para melhorar os resultados, mantendo o modelo de RNA o mais simples possível.

O processo de calibração manual consiste na alteração do parâmetro seguida pela simulação do modelo 3-PG até que os valores simulados estejam próximos dos valores observados. Uma RNA, em treinamento supervisionado, faz a comparação entre o valor predito e o valor observado, a cada iteração, de forma otimizada por meio de um algoritmo de aprendizado e com base em variáveis de entrada relacionadas com a saída. Com a aplicação de uma rede no processo de parametrização do modelo, a calibração manual pode ser evitada e, ao mesmo tempo, simplifica e resulta em maior flexibilidade e consistência, além de menor custo na obtenção de dados para calibrar o modelo 3-PG e ainda, a possibilidade de inserir variáveis categóricas na rede.

Sobre a aplicação da rede em si, a decisão sobre o uso de entradas com dados médios do sítio ou não, cabe ao usuário do modelo, pois independentemente de como as redes foram treinadas o bom desempenho veio do uso de dados de entrada adequados, como ocorreu na maioria dos casos. A organização do banco de dados, não causou prejuízo ao processo de treinamento das redes. Se a rede for apresentada a um banco de dados com variabilidade adequada, as entradas podem corresponder a dados médios ou não no momento da sua aplicação.

Por meio do grande número de estudos já publicados com o modelo 3-PG, em diferentes condições e espécies, em diversas partes do mundo, existe um acúmulo de experiência por parte dos usuários e pesquisadores com esse modelo. E pensando na forma como os parâmetros podem variar, não só por espécie, mas entre sítios, a determinação desses parâmetros, principalmente aqueles de maior importância e sensibilidade, pode ser realizada de forma mais segura ao empregar uma rede neural que compreenda variáveis de sítio e até mesmo de espécie ou clone.

A RNA também pode ser aplicada para prever o parâmetro eficiência quântica máxima do dossel (α_{Cx}). Conforme as recomendações de Sands (2004), α_{Cx} pode ser encontrado de três formas: a partir de dados experimentais com árvores crescendo sem limitações de água e nutrientes; uso do valor máximo de α_C , a partir de valores de α_C encontrados em sítios com diferentes produtividades ou pela média dos valores de α_C encontrados em sítios muito produtivos. Em qualquer desses casos, a rede pode ser utilizada como alternativa para prever α_{Cx} com a adição de outras variáveis explicativas importantes, de natureza categórica e relacionadas a espécie ou clone por exemplo.

Os modelos de RNA também podem ser integrados ao 3-PG, por um sistema paralelo, para predição dos parâmetros, simplificando a sua aplicação.

Nessa primeira tentativa, buscamos entender quais variáveis teriam relações biológicas consistentes com os parâmetros, e os resultados mostraram ser possível aplicar as redes no processo de parametrização ou calibração do modelo 3-PG. Mas ainda é necessário o uso de mais informações, principalmente de fertilidade do solo, e testar outras técnicas de aprendizado de máquina, considerando, por exemplo, a possibilidade de mudança no valor dos parâmetros em períodos específicos e em função de mudanças climáticas e edáficas, conforme Song *et al.* (2013). No caso do Brasil, seria interessante verificar se essa análise causaria impacto mesmo em menores rotações.

É também interessante investigar diferenças entre o uso de dados climáticos atuais em relação a normais climatológicas. Quanto mais avanços no aprendizado sobre o comportamento dos parâmetros, mais exatidão nos resultados e conseqüentemente melhor a aplicação para fins de manejo florestal, principalmente pensando em construir modelos de aprendizado de máquina constituído por variáveis que possam causar melhor resolução espacial ao modelo 3-PG, a nível de talhão por exemplo.

5 SUGESTÕES PARA APLICAÇÃO OU TESTE DAS REDES NEURAIS ARTIFICIAIS

$$n_s = f[g(\text{prcp}, T_a, \text{solar_rad}, A_f)] \quad a_s = f[g(n_s, \text{solar_rad}, T_a)]$$

Para realizar a predição dos parâmetros a_s e n_s é necessário o uso de variáveis climáticas referentes às áreas onde o modelo 3-PG será aplicado. Essas informações são fáceis de serem obtidas, a partir de dados de estações meteorológicas automáticas da empresa ou por meio de banco de dados disponíveis na *internet* (por exemplo: INMET, INPE, NASA POWER).

Primeiramente, é necessário predizer o parâmetro n_s , que além das variáveis climáticas, necessita do índice de área foliar. Nesse caso, o A_f pode ser obtido via satélite, calculado a partir de índices de vegetação (ALMEIDA *et al.*, 2015; BERGER *et al.*, 2019; PAIVA, 2009) ou utilizando o próprio modelo 3-PG, com parametrização realizada para uma região próxima, com mesmo genótipo ou espécie. Com todas essas informações integradas, é formado o banco de dados para a aplicação da RNA que irá predizer o parâmetro n_s .

Em seguida, com o valor predito de n_s , junto com as variáveis radiação solar e temperatura média, torna-se possível aplicar a rede para predizer o parâmetro a_s .

$$\eta_{Rn} = f[g(\text{amp_temp}, \text{solar_rad}, \text{prcp})] \quad \eta_{Rx} = f[g(\eta_{Rn}, p_2, \text{prcp}, T_a, f_D, A_f)]$$

$$\eta_{Rx} = f[g(\eta_{Rn}, p_2, \text{prcp}, \text{amp_temp})]$$

Para predizer o parâmetro η_{Rn} , mínimo de biomassa a ser alocada para a raiz, basta usar as variáveis climáticas amplitude entre temperaturas mínima e máxima, radiação solar e precipitação pluviométrica da região. Lembrando que essa rede não obteve desempenho satisfatório devido à falta de variáveis explicativas.

Já para o parâmetro intervalo máximo de biomassa a ser alocada para as raízes (η_{Rx}), na primeira abordagem, foi selecionada uma rede com maior número de variáveis. A primeira delas é o valor mínimo do intervalo (η_{Rn}), porém como a rede deste parâmetro foi pouco precisa, recomenda-se o uso de valor baseado na literatura ou valor padrão do modelo 3-PG. A fração de biomassa entre folha/fuste para um $D = 2$ cm (p_2), é um parâmetro já necessário em outras etapas do modelo 3-PG e de fácil obtenção. O modificador responsável pelo déficit de pressão de vapor

(f_D) é calculado em função do déficit de pressão de vapor (DPV) e do parâmetro K_D ($f_D = \exp(-k_D \cdot \text{DPV})$). O DPV pode ser obtido diretamente via dados de estação meteorológica ou pode ser calculado em função da temperatura. O parâmetro K_D , que descreve a relação entre DPV e f_D , é geralmente obtido pela literatura.

$$t_c = f[g(p_{20}, T_a, \text{solar_rad}, \text{prcp})] \quad t_c = f[g(T_a, \text{apar}, \text{prcp}, f_D)]$$

O parâmetro idade de fechamento do dossel não apresentou resultados precisos, pela falta de informações explicativas. Porém, as redes podem ser testadas com o uso das variáveis climáticas da região, o modificador f_D e a fração de biomassa entre folha/fuste para árvores com $D = 20$ cm, obtidos por dados observados ou pela literatura.

Como o valor dos parâmetros são constantes ao longo da aplicação do modelo 3-PG, recomenda-se a aplicação das redes para diferentes condições (idade, sítio, espaçamento, etc). A partir do resultado, pode ser adotado o valor médio para o parâmetro ou o modelo 3-PG pode ser aplicado para a área desejada, mudando o valor do parâmetro para corresponder a cada condição.

6 CONCLUSÕES

- a) Redes neurais artificiais são eficientes para o processo de parametrização e calibração do modelo 3-PG, resultando em flexibilização pela possibilidade de uso de variáveis de entrada de fácil obtenção;
- b) As redes treinadas para prever os parâmetros da relação alométrica com o D médio (a_s e n_s) e a fração máxima de biomassa alocada para a raiz (η_{Rx}) apresentaram maior precisão nos resultados. Para os demais parâmetros (η_{Rn} e t_c) existe a necessidade de mais investigação científica incluindo informações e variáveis de entrada como a fertilidade do solo;
- c) A estrutura do banco de dados não prejudicou o processo de treinamento das redes. Em casos onde os resultados não foram precisos, foi devido a falta de variáveis explicativas. As diferenças observadas estão associadas ao tamanho do banco de dados, em cada caso, e a forma como as informações foram relacionadas;
- d) A validação das redes, por meio de dados simulados, foi capaz de comprovar a eficiência das redes selecionadas na segunda abordagem.

REFERÊNCIAS

- ALMEIDA, A. C.; LANDSBERG, J. J.; SANDS, P. J. Parameterisation of 3-PG model for fast-growing *Eucalyptus grandis* plantations. **Forest Ecology and Management**, Amsterdam, v. 193, n. 1/2, p. 179-195, 2004.
- ALMEIDA, A. Q. de; RIBEIRO, A.; DELGADO, R. C.; RODY, Y. P.; OLIVEIRA, A. S. de; LEITE, F. P. Índice de área foliar de eucalyptus estimado por índices de vegetação utilizando imagens TM - Landsat 5. **Floresta e Ambiente**, Seropédica, v. 22, n. 3, p. 368-376, 2015.
- BAYAT, M.; BETTINGER, P.; HEIDARI, S.; KHALYANI, A. H.; JOURGHOLAMI, M.; HAMIDI, S. K. Estimation of tree heights in an uneven-aged, mixed forest in northern iran using artificial intelligence and empirical models. **Forests**, Basel, v. 11, n. 3, p. 324-323, 2020.
- BEHLING, M.; PIKETTY, M. G.; MORELLO, T. F.; BOUILLET, J. P.; LACLAU, J. P.; MESQUITA NETO, F. Eucalyptus plantations and the steel industry in Amazonia: a contribution from the 3-pg model. **Bois et Forêts des Tropiques**, Paris, v. 65, n. 309, p. 37-49, 2011.
- BERGER, R.; SILVA, J. A. A. da; FERREIRA, R. L. C.; CANDEIAS, A. L. B.; RUBILAR, R. Índices de vegetação para a estimativa do índice de área foliar em plantios clonais de *Eucalyptus saligna* Smith. **Ciência Florestal**, Santa Maria, v. 29, n. 2, p. 885-899, 2019.
- BINKLEY, D.; CAMPOE, O. C.; ALVARES, C. A.; CARNEIRO, R. L.; STAPE, J. L. Variation in whole-rotation yield among *Eucalyptus* genotypes in response to water and heat stresses: the TECHS project. **Forest Ecology and Management**, Amsterdam, v. 462, p. 117953, Feb. 2020.
- BINOTI, D. H. B.; BINOTI, M. L. M. da S.; LEITE, H. G. Configuração de redes neurais artificiais para estimação do volume de árvores. **Revista Ciência da Madeira**, Pelotas, v. 5, n. 1, p. 58-67, 2014.
- BINOTI, D. H. B.; DUARTE, P. J.; SILVA, M. L. M. da; SILVA, G. F. da; LEITE, H. G.; MENDONÇA, A. R. de; ANDRADE, V. C. L. de; VEGA, A. E. D. Estimation of height eucalyptus trees with neuroevolution of augmenting topologies (NEAT). **Revista Árvore**, Viçosa, MG, v. 41, n. 3, p. 1-8, 2017.
- BORGES, J. S. **Parametrização, calibração e validação do modelo 3-PG para eucalipto na região do cerrado de Minas Gerais**. 2009. 77 p. Dissertação (Mestrado em Solos e Nutrição de Plantas) - Departamento de Solos, Universidade Federal de Viçosa, Viçosa, MG, 2009.
- BURKHART, H. E.; TOMÉ, M. **Modeling forest trees and stands**. Berlin: Springer Science & Business Media, 2012.

CAMPOS, J. C. C. Principais fatores do meio que afetam o crescimento das árvores. **Revista Floresta**, Curitiba, v. 2, n. 3, p. 45-52, 1970.

CAO, L.; SHEN, X.; LIU, K.; WU, X. Estimation of forest structural parameters using UAV-LiDAR data and a process-based model in ginkgo planted forests. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, New York, v. 12, n. 11, p. 4175-4190, 2019.

CAVALLI, J. P. **Produtividade de Eucalyptus saligna com base nas propriedades físico-hídricas do solo e parametrização do modelo ecofisiológico 3-PG**. 2017. 149 p. Tese (Doutorado em Engenharia Florestal) - Universidade Federal de Santa Maria, Santa Maria, 2017.

DANTAS, D.; CALEGARIO, N.; ACERBI JÚNIOR, F. W.; CARVALHO, S. de P. C.; ISAAC JÚNIOR, M. A.; MELO, E. de A. Multilevel nonlinear mixed-effects model and machine learning for predicting the volume of Eucalyptus spp. trees. **Cerne**, Lavras, v. 26, n. 1, p. 48-57, 2020.

DOMINGUES, G. F.; SOARES, V. P.; LEITE, H. G.; FERRAZ, A. S.; RIBEIRO, C. A. A. S.; LORENZON, A. S.; MARCATTI, G. E.; TEIXEIRA, T. R.; CASTRO, N. L. M. de; MOTA, P. H. S.; SOUZA, G. S. A. de; MENEZES, S. J. M. da C. de; SANTOS, A. R. dos; AMARAL, C. H. do. Artificial neural networks on integrated multispectral and SAR data for high-performance prediction of eucalyptus biomass. **Computers and Electronics in Agriculture**, New York, v. 168, p. 105089, Jan. 2020.

ERCANLI, İ.; GÜNLÜ, A.; SENYURT, M.; KELES, S. Artificial neural network models predicting the leaf area index: a case study in pure even-aged Crimean pine forests from Turkey İlker. **Forest Ecosystems**, London, v. 5, n. 29, Sept. 2018. Disponível em: <https://forestecosyst.springeropen.com/articles/10.1186/s40663-018-0149-8#citeas>. Acesso em: 10 mar. 2021.

ESPREY, L. J.; SANDS, P. J.; SMITH, C. W. Understanding 3-PG using a sensitivity analysis. **Forest Ecology and Management**, Amsterdam, v. 193, n. 1/2, p. 235-250, 2004.

FONTES, L.; BONTEMPS, J. D.; BUGMANN, H.; OIJEN, V. van; GRACIA, C.; KRAMER, K.; LINDNER, M.; RÖTZER, T.; SKOVSGAARD, J. P. Models for supporting forest management in a changing environment. **Forest Systems**, Berlin, v. 3, n. 4, p. 8, 2010.

FRITSCH, S.; GUENTHER, F.; GUENTHER, M. F. **Package 'neuralnet'**: training of neural networks. Bonn: German Research Foundation, 2019.

GRAYBILL, F. A. **Theory and application of the linear model**. Belmont: Duxbury, 1976.

HAYKIN, S. **Neural networks and learning machines**. 3rd ed. Ottawa: Prentice Hall, 2009. 936 p.

KLIPPEL, V. H. **Modelagem ecofisiológica de cultivos de eucalipto em regiões subtropicais do Brasil**. 2015. 89 p. Tese (Doutorado em Meteorologia Agrícola) - Universidade Federal de Viçosa, Viçosa, MG, 2015.

LANDSBERG, J. J.; WARING, R. H. A generalised model of forest productivity using simplified concepts of radiation-use efficiency, carbon balance and partitioning. **Forest Ecology and Management**, Amsterdam, v. 95, n. 3, p. 209-228, 1997.

LANDSBERG, J. J.; WARING, R. H.; COOPS, N. C. Performance of the forest productivity model 3-PG applied to a wide range of forest types. **Forest Ecology and Management**, Amsterdam, v. 172, n. 2/3, p. 199-214, 2003.

LEK, S.; DELACOSTE, M.; BARAN, P.; DIMOPOULOS, I.; LAUGA, J.; AULAGNIER, S. Application of neural networks to modelling nonlinear relationships in ecology. **Ecological Modelling**, Amsterdam, v. 90, n. 1, p. 39-52, 1996.

LEMOS, C. C. Z. de. **Aprimoramentos, teste e uso do modelo 3-PG em plantios clonais de Eucalyptus no nordeste do estado de São Paulo**. 2012. 175 p. Tese (Doutorado em Recursos Florestais) - Universidade de São Paulo, Escola Superior de Agricultura "Luiz de Queiroz", Piracicaba, 2012.

LIM, H.; ALVARES, C. A.; RYAN, M. G.; BINKLEY, D. Assessing the cross-site and within-site response of potential production to atmospheric demand for water in Eucalyptus plantations. **Forest Ecology and Management**, Amsterdam, v. 464, p. 118068, Mar. 2020.

LONDERO, E. K.; SCHUMACHER, M. V.; SZYMCZAK, D. A.; ARAÚJO, E. F. Calibração do modelo 3-PG para Eucalyptus saligna Smith NA região de Guaíba - RS. **Ciencia Florestal**, Santa Maria, v. 25, n. 2, p. 293-305, 2015.

NANDY, S.; WATHAN, T.; KUSHWAHA, S. P. S.; KUMAR, A. S.; DADHWAL, V. K. Neural network-based modelling for forest biomass assessment. **Carbon Management**, London, v. 8, n. 4, p. 305-317, 2017.

NISKA, H.; SKON, J. P.; PACKALEN, P.; TOKOLA, T.; MALTAMO, M.; KOLEHMAINEN, M. Neural networks for the prediction of species-specific plot volumes using airborne laser scanning and aerial photographs. **IEEE Transactions on Geoscience and Remote Sensing**, New York, v. 48, n. 3, pt. 1, p. 1076-1085, 2010.

OLIVEIRA, C. M. M. de; DELGADO, R. C.; ARAÚJO, E. J. G. de; ALMEIDA, A. Q. de; ROSA, T. C.; OLIVEIRA JÚNIOR, J. F. de. Modelo 3-PG na previsão do potencial produtivo de áreas para plantios comerciais de Eucalyptus spp. **Ciência Florestal**, Santa Maria, v. 28, n. 1, p. 249-262, 2018.

PAIVA, Y. G. **Estimativa do índice de área foliar por métodos óticos e sensoriamento remoto para calibrar modelo ecofisiológico em plantios de eucalipto em áreas de relevo ondulado**. 2009. 74 f. Dissertação (Mestrado em Meteorologia Agrícola) - Universidade Federal de Viçosa, Viçosa, MG, 2009.

PÉREZ-CRUZADO, C.; MERINO, A.; RODRÍGUEZ-SOALLEIRO, R. A management tool for estimating bioenergy production and carbon sequestration in *Eucalyptus globulus* and *Eucalyptus nitens* grown as short rotation woody crops in north-west Spain. **Biomass and Bioenergy**, Oxford, v. 35, n. 7, p. 2839-2851, 2011.

PÉREZ-CRUZADO, C.; MUÑOZ, F.; BASURCO, F.; RIESCO, G. Combining empirical models and the process-based model 3-PG to predict *eucalyptus nitens* plantations growth in Spain. **Forest Ecology and Management**, Amsterdam, v. 262, n. 6, p. 1067-1077, 2011.

PIÑEIRO, G.; PERELMAN, S.; GUERSCHMAN, J. P.; PARUELO, J. M. How to evaluate models: observed vs. predicted or predicted vs. observed? **Ecological Modelling**, Amsterdam, v. 216, n. 3/4, p. 316-322, 2008.

R CORE TEAM. **R: a language and environment for statistical computing**. Vienna: R Foundation for Statistical Computing, 2020. Disponível em: <https://www.R-project.org/>. Acesso em: 10 out. 2020.

RASCON, N. J. L. **Modelagem ecofisiológica do desenvolvimento do eucalipto na Amazônia**. 2012. 93 f. Dissertação (Mestrado em Meteorologia Agrícola) - Universidade Federal de Viçosa, Viçosa, MG, 2012.

RIEDMILLER, M.; BRAUN, H. A direct adaptive method for faster backpropagation learning: the RPROP algorithm. *In: IEEE INTERNATIONAL CONFERENCE ON NEURAL NETWORKS*, 1993, San Francisco. **Proceedings** [...]. San Francisco: IEEE, 1993.

RODRÍGUEZ-SUÁREZ, J. A.; SOTO, B.; IGLESIAS, M. L.; DIAZ-FIERROS, F. Application of the 3PG forest growth model to a *Eucalyptus globulus* plantation in Northwest Spain. **European Journal of Forest Research**, Georgetown, v. 129, n. 4, p. 573-583, 2010.

SANDS, P. **Adaptation of 3-PG to novel species: guidelines for data collection and parameter assignment**. Hobart: CSIRO, 2004. (Technical report, 141).

SANDS, P. J. **3PG PJS user manual**. Taroona: [s. n.], 2010. 27 p.

SANDS, P. J.; LANDSBERG, J. J. Parameterisation of 3-PG for plantation grown *Eucalyptus globulus*. **Forest Ecology and Management**, Amsterdam, v. 163, n. 1/3, p. 273-292, 2002.

SILVA, A. K. V. da; BORGES, M. V. V.; BATISTA, T. S.; SILVA JUNIOR, C. A. da; FURUYA, D. E. G.; OSCO, L. P.; TEODORO, L. P. R.; BAIO, F. H. R.; RAMOS, A. P. M.; GONÇALVES, W. N.; MARCATO JUNIOR, J.; TEODORO, P. E.; PISTORI, H. Predicting *eucalyptus* diameter at breast height and total height with uav-based spectral indices and machine learning. **Forests**, Basel, v. 12, n. 5, p. 1-13, 2021.

- SILVA, G. G. C. da. **Nutrição, crescimento e sua modelagem em povoamentos de eucalipto em resposta à disponibilidade de água e nutrientes**. 2006. 102 p. Tese (Doutorado em Solos e Nutrição de Plantas) - Departamento de Solos, Universidade Federal de Viçosa, Viçosa, MG, 2006.
- SKOVSGAARD, J. P.; VANCLAY, J. K. Forest site productivity: a review of the evolution of dendrometric concepts for even-aged stands. **Forestry**, Basel, v. 81, n. 1, p. 13-31, 2008.
- SONG, X.; BRYAN, B. A.; ALMEIDA, A. C.; PAUL, K. Time-dependent sensitivity of a process-based ecological model. **Ecological Modelling**, Amsterdam, v. 265, p. 114-123, 2013.
- SONG, X.; BRYAN, B. A.; PAUL, K.; ZHAO, G. Variance-based sensitivity analysis of a forest growth model. **Ecological Modelling**, Amsterdam, v. 247, p. 135-143, 2012.
- STAHNINGER, N. I. **Parametrização de modelos de produtividade e de balanço nutricional para Pinus e Eucalyptus em Corrientes - Argentina**. 2017. 153 p. Tese (Doutorado em Solos e Nutrição de Plantas) - Departamento de Solos, Universidade Federal de Viçosa, Viçosa, MG, 2017.
- STAPE, J. L.; RYAN, M. G.; BINKLEY, D. Testing the 3-PG process-based model to simulate Eucalyptus growth with an objective approach to the soil fertility rating parameter. **Forest Ecology and Management**, Amsterdam, v. 193, p. 219, 2004.
- TROTSIUK, V.; HARTIG, F.; FORRESTER, D. I. r3PG - an R package for simulating forest growth using the 3-PG process-based model. **Methods in Ecology and Evolution**, London, v. 11, n. 11, p. 1470-1475, Aug. 2020.
- VAHEDI, A. A. Artificial neural network application in comparison with modeling allometric equations for predicting above-ground biomass in the Hyrcanian mixed-beech forests of Iran. **Biomass and Bioenergy**, Oxford, v. 88, p. 66-76, 2016.
- WEN, X.; ZHONGHUI, Z.; XIANGWEN, D.; WENHUA, X.; DALUN, T.; WENDE, Y.; XIALU, Z.; CHANGHUI, P. Applying an artificial neural network to simulate and predict Chinese fir (*Cunninghamia lanceolata*) plantation carbon flux in subtropical China. **Ecological Modelling**, Amsterdam, v. 294, p. 19-26, 2014.
- XIE, Y.; WANG, H.; LEI, X. Application of the 3-PG model to predict growth of *Larix olgensis* plantations in northeastern China. **Forest Ecology and Management**, Amsterdam, v. 406, p. 208-218, Sept. 2017.
- ZHAO, M.; XIANG, W.; PENG, C.; TIAN, D. Simulating age-related changes in carbon storage and allocation in a Chinese fir plantation growing in southern China using the 3-PG model. **Forest Ecology and Management**, Amsterdam, v. 257, n. 6, p. 1520-1531, 2009.

CONSIDERAÇÕES FINAIS

Com esta pesquisa foi possível encontrar combinações entre variáveis de fácil acesso para integrarem uma RNA dentro de um modelo processual. Estudos futuros podem ser voltados a aplicação da combinação entre 3-PG + RNA para análise da produtividade florestal frente aos cenários de mudanças climáticas, além do uso de outras técnicas de aprendizado de máquina. O mesmo é válido para os processos de parametrização e calibração do modelo 3-PG ou outros modelos processuais. Recomenda-se também estudos com o uso de técnicas de aprendizado de máquina para prever o valor de FR no 3-PG ou prever o modificador f_N diretamente.

As redes promoveram maior flexibilidade e adaptabilidade ao modelo 3-PG, o que implica em melhorias nos processos de planejamento e manejo de plantios florestais a partir do uso de um modelo processual. Além disso, demonstramos como os resultados gerados pelo modelo 3-PG podem ser melhor explorados e interpretados a partir de técnicas simples. Diante das diversas possibilidades que um modelo como o 3-PG oferece, a partir da compreensão de como a floresta pode responder a mudanças no clima ou nas técnicas de manejo e silviculturais, muito ainda pode e deve ser pesquisado. Espera-se que as redes aqui sugeridas sejam testadas ou treinadas para diferentes condições pelos usuários do modelo 3-PG, as planilhas estão disponíveis em: drive.google.com