

ELIANE CRISTINA SAMPAIO DE FREITAS

**MODELAGEM DA PRODUTIVIDADE DE EUCALIPTO POR MEIO DE REDES
NEURONAIS ARTIFICIAIS**

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*.

VIÇOSA
MINAS GERAIS - BRASIL
2017

**Ficha catalográfica preparada pela Biblioteca Central da Universidade
Federal de Viçosa - Câmpus Viçosa**

T

F866m
2017 Freitas, Eliane Cristina Sampaio de, 1988-
Modelagem da produtividade de eucalipto por meio de
redes neuronais artificiais. / Eliane Cristina Sampaio de Freitas.
– Viçosa, MG, 2017.
xii, 113f. : il. (algumas color.) ; 29 cm.

Inclui anexos.

Orientador: Haroldo Nogueira de Paiva.

Tese (doutorado) - Universidade Federal de Viçosa.

Inclui bibliografia.

1. Eucalipto - Produtividade. 2. Inteligência artificial.
3. Vegetação e clima. I. Universidade Federal de Viçosa.
Departamento de Engenharia Florestal. Programa de
Pós-graduação em Ciência Florestal. II. Título.

CDO adapt. CDD 22 ed. 634.9228

ELIANE CRISTINA SAMPAIO DE FREITAS

**MODELAGEM DA PRODUTIVIDADE DE EUCALIPTO POR MEIO DE REDES
NEURONAIS ARTIFICIAIS**

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*.

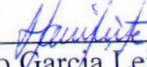
APROVADA: 07 de julho de 2017.



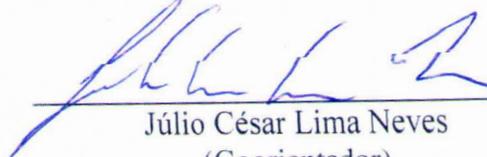
Nairam Félix de Barros



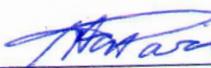
Gustavo Eduardo Marcatti



Helio Garcia Leite
(Coorientador)



Júlio César Lima Neves
(Coorientador)



Haroldo Nogueira de Paiva
(Orientador)

Aos meus pais e irmãos, amores da minha vida, pelos quais eu busco, diariamente, ser uma pessoa melhor.

AGRADECIMENTOS

A Deus pela minha vida, minha família.

Aos meus pais por tudo que tenho e sou. Ao meu pai, por me mostrar que sabedoria vai muito além de livros e diplomas adquiridos. À minha mãe, por ser meu melhor exemplo de fé, força e bondade.

Aos meus irmãos, Elsinho, Dudu, Elaine, Elinha, Érica, por me escutarem (e aguentarem) nos momentos mais caóticos, pelo apoio incondicional, e por todas as palavras e gestos de carinho.

Aos meus cunhados, família escolhida, pelos conselhos e incentivo.

Aos meus sobrinhos, pestinhas que eu amo, Vi, Luís, Lulu, João, Juju, Gu, pelo carinho, brincadeiras e diversos momentos de alegria.

Aos engenheiros florestais da turma de 2007, do SIG, pela amizade e conhecimento compartilhado. Em especial ao Gustavo, pela generosidade de sempre, por toda ajuda e sugestões não apenas na tese e banco de dados, mas também ao longo da pós-graduação.

Aos amigos da Silvicultura, Kellen, Rodrigo, Marcone, Brígida, Natane, Cibele e Antônio, pelos momentos de descontração. Em especial à Luciana e Ricardo, pelo incentivo constante e, principalmente, por toda ajuda, até mesmo montando aula para concurso durante a madrugada.

Aos amigos da pós-graduação, por compartilhar a rotina diária de estudo. Ao Reginaldo pelos conselhos e exemplo de determinação; ao Álvaro, Denise, Erlon, Cris, Breda, por tornarem os almoços do RU mais agradáveis e os dias na salinha da pós-graduação mais alegres. Ao Artur e Adriana, por escutarem os desabafos e pelo incentivo nos momentos de desânimo. Ao Caio, pela positividade de sempre, inúmeras conversas e torcida nos concursos (com direito a água benta).

Ao Sérgio, pela ajuda no inglês, amizade e reflexões sobre a vida.

Às amigas de república, Lívia, Cássia, Larissa, Gabi, e calouras, por se tornarem minha família em Viçosa e por aguentaram as oscilações de humor durante a minha trajetória na pós-graduação.

Aos amigos de sempre, “Tias da Anaterra”, Maíra, Máxima, Mariana, Mayara, Helena, Denise, Pedro, João, Bruno, Lori, Naiara, pelas inúmeras conversas construtivas, por me apoiarem e vibrarem com minhas conquistas.

Ao Guilherme (Pexe), por toda ajuda, pelos inúmeros cafés e chocolates compartilhados, por se encaixar em todos os exemplos mencionados de amizade, e por me aturar quase que diariamente (sei que não é fácil).

Aos professores do DEF, pelos ensinamentos e aos funcionários do DEF, pela prestatividade (sempre). Em especial ao Chiquinho, pelas conversas e alegria contagiante, e ao Dilson, Alexandre e Rita, pela disposição em nos ajudar.

Aos funcionários da empresa Gerdau pela disponibilidade em tirar minhas dúvidas em relação ao banco de dados, e à empresa pela disponibilização do mesmo.

Ao Luciano, que, mesmo sem me conhecer, se disponibilizou em ajudar com o banco de dados climáticos.

Ao professor Júlio, pela orientação, sugestões e disponibilidade em participar desse trabalho.

Ao professor e coorientador Helio, pela constante ajuda desde a graduação, sempre com bom humor, fazendo sugestões, correções e questionamentos que estimulam o pensamento crítico.

Ao professor e orientador Haroldo, pelos (quase) seis anos de dedicação, confiança, e, sobretudo, paciência. Principalmente, pelo apoio nos momentos de problemas familiares, por enxergar soluções quando eu só via problemas, pelos inúmeros conselhos e críticas construtivas, enfim, por realmente me orientar.

À banca examinadora pela disposição em ler e participar do meu trabalho.

À CAPES, pela concessão da bolsa e à UFV que possibilitou a realização de muitos sonhos.

A todos que me ajudaram, direta ou indiretamente, a concretizar essa etapa. Ninguém constrói nada sozinho. GRATIDÃO!

“E aprendi que se depende sempre
De tanta, muita, diferente gente
Toda pessoa sempre é as marcas
Das lições diárias de outras tantas pessoas

E é tão bonito quando a gente entende
Que a gente é tanta gente onde quer que a gente vá
E é tão bonito quando a gente sente
Que nunca está sozinho por mais que pense estar

É tão bonito quando a gente pisa firme
Nessas linhas que estão nas palmas de nossas mãos
É tão bonito quando a gente vai à vida
Nos caminhos onde bate, bem mais forte o coração”

Gonzaguinha

BIOGRAFIA

Eliane Cristina Sampaio de Freitas, filha de Elson de Freitas e Maria da Piedade Sampaio Freitas, nasceu em 21 de junho de 1988, em Curvelo, Minas Gerais. Concluiu o Ensino Médio em Curvelo, na Escola Estadual Bolivar de Freitas, em 2005.

Em 2007, iniciou o curso de Engenharia Florestal, na Universidade Federal de Viçosa, sendo o mesmo concluído em dezembro de 2011. Em fevereiro de 2012, iniciou o mestrado em Ciência Florestal na mesma Instituição, concluindo-o em julho de 2013.

Em agosto de 2013, iniciou o Programa de Pós-Graduação em Ciência Florestal, em nível de doutorado, na área de Silvicultura, na Universidade Federal de Viçosa, Viçosa, MG.

SUMÁRIO

RESUMO	ix
ABSTRACT	xi
INTRODUÇÃO	1
REFERÊNCIAS BIBLIOGRÁFICAS	4
OBJETIVOS.....	8
CAPÍTULO 1: Fundamentação teórica.....	9
1. REDES NEURONAIS ARTIFICIAIS	9
1.1. Neurônio artificial	11
1.2. Função de ativação.....	13
1.3. Arquitetura e topologia da RNA	16
1.4. Treinamento de uma RNA	21
1.5. Algoritmos de treinamento.....	28
1.6. Capacidade de generalização de uma rede neuronal artificial	34
1.7. Referências bibliográficas.....	34
2. FATORES QUE INFLUENCIAM O CRESCIMENTO E A PRODUTIVIDADE FLORESTAL	37
2.1. Introdução	37
2.2. Fatores ambientais.....	37
2.3. Fatores bióticos	43
2.4. Genótipo.....	45
2.5. Práticas silviculturais e manejo.....	46
2.6. Referências bibliográficas.....	51
CAPÍTULO 2: Redes neuronais artificiais para estimação da produtividade de eucalipto em função do genótipo, fatores ambientais e práticas silviculturais.....	57
1. INTRODUÇÃO.....	57
2. MATERIAL E MÉTODOS	59
3. RESULTADOS.....	66
4. DISCUSSÃO.....	70
5. CONCLUSÕES.....	75
6. REFERÊNCIAS BIBLIOGRÁFICAS	75
CAPÍTULO 3: Importância das variáveis preditoras na estimação da produtividade de eucalipto através de redes neuronais artificiais.....	79
1. INTRODUÇÃO.....	79
2. MATERIAL E MÉTODOS	81

3. RESULTADOS.....	84
4. DISCUSSÃO.....	89
5. CONCLUSÕES.....	93
6. REFERÊNCIAS BIBLIOGRÁFICAS	93
CONCLUSÕES GERAIS	97
ANEXOS.....	98

RESUMO

FREITAS, Eliane Cristina Sampaio de, D.Sc., Universidade Federal de Viçosa, julho de 2017. **Modelagem da produtividade de eucalipto por meio de redes neurais artificiais.** Orientador: Haroldo Nogueira de Paiva. Coorientadores: Helio Garcia Leite e Júlio César Lima Neves.

A produtividade florestal é influenciada por diversos fatores, e apesar de ser fácil enumerá-los, é extremamente complexo o entendimento da influência de suas interações no crescimento e desenvolvimento das plantas. Por permitir modelar relações complexas e não-lineares, as redes neurais artificiais (RNA) têm sido muito utilizadas em estudos sobre a produtividade florestal. Nesse sentido, o objetivo desse trabalho foi configurar, treinar e validar RNA para estimar a produtividade de povoamentos de eucalipto em função de variáveis ambientais, genótipo e práticas silviculturais, e avaliar quais são as variáveis preditoras mais importantes e como elas afetam a produtividade do eucalipto. Para isso foram utilizados dados de inventário florestal contínuo (IFC) de 507 talhões de eucalipto pertencentes à Gerdau, em Minas Gerais, compostos por diferentes genótipos e espaçamentos. Também foram utilizados dados de análise de solo desses talhões, fertilizações realizadas ao longo da rotação, e variáveis climáticas. Redes do tipo Perceptron de Múltiplas Camadas (MLP) foram treinadas para estimar o incremento médio anual de povoamentos de eucalipto aos seis anos de idade (IMA6), alterando as variáveis de entrada, número de neurônios na camada oculta, algoritmos de treinamento (Backpropagation, Resilient Propagation (Rprop+) e Quick Propagation), porcentagem de dados nos subconjuntos de treino e validação, e as funções de ativação (logística, tangente hiperbólica, linear) na camada intermediária (exceto a linear) e de saída. Para avaliar a importância das variáveis preditoras na estimativa da RNA, foram utilizados apenas os dados do clone (GG100) mais plantado pela empresa Gerdau e treinadas redes (algoritmo Rprop+ e função de ativação logística na camada oculta e de saída) para estimar o IMA6 em função do espaçamento, teor de argila, temperatura, precipitação pluviométrica total (considerando os seis anos da rotação mais dois anos anteriores ao plantio) e fertilizações realizadas. Para a rede selecionada, considerando-se a correlação entre o IMA6 estimado e observado ($r_{y\hat{y}}$) e a raiz quadrada do erro quadrático médio (REQM), foram utilizadas as seguintes metodologias para avaliar a influência das variáveis preditoras nas estimativas da rede: Diagrama de Interpretação Neuronal (NID), algoritmos de Olden e de Garson, Lekprofile, e Análise de Sensibilidade Global. Para a primeira etapa foram obtidas redes com $r_{y\hat{y}}$ maior que 85 % e REQM menor que

15 % na validação. Todas as redes foram obtidas com o Rprop+ utilizando a função logística, tanto na camada oculta (6 a 8 neurônios) como na de saída, e utilizando 90 % dos dados para o treinamento. A utilização de RNA possibilitou a estimação do IMA6 de povoamentos de eucalipto com boa precisão, apesar da complexidade dos dados, e inclusão de inúmeras variáveis, até mesmo categóricas. Entre as variáveis explicativas, o genótipo, espaçamento, as características edáficas: argila, matéria orgânica e CTC, as características climáticas: precipitação pluviométrica, temperatura e déficit hídrico, e a fertilização tiveram maior influência na produtividade do eucalipto ao final da rotação. Em relação às metodologias usadas para avaliar a importância das variáveis preditoras na resposta da RNA, o método Lekprofile apresentou melhores resultados, uma vez que foram mais condizentes com a resposta biológica esperada. A precipitação pluviométrica total foi a variável que apresentou maior importância na estimação do IMA6 de povoamentos do clone GG100 para a RNA selecionada, e seu aumento resultou em maior IMA6 independentemente dos valores dos outros fatores. O oposto foi observado para a adubação nitrogenada. A utilização de RNA possibilita a modelagem da produtividade de povoamentos de eucalipto com boa precisão, e a não utilização de variáveis dendrométricas como preditoras pode ajudar o gestor florestal a tomar decisões em locais onde não existem dados de IFC ou que não existem plantios de eucalipto, além de possibilitar uma melhor avaliação de como os fatores ambientais, genótipo e práticas silviculturais influenciam a produtividade florestal.

ABSTRACT

FREITAS, Eliane Cristina Sampaio de, D.Sc., Universidade Federal de Viçosa, July, 2017. **Modeling of eucalyptus productivity by artificial neural networks.** Adviser: Haroldo Nogueira de Paiva. Co-advisers: Helio Garcia Leite and Júlio César Lima Neves.

Although it is easy to enumerate the several factors that influence forest productivity, their interactions on plant growth and development are extremely complex. Artificial neural networks (ANN) have been widely used to understand forest productivity due to their ability to model complex and nonlinear relationships. This study aimed to configure, train and validate ANN to estimate the productivity of eucalyptus stands as a function of environmental factors, genotype and forestry practices. Other objective was evaluating what are the most important predictors and how they affect eucalyptus productivity. The dataset was from a continuous forest inventory (CFI) from 507 eucalyptus stands, composed by different genotype and spacing, belonging to the Gerdau company in Minas Gerais. Information about soil analysis, fertilizations and climatic variables were also used. ANN were trained to estimate the mean annual increment of eucalyptus stands at six years of age (MAI6). Multilayer Perceptron (MLP) networks were trained by altering the input variables, number of neurons in the hidden layer, training algorithms (Backpropagation, Resilient Propagation (Rprop+) and Quick Propagation), percentage of data in training and validation subsets, and activation function (logistic, hyperbolic tangent, linear) in the intermediate (except linear) and output layers. Only the dataset of the clone (GG100) most planted by the Gerdau company was used to train neural networks (Rprop+ algorithm and logistic activation function in hidden and output layers) to evaluate the importance of independent variables in the ANN response. This trained ANN estimates the MAI6 as a function the spacing, clay content, temperature, fertilization and total rainfall (considering the six years of rotation and two years before planting). The ANN was selected according to the correlation between estimated and observed MAI6 ($r_{y\hat{y}}$) and root mean square error (RMSE) and the following methodologies were applied to evaluate the importance of the predictor variables: Neuronal Interpretation Diagram, Olden and Garson algorithms, Lekprofile and Global Sensitivity Analysis. In first step of this study, neural networks with $r_{y\hat{y}}$ greater than 85 % and RMSE less than 15 % were obtained in the validation. All ANNs were obtained with Rprop+ algorithm, logistic function in hidden (6 to 8 neurons) and input layers, using 90 % of the dataset for their training. The use of ANN allowed the MAI6 estimation of eucalyptus stands with good precision, despite the complexity of the dataset and inclusion of many variables, even

categorical ones. Among the explanatory variables, the genotype, spacing, the edaphic characteristics: clay, organic matter and cation exchange capacity - CEC, the climatic characteristics: rainfall, temperature and water deficit, and fertilization had great influence on forest productivity at the end of rotation. In relation to the methodologies chosen to evaluate the importance of predictor variables, the Lekprofile method presented better results, since they were more compatible with the expected biological response. The total rainfall was the most important variable in the MAI6 estimation for stands of eucalyptus clone (GG100) by the selected neural network. Forest productivity estimation, without considering the dendrometric data as predictor variables, may help in decisions where there are no CFI datasets or eucalyptus stands, besides making possible the best evaluation of how the environmental factors, genotype and forestry practices influence forest productivity.

INTRODUÇÃO

A atividade florestal tem grande importância na economia brasileira, especialmente a parte que tem a eucaliptocultura como base. O gênero *Eucalyptus* tem sido utilizado em larga escala nos projetos florestais no Brasil devido a sua adaptação a distintas condições edafoclimáticas, seu crescimento rápido, sua ampla utilização e conhecimento das práticas silviculturais. Em 2008, o GIT Forestry Consulting contabilizava 19.609.670 hectares de eucalipto plantados no mundo, sendo que mais da metade da área de plantio estava concentrada na Índia (22 %), Brasil (20 %) e China (14 %). Atualmente, essa área já passa dos 20 milhões de hectares.

O aumento da demanda por produtos florestais, ao mesmo tempo em que a disponibilidade de terra tem se tornado mais escassa, sinaliza a necessidade de aumentar a produtividade florestal, sem aumentar a área plantada, o que requer melhor conhecimento dos fatores que influenciam o crescimento e o desenvolvimento florestal.

O crescimento arbóreo é influenciado por diversos fatores intrínsecos e extrínsecos, como genótipo e condições do sítio: clima (temperatura, precipitação, vento, insolação e nutrientes), solo (características físicas, químicas e biológicas), fisiografia (inclinação, altitude e exposição) (ZANON e FINGER, 2010; MARTINKOSKI et al., 2015). Nas regiões tropicais, a produtividade florestal potencial, definida pela qualidade do material genético, se dará quando os fatores água, nutrientes e as características físicas do solo não forem limitantes (BORGES, 2012).

A produtividade florestal e os fatores que a influenciam têm sido objetivo de muitos estudos (FERRAZ, 1993; LEITE et al., 1999; BRAGA et al., 1999; STAPE et al., 2004; FARIA et al., 2008; GAVA e GONÇALVES, 2008; OLIVEIRA et al., 2011; LAFETÁ, 2012; OTTO et al., 2013; CAMPOE et al., 2013; GONÇALVES et al., 2014; ALCÂNTARA, 2015; GADELHA et al., 2015; JESUS et al., 2015; PULITO et al., 2015; ROCHA et al., 2015; MEDEIROS, 2016; SILVA et al., 2016). Entretanto, muitos trabalhos consideram poucas variáveis que afetam a produção florestal, uma vez que isolar o efeito dessas em campo é extremamente difícil, assim como avaliar a influência da interação delas no crescimento e desenvolvimento das plantas.

A crescente necessidade de conhecimento sobre a situação dos povoamentos, bem como sua dinâmica, tem conduzido a um contínuo aprimoramento das técnicas para estimar a produtividade florestal (BERGER et al., 2002). Para a modelagem envolvendo inúmeras

variáveis, inclusive categóricas, com relações não-lineares e complexas, têm sido utilizadas redes neurais artificiais (RNA). São diversas as aplicações das RNA na área florestal, como classificação e mapeamento das florestas, modelagem do crescimento florestal, análise de dados espaciais, análise da dinâmica de doenças de plantas, e mudança climática (HILBERT e OSTENDORF, 2001; OZÇELIK et al., 2010; LEITE et al., 2011; HICKEY et al., 2015; BINOTI et al., 2015; BHERING et al., 2015; SILVA RIBEIRO et al., 2016; ZANUNCIO et al., 2016; CAMPOS et al., 2016; MARTINS et al., 2016; VAHEDI, 2017).

A RNA é um sistema computacional paralelo composto por vários elementos de processamento simples (neurônios artificiais) conectados entre si de uma maneira específica para executar uma determinada tarefa (BULLINARIA, 2014). As conexões dos neurônios estão associadas a pesos, e o ajuste deles é realizado por um processo chamado treinamento, que é responsável pela extração das características dos dados e armazenamento de conhecimento das redes (BINOTI, 2012).

As RNA são mais precisas que outras técnicas estatísticas, particularmente quando o problema abordado é complexo ou mal compreendido, não exigem conhecimento prévio do processo a ser modelado ou da função alvo, e podem ser incluídas inúmeras variáveis quantitativas e qualitativas, características que as tornam uma ferramenta muito flexível e poderosa (PENG e WEN, 1999). Entretanto, segundo Leite et al. (2011), as redes apresentam algumas limitações como: o modelo gerado não possui fácil interpretação, dificultando a avaliação da influência das variáveis preditoras na resposta da rede; é difícil definir a arquitetura ideal da rede, pois não existem regras para definir o número de neurônios em cada camada ou o número de camadas; e não há garantia de convergência do algoritmo para uma solução ideal. No entanto, tais limitações não impedem o uso dessa técnica, e a maioria delas pode ser contornada, por exemplo, a definição da arquitetura da rede pode ser facilitada pela utilização de validação cruzada (SILVA et al., 2010) e NEAT (Neuroevolution of Augmenting Topologies) (MUNIZ e NEVES, 2015). Em relação à convergência, existem algoritmos de treinamento disponíveis que retornam boas soluções.

Em relação à explicação da contribuição das variáveis preditoras na resposta da rede, assim como o entendimento das suas inter-relações, algumas metodologias têm sido propostas, como a inversão de redes (DUA e GUPTA, 2000), métodos baseados em pesos (Olden e Garson), que retornam a importância das variáveis preditoras, e o método Lekprofile, que possibilita observar o comportamento e a influência das variáveis preditoras na resposta da rede (OLDEN e JACKSON, 2002).

Dua e Gupta (2000) citam a inversão de redes, que implica descobrir os valores das entradas (variáveis independentes) que fornecem uma determinada saída, como um método potencial para gerenciar recursos de modo a garantir um resultado desejado. De acordo com esses autores, a inversão de redes pode ser modelada como um problema de otimização, utilizando programação não-linear, por exemplo. Entretanto, não existem trabalhos de inversão de redes na área florestal.

Beck (2015) cita dois algoritmos, Garson e Olden, para definir a importância das variáveis preditoras na estimativa da rede. Esses algoritmos levam em consideração os pesos das conexões entre os neurônios das camadas entrada-oculta e oculta-saída para cada neurônio da camada de entrada e da camada oculta. Gevrey et al. (2003) analisaram algumas metodologias para verificar a importância das variáveis preditoras e observaram que tanto os métodos baseados nos pesos e o *stepwise*, que só fornecem o grau de importância das variáveis, quanto os métodos que possibilitam observar o comportamento e a influência das variáveis preditoras na resposta da rede, possuem boa classificação, mas apresentam algumas limitações, por exemplo, a maior instabilidade dos métodos baseados nos pesos. Esses autores enfatizam que ao utilizar essas metodologias, o conhecimento em relação ao problema deve ser levado em consideração para avaliar a capacidade de ranqueamento do método usado.

Apesar da existência dessas metodologias, que possibilitam avaliar o comportamento e a influência das variáveis preditoras na resposta da RNA, não existem trabalhos na área florestal sobre a avaliação delas.

REFERÊNCIAS BIBLIOGRÁFICAS

- ALCÂNTARA, A.E.M. **Redes neurais artificiais para prognose do crescimento e da produção de povoamentos de eucalipto em Minas Gerais**. 2015. 43f. Tese (Doutorado em Ciência Florestal) - Universidade Federal de Viçosa, Viçosa, MG, 2015.
- BERGER, R.; SCHNEIDER, P.R.; FINGER, C.A.G.; HASELEIN, C.R. Efeito do espaçamento e da adubação no crescimento de um clone de *Eucalyptus saligna* Smith. **Ciência Florestal**, v.12, n.2, p.75-87, 2002.
- BECK, M.W. **NeuralNetTools: Visualization and Analysis Tools for Neural Networks**. R Foundation for Statistical Computing, 2015. R Package.
- BHERING, L. L.; CRUZ, C. D.; PEIXOTO, L. D. A.; ROSADO, A. M.; LAVIOLA, B. G.; NASCIMENTO, M. Application of neural networks to predict volume in eucalyptus. **Crop Breeding and Applied Biotechnology**, v.15, n.3, p.125-131, 2015.
- BINOTI, M.L.M.S. **Emprego de redes neurais artificiais em mensuração e manejo florestal**. 2012. 130 f. Tese (Doutorado em Ciência Florestal) - Universidade Federal de Viçosa. 2012.
- BINOTI, M.L.M.S.; LEITE, H.G.; BINOTI, D.H.B.; GLERIANI, J.M. Prognose em nível de povoamento de clones de eucalipto empregando redes neurais artificiais. **Cerne**, v. 21, n. 1, p. 97-105, 2015.
- BORGES, J.S. **Modulador edáfico para uso em modelo ecofisiológico e produtividade potencial de povoamentos de eucalipto**. 70f. 2012. Tese (Doutorado em Solos e Nutrição de Plantas) – Universidade Federal de Viçosa, 2012.
- BRAGA, F.A.; BARROS, N. F.; SOUZA, A. L.; COSTA, L. M. Características ambientais determinantes da capacidade produtiva de sítios cultivados com eucalipto. **Revista Brasileira de Ciência do Solo**, v.23, n., p.291-298, 1999.
- BULLINARIA, J. A. **Introduction to Neural Computation**. Notas de aula. 2014. Disponível em: <<http://www.cs.bham.ac.uk/~jxb/inc.html>>. Acesso em: 27 de maio de 2015.
- CAMPOE, O.T.; STAPE, J.L.; ALBAUGH, T.J.; ALLEN, H.L.; FOX, T.R.; RUBILAR, R.; BINKLEY, D. Fertilization and irrigation effects on tree level aboveground net primary production, light interception and light use efficiency in a loblolly pine plantation. **Forest Ecology and Management**, v.288, p.43–48, 2013.
- CAMPOS, B. P. F.; DA SILVA, G. F.; BINOTI, D. H. B.; DE MENDONÇA, A. R.; LEITE, H. G. Predição da altura total de árvores em plantios de diferentes espécies por meio de redes neurais artificiais. **Pesquisa Florestal Brasileira**, v.3, n.88, p.375-385, 2016.
- DUA, A., GUPTA, A. **Inversion of Neural Networks: A Solution to the Problems Encountered by a Steel Corporation**. 2000. Disponível em: <http://web.mit.edu/profit/PDFS/DuaA.pdf>. Acesso em: 10 de abril de 2017.
- FARIA, G. E.; BARROS, N. F.; CUNHA, V. L. P.; MARTINS, I. S.; MARTINS, R. D. C. C. Avaliação da produtividade, conteúdo e eficiência de utilização de nutrientes em genótipos de

Eucalyptus spp. no vale do Jequitinhonha, MG. **Ciência Florestal**, v. 18, n. 3, p. 363-373, 2008.

FERRAZ, E.S.B. A influência da precipitação na produção de matéria seca de eucaliptos. **IPEF**, n.46, p.32-42, 1993.

GADELHA, F. H.L.; DA SILVA, J. A. A.; FERREIRA, R. L. C.; DOS SANTOS, R. C.; TAVARES, J. A. Produtividade de clones de eucaliptos em diferentes sistemas de manejo para fins energéticos. **Pesquisa Florestal Brasileira**, v.35, n.83, p.263-270, 2015.

GAVA, J. L.; GONÇALVES, J.L.M. Soil attributes and wood quality for pulp production in plantations of *Eucalyptus grandis* clone. **Scientia Agricola**, v.65, n.3, p.306-313, 2008.

GIT Forestry Consulting. Eucalyptus Global Map 2008: cultivated forests worldwide. Disponível em: <http://git-forestry-blog.blogspot.com/2008/09/eucalyptus-global-map-2008-cultivated.html>. Acesso em: 23 de outubro de 2016.

GEVREY, M.; DIMOPOULOS, I.; LEK, S. Review and comparison of methods to study the contribution of variables in artificial neural network models. **Ecological modelling**, v. 160, n. 3, p. 249-264, 2003.

GONÇALVES, J. L. D. M.; ALVARES, C. A.; BEHLING, M.; ALVES, J. M.; PIZZI, G. T.; ANGELI, A. Produtividade de plantações de eucalipto manejadas nos sistemas de alto fuste e talhadia, em função de fatores edafoclimáticos. **Scientia Forestalis**, v. 42, n. 103, p. 411-419, 2014.

HICKEY, C.; KELLY, S.; CARROLL, P.; O'CONNOR, J. Prediction of forestry planned end products using dirichlet regression and neural networks. **Forest Science**, v.61, n.2, p.289-297, 2015.

HILBERT, D. W; OSTENDORF, B. The utility of artificial neural networks for modelling the distribution of vegetation in past, present and future climates. **Ecological modelling**, v.146, n.1, p.311-327, 2001.

JESUS, G. L.; SILVA, I.R.; ALMEIDA, L. F.J.; SANTOS, M.A.; LEITE, F.P.; NEVES, J. C.L. produtividade do eucalipto, atributos físicos do solo e frações da matéria orgânica influenciadas pela intensidade de tráfego e resíduos de colheita. **Revista Brasileira de Ciência do Solo**, v. 39, n. 4, p. 1190-120, 2015.

LAFETÁ, B. O. **Eficiência nutricional, área foliar e produtividade de plantações de eucalipto em diferentes espaçamentos estimados com redes neurais artificiais**. 2012.76f. Dissertação (Mestrado em Ciência Florestal) - Universidade Federal dos Vales do Jequitinhonha e Mucuri,2012.

LEITE, F. P.; BARROS, N. F.; NOVAIS, R. F.; SANS, L. M. A.; FABRES, A. S. Relações hídricas em povoamento de eucalipto com diferentes densidades populacionais. **Revista Brasileira de Ciência do Solo**, v. 23, n. 1, p. 9–16, 1999.

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

- MARTINKOSKI, L.; VOGEL, G. F.; JADOSKI, S. O. Influência do clima no crescimento diamétrico de *Araucaria angustifolia*: revisão bibliográfica. **Revista Brasileira de Tecnologia Aplicada nas Ciências Agrárias**, v. 8, n. 2, p.104-111, 2015.
- MARTINS, E.R.; BINOTI, M. L. M.S.; LEITE, H. G.; BINOTI, D. H. B.; DUTRA, G. C. Configuração de redes neurais artificiais para estimação da altura total de árvores de eucalipto. **Revista Brasileira de Ciências Agrárias**, v.11, n.2, p.117-123, 2016.
- MEDEIROS, R. A. **Potencial produtivo, manejo e experimentação em povoamentos de *Tectona grandis* Lf no Estado de Mato Grosso**. 2016. 182f. Tese (Doutorado em Ciência Florestal) - Universidade Federal de Viçosa, Viçosa, MG, 2016.
- MUNIZ, A.L.N.; NEVES, C.A.M.S. **Redes Neurais Evolucionárias**. 2015. Disponível em: <https://www.researchgate.net/publication/267297071_Redex_Neurais_Evolucionarias>. Acesso em: 15 de junho de 2017.
- OLDEN, J.D.; JACKSON, D.A. Illuminating the “black box”: a randomization approach for understanding variable contributions in artificial neural networks. **Ecological Modelling**, v.154, p.135–150, 2002.
- OLIVEIRA, B. R. U.; DE FIGUEIREDO LATORRACA, J. V.; TOMAZELLO FILHO, M.; GARCIA, R. A.; DE CARVALHO, A. M. Correlações dendroclimatológicas do *Eucalyptus grandis* Hill ex Maiden na região de Rio Claro, RJ. **Ciência Florestal**, v.21, n.3, p.499-508, 2011.
- OTTO, M.S.G.; VERGANI, A.R.; GONÇALVES, A.N.; VRECHI, A.; SILVA, S.R.; E STAPE, J.L. Fotossíntese, condutância estomática e produtividade de clones de *Eucalyptus* sob diferentes condições edafoclimáticas. **Revista Árvore**, v.36, v.37, n.3, p.431-439, 2013.
- OZÇELIK, R.; DIAMANTOPOULOU, M. J.; BROOKS, J. R.; WIANT, H. V. Estimating tree bole volume using artificial neural network models for four species in Turkey. **Journal of environmental management**, v.91, n.3, p.742-753, 2010.
- PENG, C.; WEN, X. **Recent applications of artificial neural networks in forest resource management: an overview**. 1999. Disponível em: <https://vww.aaai.org/Papers/Workshops/1999/WS-99-07/WS99-07-003.pdf>. Acesso em 15 de março de 2016.
- PULITO, A. P.; GONÇALVES, J.L.M.; SMETHURST, P.J.; ARTHUR JUNIOR, J.C.; ALVARES, C.A.; ROCHA, J.H.T.; HÜBNER, A.; MORAES, L.F.; MIRANDA, A.C.; KAMOGAWA, M.Y.; GAVA, J.L.; CHAVES, R.; SILVA, C.R. Available nitrogen and responses to nitrogen fertilizer in Brazilian eucalypt plantations on soils of contrasting texture. **Forests**, v.6, n.4, p.973-991, 2015.
- ROCHA, S. P.; PREVEDELLO, J.; REINERT, D. J.; FLEIG, F. D.; VOGELMANN, E. S.; SOARES, J. C. W.; HEINZ, B. B. Propriedades físicas do solo e crescimento de eucalipto implantado em diferentes métodos de preparo do solo. **Scientia Forestalis**. v. 43, n. 108, p. 965-977, 2015.
- SILVA, I. N.; SPATTI, H. D.; FLAUZINO, R. A. **Redes Neurais Artificiais: para engenharia e ciências aplicadas**. São Paulo: Artliber, 399 p. 2010.

SILVA, R.M.L.; HAKAMADA, R.E.; BAZANI, J.H.; OTTO, M.S.G.; STAPE, J.L. Fertilization response, light use, and growth efficiency in *Eucalyptus* plantations across soil and climate gradients in Brazil. **Forests**, v.7, n.117, p.1-12, 2016.

SILVA RIBEIRO, R. B.; GAMA, J. R. V.; SOUZA, A. L.; LEITE, H. G.; SOARES, C. P. B.; SILVA, G. F. Métodos para estimar o volume de fustes e galhos na Floresta Nacional do Tapajós. **Revista Árvore**, v.40, n.1, p.81-88, 2016.

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**, v.193, p.17–31, 2004.

VAHEDI, A. A. Monitoring soil carbon pool in the Hyrcanian coastal plain forest of Iran: Artificial neural network application in comparison with developing traditional models. **Catena**, v.152, p.182-189, 2017.

ZANON, M.L.B.; FINGER, C.A.G. Relação de variáveis meteorológicas com o crescimento das árvores de *Araucaria angustifolia* (Bertol.) Kuntze em povoamentos implantados. **Ciência Florestal**, v. 20, n. 3, p. 467-476, 2010.

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

OBJETIVOS

Configurar, treinar e validar redes neurais artificiais para estimar a produtividade de povoamentos de eucalipto em Minas Gerais em função de variáveis ambientais, genótipo e práticas silviculturais.

Avaliar quais são as variáveis preditoras mais importantes e como elas influenciam a produtividade do eucalipto.

CAPÍTULO 1: FUNDAMENTAÇÃO TEÓRICA

1. Redes Neurais Artificiais

As Redes Neurais Artificiais (RNA) são procedimentos computacionais inspirados no cérebro humano, sendo aproximações simplificadas e imperfeitas do mesmo (BULLINARIA, 2014). Uma RNA é um sistema computacional composto por várias unidades de processamento simples (neurônios artificiais), distribuídas paralelamente e conectadas entre si de uma maneira específica para executar uma determinada tarefa (HAYKIN, 2001; BULLINARIA, 2014). Essas conexões estão associadas a pesos, e o ajuste deles é realizado por um processo chamado treinamento ou aprendizado, que extrai as características dos dados e armazena o conhecimento nas redes (BINOTI, 2012).

RNA são caracterizadas pelo paralelismo massivo, responsável pelo seu desempenho e eficiência; capacidade de aprender e generalizar, possibilitando a resolução de problemas complexos; tolerância a falhas e ruídos; adaptabilidade, uma rede tem capacidade de adaptar seus pesos a modificações do ambiente; e analogia neurobiológica (HAYKIN, 2001; BULLINARIA, 2014).

Entre as aplicações das redes neurais artificiais (Quadro 1; Figura 1), destaca-se a aproximação de funções, utilizada nas situações em que existe relação entre as variáveis preditoras e preditas, mesmo que essa relação seja muito complicada. As RNA são capazes de modelar funções extremamente complexas, como funções não-lineares com grande número de variáveis, inclusive as categóricas (STATSOFT, INC, 2007).

Quadro 1 – Áreas de aplicação das redes neurais artificiais

Áreas	Característica
Classificação de padrões	Consiste em associar um padrão de entrada (amostra) a uma das classes pré-definidas.
Agrupamento de dados (clusterização)	Identifica e detecta similaridades e particularidades entre os diversos padrões de entrada a fim de possibilitar seu agrupamento.
Otimização	Consiste em minimizar ou maximizar uma função custo (objetivo) obedecendo a eventuais restrições que são impostas para o correto mapeamento do problema.
Predição	Estima valores futuros de um processo levando em consideração diversas medidas prévias observadas em seu domínio.
Aproximação de função	Consiste em mapear a relação funcional entre variáveis de um sistema a partir de um conjunto conhecido de seus valores representativos.

Memórias associativas (Recuperação de conteúdo)	Recupera padrões corretos mesmo se seus elementos constituintes forem apresentados de forma incorreta ou imprecisa.
---	---

Adaptado de Silva (2010).

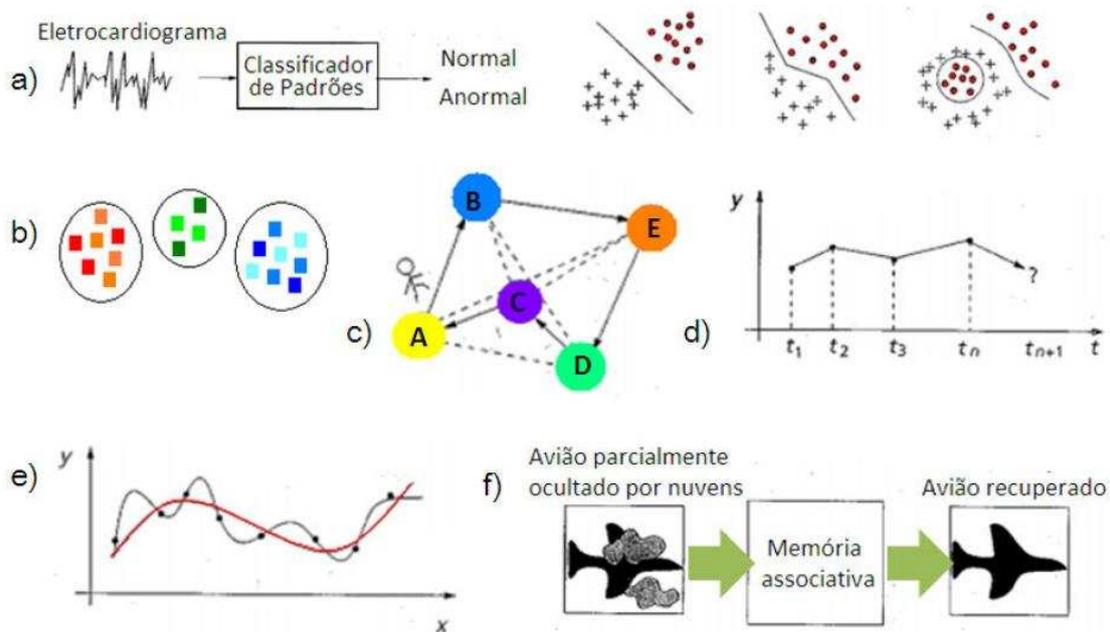


Figura 1 - Tarefas da aprendizagem em RNA: a) classificação de padrões, b) agrupamento de dados, c) otimização, d) predição (séries temporais), e) aproximação de função e f) recuperação de conteúdo (Fonte: JAIN et al., 1996, citado por BINOTI, 2010).

As RNA podem ser mais acuradas que outras técnicas estatísticas, particularmente quando o problema é mal compreendido, não sendo necessário o conhecimento a priori da função que será ajustada (PENG e WEN, 1999). Ou seja, a rede neuronal artificial é uma ferramenta matemática que não necessita de suposições sobre as relações entre as variáveis utilizadas no ajuste, em vez disso, a rede é treinada e se encarrega de modelar as relações lineares e não lineares existentes (HAYKIN, 2001; VON ZUBEN e DE CASTRO, 2001; BINOTI, 2012). Entretanto, é importante que seja conhecido ou que pelo menos se suspeite que exista uma relação entre as entradas e as saídas para que não se utilize variáveis que não explicam o modelo.

Algumas pesquisas na área florestal mostram o melhor desempenho das RNA em comparação aos modelos de regressão (OZÇELIK et al., 2010; DIAMANTOPOULOU, 2012; BHERING et al. 2015; SILVA RIBEIRO et al., 2016; VAHEDI, 2017). As variáveis categóricas (classe de solo, textura, espaçamento, relevo, clone, por exemplo) que interferem no volume das árvores apresentam, na maioria das vezes, relações complexas e tendências não

lineares, dificultando o ajuste de modelos volumétricos com a inclusão delas (BINOTI, 2012). Nesse sentido, a utilização de RNA se torna apropriada nessas situações.

A solução do problema inicia-se com o treinamento, quando dados representativos são apresentados à rede e algoritmos de treinamento são utilizados para aprender automaticamente a estrutura dos dados, ou seja, as RNA aprendem pelo exemplo (STATSOFT, INC, 2007). O treinamento extrai características de um determinado problema, sendo capaz de resolvê-lo satisfatoriamente quando novos dados do mesmo tipo de problema são apresentados à rede.

1.1. Neurônio artificial

Um neurônio artificial é a unidade de processamento simples da RNA e baseia-se na estrutura e funcionamento de um neurônio biológico. Similar aos neurônios biológicos, os neurônios artificiais individuais possuem capacidade computacional limitada, entretanto, um conjunto de neurônios artificiais conectados entre si, constituindo uma rede, é capaz de resolver problemas de elevada complexidade (BINOTI, 2012).

O primeiro modelo de neurônio artificial foi desenvolvido por McCulloch e Pitts em 1943, sendo descrito pela propriedade tudo-ou-nada. Segundo Haykin (2001), esse neurônio consistia em uma soma ponderada das entradas e pesos numéricos, que em seguida era submetida a uma função de ativação (função de limiar), onde a saída do neurônio era igual a 1, quando o resultado da função de soma fosse não-negativo, ou 0, caso contrário. Depois, foram desenvolvidos outros modelos, com diferentes funções de ativação, ampliando os usos e potencialidade das RNA.

Um neurônio artificial possui elementos básicos como pesos sinápticos, um somador (combinador linear), função de ativação, e um bias (limiar de ativação) aplicado externamente, que tem a função de aumentar ou diminuir a entrada da função de ativação (Figura 2) (HAYKIN, 2001). Um sinal x_j na entrada é conectado ao neurônio k e multiplicado pelo peso sináptico w_{kj} (k refere-se ao neurônio e j à entrada em que o peso se refere). O somador realiza a soma dos sinais de entrada, ponderados pelos respectivos pesos, e a função de ativação restringe o intervalo ($[0,1]$ ou $[-1,1]$) do sinal de saída de um neurônio a um valor finito.

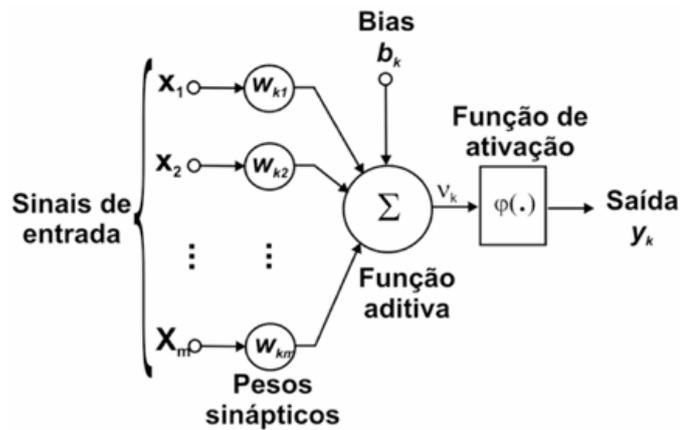


Figura 2 – Modelo de um neurônio artificial (Fonte: HAYKIN, 2001).

Em termos matemáticos, Haykin (2001) descreve um neurônio k da seguinte maneira:

$$u_k = \sum_{j=1}^m w_{kj} x_j$$

$$y_k = \varphi(u_k + b_k)$$

onde x_j são os sinais de entrada, w_{kj} são os pesos sinápticos do neurônio k , u_k é a saída do combinador linear, b_k é o bias, e $\varphi()$ é a função de ativação e y_k é a saída do neurônio.

O bias tem a função de aplicar uma transformação afim à saída u_k , resultando no potencial de ativação (v_k):

$$v_k = u_k + b_k$$

Para facilitar os cálculos, o bias é considerado como um peso, adicionando uma nova entrada (x_0) com um valor fixo (+1), que será associada ao peso $w_{k0} = b_k$ (Figura 3).

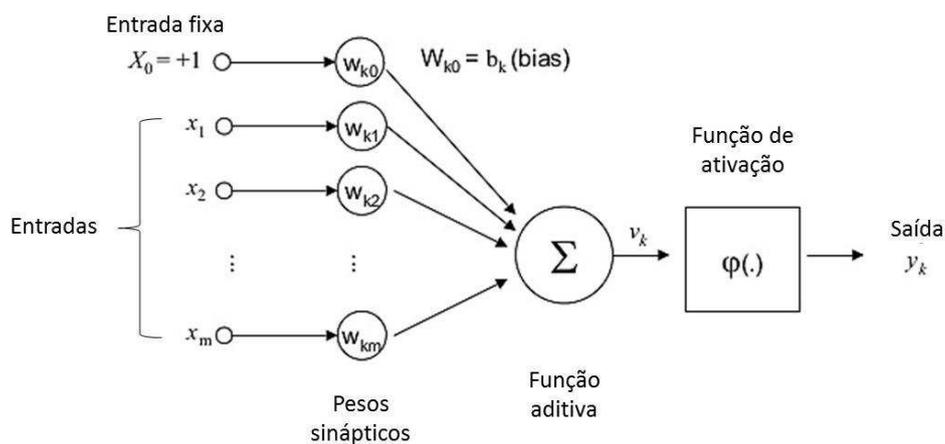


Figura 3 - Modelo de um neurônio com entrada fixa (Fonte: HAYKIN, 2001).

Dessa maneira, a saída do neurônio artificial será:

$$y_k = \varphi(v_k)$$

Em que:

$$v_k = \sum_{j=1}^m w_{kj} x_j$$

Em termos de implementação computacional, é adequado tratar o limiar de ativação do neurônio como um peso sináptico associado a uma entrada fixa, dessa maneira, o limiar torna-se um parâmetro a ser ajustado pelo algoritmo de treinamento da rede e o modelo permanece matematicamente equivalente (BINOTI, 2012).

1.2. Função de ativação

A função de ativação $\varphi(v)$ gera a saída de um neurônio em função do potencial de ativação v e limita a amplitude da saída (HAYKIN, 2001). Esse mesmo autor cita três tipos básicos de funções de ativação: função de limiar, função linear por partes e função sigmoide (Figura 4).

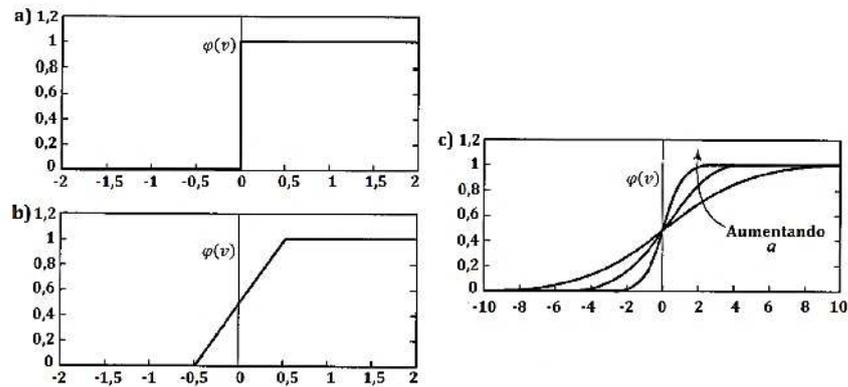


Figura 4 - (a) Função de limiar, (b) função linear por partes, (c) função sigmoide (Fonte: HAYKIN, 2001).

1.2.1. Função de limiar:

Nessa função, a saída de um neurônio pode assumir apenas dois valores, sendo utilizada para problemas que envolvem a classificação de padrões. Na função de limiar, é utilizada a propriedade tudo-ou-nada, onde a saída do neurônio é expressa como:

$$\varphi(v) = \begin{cases} 0 & \text{se } v < 0 \\ 1 & \text{se } v \geq 0 \end{cases}$$

1.2.2. Função linear por partes:

Na função linear por partes tem-se que:

$$\varphi(v) = \begin{cases} 1, & v \geq +0,5 \\ v, & +0,5 > v > -0,5 \\ 0, & v \leq -0,5 \end{cases}$$

1.2.3. Função sigmoide:

A função sigmoide é a função de ativação mais utilizada em RNA. Ela é definida como uma função estritamente crescente que exhibe um balanceamento adequado entre comportamento linear e não linear (HAYKIN, 2001). As funções logística e tangente hiperbólica pertencem às funções sigmóides e são diferenciáveis, ou seja, possuem derivadas de primeira ordem (SILVA et al., 2010).

- Função logística

O resultado de saída terá valores reais entre 0 e 1, e sua expressão matemática é dada por:

$$g(u) = \frac{1}{1 + e^{-\beta u}}$$

sendo $g(u)$ a função de ativação e u o potencial de ativação.

O β é o parâmetro de inclinação da função em relação ao seu ponto de inflexão (Figura 5) (SILVA et al., 2010). Quando o β for muito elevado, a função sigmoide se torna uma função de limiar. Enquanto uma função de limiar assume valores de 0 ou 1, uma função logística assume um intervalo contínuo de valores de 0 a 1 (HAYKIN, 2001).

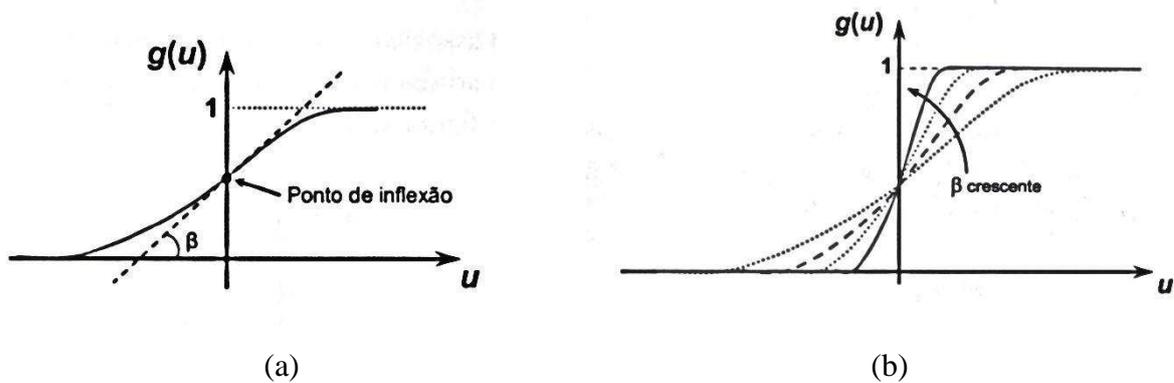


Figura 5- (a) Função de ativação logística, (b) Influência do parâmetro β na função de ativação logística (Fonte: SILVA et al., 2010).

- Função tangente hiperbólica

Essa função possui o intervalo de - 1 a + 1, assumindo nesse caso uma forma antissimétrica ($g(-u) = -g(u)$) em relação à origem (HAYKIN, 2001). Sua expressão matemática é definida por:

$$g(u) = \frac{1 - e^{-\beta u}}{1 + e^{-\beta u}}$$

Assim como na função logística, à medida que a inclinação da função aumenta, a função se aproxima do eixo y (Figura 6). O valor de β varia de acordo com a amplitude do potencial de ativação.

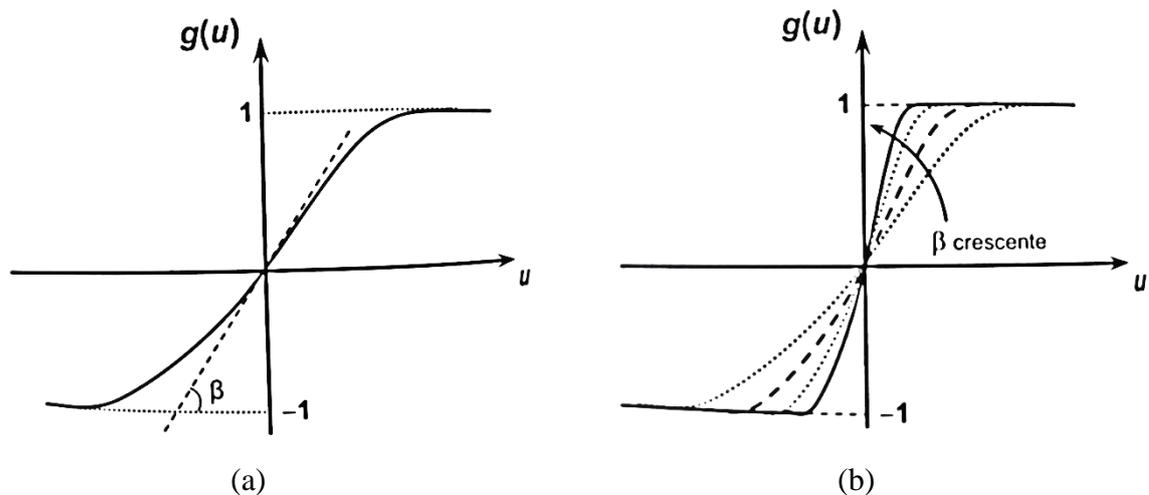


Figura 6- (a) Função de ativação tangente hiperbólica, (b) Influência do parâmetro β na função de ativação tangente hiperbólica (Fonte: SILVA et al., 2010).

1.3. Arquitetura e topologia da RNA

Uma rede neuronal pode ser dividida em três partes: camada de entrada, que recebe as informações do meio externo; camadas intermediárias (oculta ou escondida), compostas por neurônios que extraem as características associadas ao problema a ser resolvido; e camada de saída, responsável por gerar os resultados finais da rede (SILVA et al., 2010). Ressalta-se que apenas os neurônios das camadas ocultas e da camada de saída realizam o processamento dos dados.

A arquitetura de uma rede define a forma que os neurônios estão arranjados em relação aos outros (SILVA et al., 2010), e está relacionada com o algoritmo de treinamento utilizado para treinar a rede (HAYKIN, 2001). Já a topologia da RNA se refere às configurações possíveis em relação ao número de neurônios nas camadas. Em relação ao tipo de conexão entre os neurônios, a rede pode ser *feedforward* (acíclica) ou *feedback* (cíclica), totalmente conectada (todos os nós de uma camada ligados a todos os nós da camada subsequente) ou parcialmente conectada (alguns elos de comunicação faltando na rede) (BRAGA et al., 2000).

1.3.1. Tipos de arquitetura

- Redes *feedforward* de camada única:

Esse tipo de rede possui uma camada de entrada que se projeta em uma camada de saída, mas não vice-versa (Figura 7). Essa rede é chamada de rede de camada única referindo-se a camada de saída que faz o processamento da informação (HAYKIN, 2001).

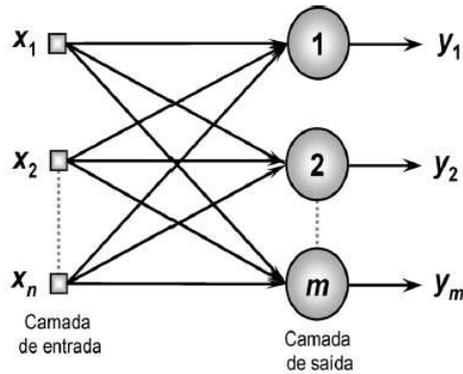


Figura 7 – Exemplo de rede *feedforward* de camada única (Fonte: SILVA et al., 2010)

Essa arquitetura é a mais simples de uma rede neuronal artificial. Segundo Silva et al. (2010) as redes *feedforward* de camada única (Perceptron e Adaline) são geralmente envolvidas em problemas relacionados a classificação de padrões e filtragem linear.

- Redes *feedforward* com múltiplas camadas

Esse tipo de rede possui uma ou mais camadas ocultas (Figura 8). Os sinais de saída da segunda camada são os sinais de entrada da terceira camada e assim sucessivamente. O conjunto de sinais de saída dos neurônios da camada de saída constitui a resposta global da rede para os dados fornecidos na camada de entrada.

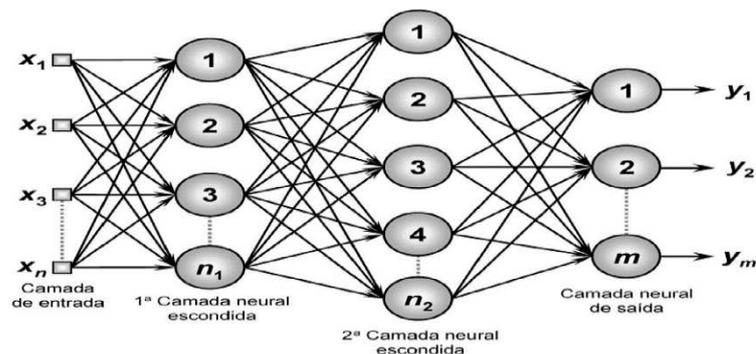


Figura 8 – Exemplo de rede *feedforward* com múltiplas camadas (Fonte: SILVA et al., 2010).

Como exemplo dessa arquitetura tem-se as Perceptron de Múltiplas Camadas (MLP) e as redes de Função de Base Radial (RBF), que são utilizadas para a solução de problemas relacionados à aproximação de função e classificação de padrões, por exemplo (SILVA et al., 2010). A MLP apresenta uma ou mais camadas ocultas, que melhoram a capacidade de solução

de problema, devido ao conjunto extra de conexões sinápticas e à dimensão extra de interações neuronais (BINOTI, 2010).

As redes RBF possuem uma única camada intermediária com um número elevado de neurônios e função de ativação gaussiana, que tem como argumento a distância entre seus vetores de entrada e de peso (BINOTI et al., 2009). A camada oculta aplica uma transformação não linear nas entradas e a camada de saída, que é linear, fornece a resposta da rede (BINOTI, 2010).

- Redes recorrentes

As redes recorrentes possuem pelo menos um laço de realimentação, ou seja, a saída de um neurônio é realimentada para o mesmo neurônio (auto-realimentação) ou para outro (Figura 9), tendo grande impacto na capacidade de aprendizagem da rede e no seu desempenho (HAYKIN, 2001).

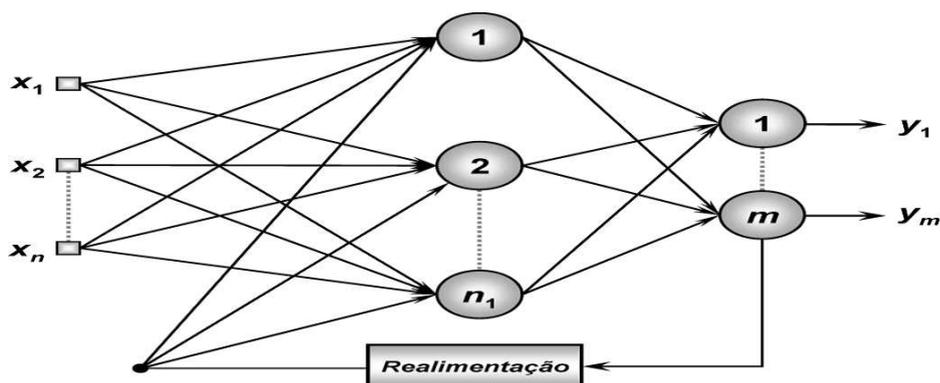


Figura 9 – Exemplo de rede recorrente (Fonte: SILVA et al., 2010).

A característica de realimentação qualifica tais redes para o processamento dinâmico de informações, isto é, elas podem ser utilizadas em sistemas variantes em relação ao tempo, como previsão de séries temporais, otimização e controle de processos (SILVA et al., 2010). Esses autores citam a rede de Hopfield como exemplo de RNA que possui realimentação.

Em comparação com as redes *feedforward*, as redes recorrentes são mais instáveis (STATSOFT, INC, 2007). Essas redes são muito interessantes para os investigadores em RNA, mas até agora é a estrutura de redes *feedforward* que provou ser mais útil na resolução de problemas reais (SILVA et al., 2010).

1.3.2. Escolha da arquitetura e topologia da RNA

Segundo Haykin (2001), não existe uma regra bem definida para determinar a melhor arquitetura e topologia de uma RNA. Isso depende de inúmeras tentativas a fim de gerar resultados satisfatórios, uma vez que esse processo é aleatório, sem nenhum critério para definir o número de neurônios nas camadas ocultas (BINOTI et al., 2009).

Trabalhos anteriores, que utilizaram RNA para resolver problemas semelhantes, podem ser usados para nortear a escolha do número de neurônios na camada oculta, uma vez que o número de neurônios das camadas de entrada e saída são definidos pelo problema. Na maioria dos casos, a rede terá uma única variável de saída, embora existam problemas com um número maior de saídas. Se for definida uma única rede com muitas variáveis de saída, ela pode sofrer *cross-talk*, que é a dificuldade de aprendizagem dos neurônios ocultos por terem que modelar pelo menos duas funções ao mesmo tempo (STATSOFT, INC, 2007).

Assim, o número de camadas ocultas e de neurônios que as redes possuem irá variar de acordo com o problema abordado. A decisão sobre o tamanho da rede que será utilizada implica uma experimentação com diferentes configurações, treinadas mais de uma vez para evitar problemas associados com os mínimos locais, e observar as performances individuais (STATSOFT, INC, 2007).

Uma metodologia utilizada para a definição do número de neurônios na camada oculta é a validação cruzada (Figura 10), cujo objetivo é avaliar a aptidão de cada rede quando aplicada a um conjunto de dados diferente daquele usado no ajuste dos parâmetros internos (SILVA et al., 2010). Para isso, são definidos os subconjuntos de treinamento e teste das topologias candidatas. Primeiramente, é feito o treinamento da rede, e depois é aplicado o subconjunto de teste para avaliar o potencial de generalização de cada topologia. O número ideal de neurônios é aquele que possibilita o menor erro do subconjunto teste (SILVA et al., 2010).

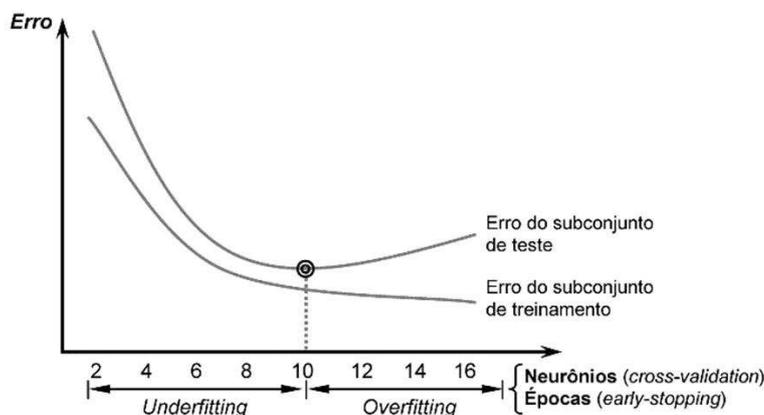


Figura 10 – Validação cruzada para definição de topologia de rede (Fonte: SILVA et al., 2010).

A escolha da topologia através da validação cruzada leva em consideração superar o *underfitting* e evitar o *overfitting* (SILVA et al., 2010). De acordo com esses autores, o número excessivo de neurônios na camada oculta pode acarretar a memorização dos dados de treinamento (*overfitting*) e, por outro lado, um número muito pequeno pode ser insuficiente para a extração e armazenamento das características do problema. Nesse último caso, o erro tanto na fase de treinamento como na fase de teste serão significativos. Além de ser mais propenso ao *overfitting*, em geral, o aumento do número de unidades ocultas apesar de aumentar o poder de modelagem da RNA, faz com que seja mais difícil de treinar e mais lento para processar (STATSOFT, INC, 2007).

Existem metodologias e ferramentas para facilitar a escolha da melhor arquitetura e topologia das redes. O *software* Statistica possui uma ferramenta, *Intelligent Problem Solver* (IPS), que otimiza a definição da arquitetura e topologia das redes. Essa ferramenta testa diferentes configurações e seleciona as redes que melhor representam os dados (BINOTI et al., 2009). Para cada tipo de rede é especificado um intervalo de valores (mínimo e máximo) para o número de unidades na camada oculta a ser testada (STATSOFT, INC, 2007).

O NEAT (Neuroevolution of Augmenting Topologies) é uma técnica que, a partir de algoritmos genéticos, ajusta simultaneamente os pesos sinápticos e a topologia de uma RNA, eliminando a etapa de busca da melhor arquitetura. O NEAT começa com redes simples sem camadas ocultas, apenas com conexões entre as entradas e as saídas, e aumenta a complexidade das redes gradativamente com a adição de neurônios e conexões, mas evitando que estruturas desnecessárias sejam introduzidas (MUNIZ e NEVES, 2015).

Em resumo, uma vez que as variáveis de entrada e saída tenham sido selecionadas em função do problema, alguns passos para escolher a arquitetura de uma rede são definidos: escolher uma configuração inicial mais simples (uma camada oculta com o número de neurônios definido, por exemplo, metade da soma do número de unidades de entrada, sendo que cada classe da variável categórica corresponde a um neurônio, e de saída) e treinar a rede, se ao final disso a rede não alcançar um nível de desempenho aceitável pode-se adicionar mais neurônios na camada oculta, caso isso não ajude, pode-se adicionar uma camada oculta, e assim sucessivamente. Se as redes com maior quantidade de neurônios na camada oculta apresentarem bom desempenho no treinamento, mas pior desempenho na validação, então provavelmente ocorreu *overfitting* e deve-se reduzir para redes menores (STATSOFT, INC, 2007).

1.4. Treinamento de uma RNA

O treinamento de uma RNA consiste no ajuste dos pesos sinápticos e limiares de ativação dos seus neurônios para obter saídas finais mais próximas das saídas desejadas, através de um algoritmo de treinamento (HAYKIN, 2001; BULLINARIA, 2014).

A rede irá extrair características do problema a ser mapeado através das amostras apresentadas, que devem ser representativas e não tendenciosas. Se os dados de treinamento não são representativos o modelo é, na melhor das hipóteses, comprometido, e na pior das hipóteses, ele pode ser inútil (STATSOFT, INC, 2007). Assim, se o número de exemplos é suficientemente grande e a rede é treinada para aprender a discriminar os diferentes aspectos do problema, o esperado é que a rede generalize corretamente quando novos dados são apresentados (HAYKIN, 2001).

Uma RNA só pode aprender com os casos que estão presentes, isto é, não se pode esperar que a rede tome uma decisão correta quando ela encontrar um caso não visto anteriormente. Segundo Silva et al. (2010), o conjunto de treinamento deve conter os dados com os valores mínimos e máximos de cada variável, caso contrário, a rede não conseguirá generalizar para valores que estão fora do domínio de definição. Em conjuntos de dados desbalanceados, a rede treinada pode ter sua decisão viesada, em direção àquela que possui a maioria dos casos. Se a representação desses casos é diferente na população real, a decisão da rede poderá ser errada. Outro problema são os ruídos, apesar da rede ser tolerante a eles, existe um limite. Valores extremos fora do intervalo de valores normais para uma variável podem influenciar o treinamento de uma rede, sendo, nesse caso, melhor identificar os anómalos e removê-los (STATSOFT, INC, 2007).

O número de dados necessários para o treinamento da RNA está relacionado com a complexidade da função que a rede irá modelar. À medida que o número de variáveis aumenta, o número de dados necessários para o treinamento aumenta não linearmente (STATSOFT, INC, 2007).

Nem todos os dados são utilizados no treinamento das redes, alguns deles são reservados e usados para manter uma verificação independente sobre a situação/progresso do algoritmo de treinamento e validação da rede treinada. Os dados de teste são aqueles utilizados após o treinamento da rede para verificar se os aspectos referentes ao treinamento da rede estão em patamares aceitáveis, possibilitando assim a validação da topologia assumida (SILVA et al., 2010). Para adicionar confiança no desempenho do modelo final, é reservado um conjunto de

validação ou generalização, que avalia a capacidade da rede em fornecer resultados precisos para dados desconhecidos.

Cabe ressaltar que os dados de treinamento, teste e validação devem ser representativos do problema a ser modelado e que os três conjuntos devem ser independentemente apresentados à rede. Já o dimensionamento desses subconjuntos deve levar em consideração a caracterização estatística dos dados (SILVA et al., 2010) e o tamanho da base de dados.

1.4.1. Tipos de treinamento (aprendizado)

Alguns tipos de aprendizado são definidos por Silva et al. (2010): supervisionado (*off-line* e *on-line*) e não-supervisionado. Na aprendizagem supervisionada, cada amostra de treinamento é composta pelos sinais de entrada e suas respectivas saídas desejadas, como se houvesse um “professor” ensinando para a rede qual a resposta correta para cada amostra apresentada a sua entrada (SILVA et al., 2010). Assim, os pesos sinápticos e limiares são continuamente ajustados através da comparação entre a saída da rede e a saída desejada, e a diferença é usada no processo de ajuste pelos algoritmos de treinamento. A rede é considerada treinada quando essa diferença estiver dentro de valores aceitáveis. A apresentação completa de todas as amostras de treinamento à rede é denominada época ou ciclo de treinamento.

No aprendizado *off-line*, os ajustes dos pesos e limiares da rede só são efetuados após a apresentação de todo o conjunto de treinamento, precisando de pelo menos uma época de treinamento para realizar um passo de ajuste (SILVA et al., 2010). Essa técnica é geralmente mais estável, mas pode ser lenta se o conjunto de treinamento for grande e redundante (BINOTI, 2010). Já no aprendizado *on-line*, os ajustes dos pesos e limiares são feitos após a apresentação de cada amostra. Como os padrões são apresentados um por vez, o ajuste dos pesos e limiares é bem localizado e pontual, conseqüentemente, a rede apenas começará a fornecer respostas mais precisas após a apresentação de um número significativo de amostras (SILVA et al., 2010).

No aprendizado não-supervisionado as saídas desejadas inexistem. A rede identifica subconjuntos (*clusters*) que contêm similaridades, e os algoritmos de treinamento ajustam os pesos sinápticos e limiares de forma a refletir essa representação dentro da rede (SILVA et al., 2010). Um exemplo é a classificação não-supervisionada de uma imagem digital, em que a rede agrupa os pixels em diferentes classes espectrais de acordo com critérios estatísticos pré-determinados, e, posteriormente, o usuário tenta identificar as classes geradas pelo computador (água, floresta, por exemplo). O número de *clusters* pode ser definido inicialmente pelo utilizador da rede de acordo com seu conhecimento a respeito do problema tratado. Este tipo de

aprendizado só se torna possível quando existe redundância nos dados de entrada, caso contrário, torna-se impossível encontrar quaisquer padrões ou características dos dados de entrada (BINOTI, 2010).

Como exemplo de rede com aprendizado não-supervisionado, tem-se a rede de Kohonen. Nessa rede, segundo Braga et al. (2000), não existe uma classificação de padrões em classes pré-definidas, e sim um agrupamento dos dados, com cada grupo de padrões representando uma e apenas uma classe, de acordo com suas similaridades e particularidades. Para esse agrupamento, o algoritmo de treinamento precisa encontrar características ou padrões significativos nos dados de entrada e cada padrão a ser reconhecido deverá ter, no mínimo, um neurônio de saída correspondente. Esse tipo de rede é usado quando se deseja reconhecer diversos padrões que possuam alguma relação entre si, como reconhecimento de voz, em que no treinamento cada grupo de neurônios se especializa em um tipo de som e assim o identifica quando recebe seus sinais de entrada.

O tipo de aprendizagem será determinado pelo problema a ser solucionado pela rede neuronal artificial (BINOTI, 2010). Na aproximação de funções, o aprendizado é do tipo supervisionado, onde as saídas desejadas são apresentadas à rede juntamente com as entradas.

1.4.2. Etapas do treinamento

1.4.2.1. Normalização dos dados

O intervalo de resposta numérico limitado, aliado ao fato de que a informação tem que ser em forma numérica, implica que os dados requerem etapas de pré-processamento e pós-processamento para serem usados. A normalização é uma etapa de pré-processamento dos dados que implica em uma melhor precisão numérica frente às operações matemáticas realizadas pela rede (SILVA et al., 2010) e redução no tempo de processamento da mesma (HAYKIN, 2001). Segundo Bishop (1995), o redimensionamento dos dados é útil quando as variáveis possuem valores que diferem significativamente em ordem de grandeza, por exemplo, variáveis com unidades diferentes (temperatura e pressão), evitando que os valores maiores de algumas delas influenciem de forma tendenciosa as estimativas.

Na prática, a normalização dos dados de entrada garante que todas as variáveis estejam padronizadas, assim não haverá desigualdade entre os pesos, que também estarão padronizados. Sem a transformação dos dados, seria necessário encontrar uma solução para os pesos que tivessem valores muito diferentes dos outros (BISHOP, 1995). Esse autor recomenda que, nos casos de aproximação de funções, os dados das variáveis dependentes também sejam

normalizados. Sendo necessário um pós-processamento dos dados ao final do treinamento de uma rede, revertendo a normalização realizada anteriormente (BINOTI, 2012).

Existem alguns métodos para normalizar os dados. Tipicamente, os valores das variáveis quantitativas são dimensionados de forma linear, embora em algumas circunstâncias, a escala não linear pode ser apropriada, por exemplo, se for conhecido que uma variável é distribuída exponencialmente (STATSOFT, INC, 2007).

No método citado por Bishop (1995), a média das variáveis transformadas será igual a zero e o desvio padrão igual a um. Para isso, cada variável de entrada é tratada independentemente, e para cada variável x_i é calculada uma média \bar{x}_i e uma variância σ_i^2

$$\bar{x}_i = \frac{1}{N} \sum_{n=1}^N x_i^n$$

$$\sigma_i^2 = \frac{1}{N-1} \sum_{n=1}^N (x_i^n - \bar{x}_i)^2$$

onde N é o número total de observações da variável x_i . Dessa forma, o valor redimensionado será:

$$\tilde{x}_i^n = \frac{x_i^n - \bar{x}_i}{\sigma_i}$$

Outro método de normalização dos dados considera o valor mínimo e máximo de cada variável na transformação para valores em um intervalo fechado (0 a 1 ou -1 a 1), mantendo as distâncias entre os valores normalizados proporcionais às distâncias entre os dados originais (BINOTI, 2012).

$$x' = \frac{(x - x_{min})(b - a)}{(x_{max} - x_{min})} + a$$

onde x' é valor normalizado; x é o valor original; x_{min} é o valor mínimo e x_{max} é o valor máximo da variável; a é o limite inferior e b é o limite superior do intervalo de normalização.

As variáveis categóricas também devem ser tratadas na etapa de pré-processamento, sendo codificadas de forma a atender às necessidades de uma rede, ou seja, que os dados estejam em uma representação numérica, possibilitando a RNA multiplicar a classe por um peso sináptico associado (BINOTI, 2012). Entretanto, a simples utilização de códigos numéricos (por exemplo, para três categorias de uma variável (vermelho, verde e azul) utilizar três números (1, 2 e 3)) pode impor uma ordenação artificial sobre os dados. Para contornar esse problema, Bishop (1995) sugere usar uma codificação 1-de-c para os dados de entrada. Nesse método, o código terá o número de elementos igual ao número de categorias da variável, e cada elemento recebe o valor 0, exceto aquele que representa a categoria em questão. No exemplo citado anteriormente, as três cores seriam representadas por valores de entrada de (1,0,0), (0,1,0) e (0,0,1).

1.4.2.2. Treinamento e critérios de parada

O treinamento inicia com a introdução dos dados que representam um determinado problema a uma arquitetura pré-estabelecida. Os pesos iniciais podem apresentar valores aleatórios (mais comum) ou números pré-determinados, e após o processamento da primeira observação dos dados, a saída da rede é comparada com a saída desejada, gerando um sinal de erro (e_i), que servirá para calibrar o ajuste dos pesos por um algoritmo de treinamento.

$$e_i = d_i - y_i$$

em que d_i é a saída desejada e y_i é a saída estimada pela rede.

Os dados de treinamento são apresentados à RNA por épocas sucessivas até que se atinja um critério de parada previamente estabelecido, que pode ser:

- Erro quadrático médio: Ao final da apresentação de todas as n observações (uma época de treinamento) é calculado o erro quadrático médio (EQM). O treinamento encerra ao atingir um valor do EQM pré-estabelecido.

$$EQM = \frac{1}{n} \sum_{i=1}^n (y_{obs} - y_{RNA})^2$$

- Número de época ou ciclos: Encerra o treinamento de uma rede após atingir uma determinada quantidade de ciclos. Usar um número de época como critério adicional de parada é uma estratégia simples e eficiente para parar o treinamento quando a precisão especificada se torna inalcançável (SILVA et al., 2010).
- Parada antecipada (validação cruzada): A parada antecipada tem sido inserida na técnica da validação cruzada, que avalia qual a topologia adequada para ser utilizada. A cada época, após o reajuste dos pesos, o treinamento é parado e o subconjunto de teste é apresentado à rede para calcular o erro. O processo é repetido época a época, e o treinamento será interrompido quando o valor do erro para o subconjunto de teste, após atingir seu mínimo, começa a crescer ou torna-se estacionário (Figura 10).

Outra consideração importante é que existem pontos de mínimos locais e pontos de mínimos globais do erro e, dependendo dos pesos iniciais do treinamento da rede, o algoritmo pode convergir para pontos de mínimos locais inapropriados. Para qualquer configuração possível de pesos, é plotada uma superfície de erro, sendo o objetivo do treinamento da rede encontrar o seu ponto mais baixo. Em virtude da superfície do erro produzida ser não-linear, pode ser que o treinamento direcione a matriz de pesos da rede para um ponto de mínimo local que não corresponde aos valores mais apropriados aos propósitos de generalização dos resultados (STATSOFT, INC, 2007).

No exemplo da figura 11, apresentado por Silva et al. (2010), caso a rede convergisse para o ponto indicado em p (2), os resultados produzidos seriam melhores que a convergência para p (1) ou p (3), pois o valor do erro em p (2) é menor. A tendência de convergência fica condicionada à posição inicial em que a matriz de pesos W é iniciada, pois a maioria dos algoritmos de treinamento é baseada em métodos de gradiente descendente. No exemplo, se a matriz tivesse iniciado em W (a), a tendência de convergência seria para p (1), e se tivesse iniciado em W (b) seria para direção de p (2).

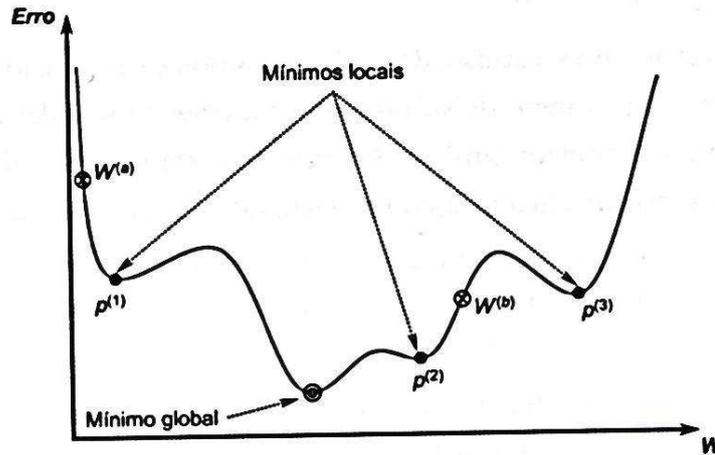


Figura 11 – Pontos do mínimo local em função do erro (Fonte: SILVA et al., 2010).

Nesse sentido, recomenda-se treinar uma rede mais de uma vez, com diferentes matrizes de pesos iniciais, visando evitar a convergência do erro para pontos de mínimos locais inapropriados (SILVA et al., 2010). Braga et al. (2000) cita a utilização de algoritmos genéticos para o treinamento da RNA como alternativa para diminuir a chance de ocorrência de mínimos locais, quando usadas grandes populações (conjunto de soluções possíveis), mas ressaltam que esses algoritmos demandam maior esforço computacional.

Ao final do treinamento, se a rede estiver devidamente treinada, ou seja, aprendeu a modelar a função que relaciona as variáveis de entrada com as variáveis de saída, ela poderá ser usada em condições em que a saída não é conhecida.

1.4.3. Sobre-treinamento (*overfitting*)

O sobre-treinamento ocorre quando uma rede decora a correspondência entre os valores das variáveis de entrada e a saída durante o treinamento. Assim, a função ajustada passa sobre a maioria dos pontos ao invés de aproximar a função que descreve a relação entre as entradas e a saída (linha em azul – Figura 12) (HAYKIN, 2001; BINOTI, 2010; BULLINARIA, 2014). No treino, essa rede apresenta um erro inferior associado ao excesso de encaixe em vez de boa modelagem, e quando novos dados são apresentados à rede, a função fica afastada da maioria dos pontos, indicando pior capacidade de generalização.

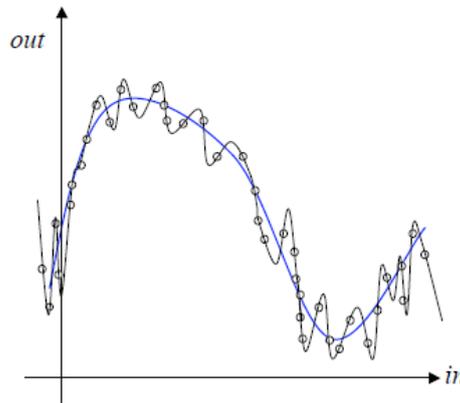


Figura 12 – Sobre-treinamento de dados (Fonte: BULLINARIA, 2014).

É mais fácil demonstrar este conceito utilizando o exemplo dos polinômios. Dado um conjunto de dados, deseja-se ajustar uma curva polinomial para explicá-los. Os dados costumam ter ruídos, por isso, não se espera que o melhor modelo passe exatamente por todos os pontos. Um polinômio de ordem inferior pode não ser suficientemente flexível para se ajustar perto dos pontos, ao contrário de um polinômio de ordem superior, que ajusta melhor aos dados pela adoção de uma forma mais excêntrica (STATSOFT, INC, 2007). Com as RNA ocorre o mesmo, uma rede com mais pesos modela uma função mais complexa, mas o número excessivo de neurônios utilizados na camada intermediária torna a rede mais propensa ao sobre-treinamento (CERQUEIRA et al., 2001).

Para evitar o excesso de encaixe, Bullinaria (2014) faz algumas recomendações: restringir o número de parâmetros ajustáveis, reduzindo o número de unidades ocultas ou forçando algumas conexões a compartilhar os mesmos valores de peso; parar o treinamento mais cedo, antes da rede ter tempo para decorar os dados de treinamento; e adicionar ruído nos padrões de treinamento.

1.5. Algoritmos de treinamento

A RNA é treinada utilizando um algoritmo de treinamento, cuja função é ajustar os pesos sinápticos da rede até alcançar o objetivo definido (HAYKIN, 2001). O algoritmo de treinamento utilizado influencia a fuga dos mínimos locais, o desempenho da tarefa desejada e o tempo de treinamento (BINOTI, 2012).

O algoritmo retropropagação do erro é um dos mais conhecidos. Esse algoritmo ajusta primeiramente os pesos da camada de saída de acordo com a diferença entre a saída desejada e a apresentada pela rede. Posteriormente, esse erro é retropropagado para os neurônios das

camadas anteriores, e a resposta desejada de um neurônio de uma camada será determinada em função das camadas posteriores (SILVA et al., 2010). No entanto, o algoritmo retropropagação do erro tem algumas desvantagens conhecidas, como convergência lenta (OZÇELIK et al., 2010). Depois desse algoritmo, outros foram desenvolvidos com o intuito de melhorar o ajuste das relações e, conseqüentemente, reduzir o erro.

1.5.1. Algoritmo retropropagação do erro (*Backpropagation*)

Também conhecido como regra delta generalizada, a aplicação desse algoritmo possui duas etapas: propagação adiante e retropropagação do erro. Para exemplificar considera-se uma rede com uma variável de entrada (x_1), uma camada oculta com dois neurônios e uma saída (Figura 13). Considera-se também a entrada x_0 , associada ao peso w_0 (limiar de ativação), igual a 1.

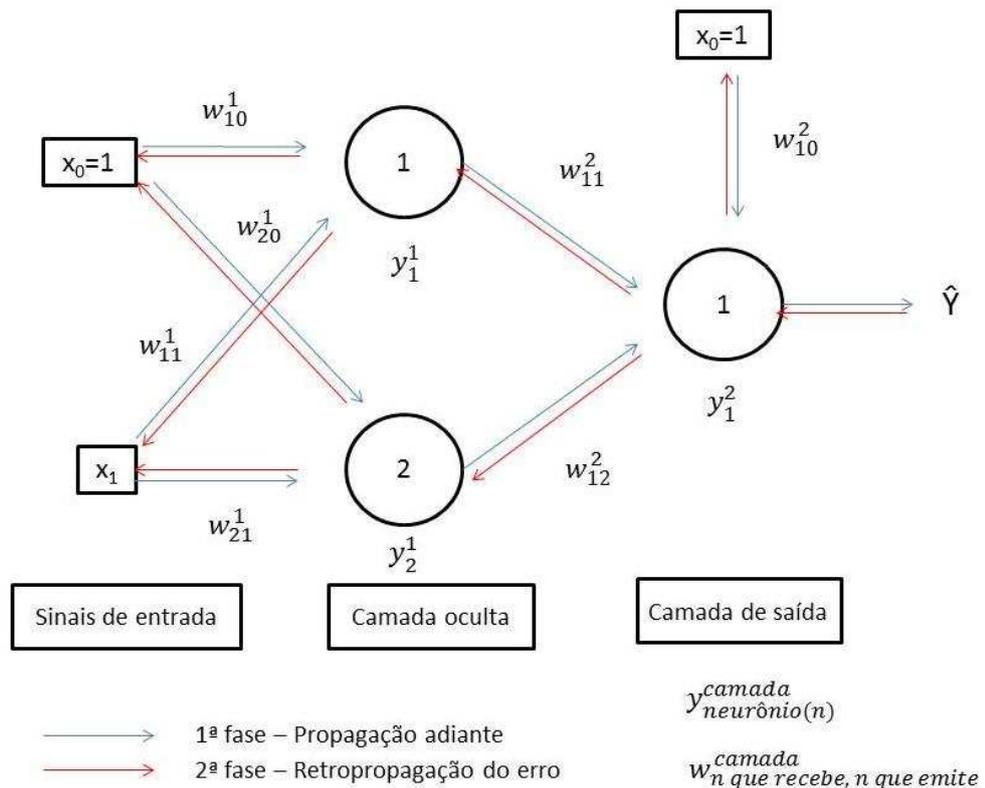


Figura 13 – Fases do algoritmo de retropropagação do erro (Fonte: Autor).

- 1ª fase - Propagação adiante:

Nessa fase o objetivo é produzir a resposta real da rede (\hat{y}) e durante essa fase todos os pesos são fixos (HAYKIN, 2001). Para cada neurônio da camada oculta será calculada uma

saída (y) de acordo com a função de ativação ($f(u)$). Primeiro é calculado o potencial de ativação para cada neurônio da camada intermediária, e depois o cálculo da função de ativação. Nesse exemplo será considerada a função logística (considerando β igual a 1). Assim, têm-se os cálculos:

$$u_1^1 = w_{10}^1 x_0 + w_{11}^1 x_1$$

$$u_2^1 = w_{20}^1 x_0 + w_{21}^1 x_1$$

$$f(u) = y_1^1 = \frac{1}{1 + e^{-u_1^1}}$$

$$f(u) = y_2^1 = \frac{1}{1 + e^{-u_2^1}}$$

em que x_k é o sinal da entrada, u_j^L é o potencial de ativação, w_{jk}^L é o peso da conexão entre os neurônios, e y_j^L é a saída do neurônio, sendo j o neurônio pertencente a camada L , e k o neurônio que emite o sinal.

Posteriormente, é calculado o potencial de ativação para o neurônio da camada de saída e a função de ativação, sendo que $\hat{y} = y_1^2$.

$$u_1^2 = w_{10}^2 x_0 + w_{11}^2 y_1^1 + w_{12}^2 y_2^1$$

$$f(u) = y_1^2 = \frac{1}{1 + e^{-u_1^2}}$$

- 2ª fase - Retropropagação do erro:

Nessa fase os pesos são todos ajustados de acordo com uma regra de correção do erro (HAYKIN, 2001). Esse procedimento ajusta a matriz de pesos em direção oposta ao gradiente a fim de minimizar o erro (SILVA et al., 2010). A resposta da rede é subtraída da resposta desejada (d) para produzir o sinal de erro (e), que será propagado para trás por meio da rede (HAYKIN, 2001). Esse autor ressalta que a atualização de pesos sequencial, ou seja, de padrão em padrão, é computacionalmente mais rápida, principalmente quando o conjunto de dados for grande. No exemplo citado, o erro para a primeira observação será:

$$e_1 = d_1 - y_1^2$$

Após o erro calculado na camada de saída, o ajuste dos pesos é feito da última para a primeira camada. O gradiente local (δ) em relação ao neurônio é dado por:

$$\delta_j^L = e g'(\cdot)$$

sendo e o erro, $g'(\cdot)$ a derivada de primeira ordem da função de ativação (no exemplo: função logística), j -ésimo neurônio pertencente a camada L .

Após o cálculo do gradiente local do neurônio da camada de saída, os pesos das conexões que ligam a camada de saída à intermediária são ajustados:

$$\begin{aligned}\delta_1^2 &= y_1^2(1 - y_1^2)e_1 \\ w_{10}^2(t + 1) &= w_{10}^2(t) + \eta\delta_1^2x_0^1 \\ w_{11}^2(t + 1) &= w_{11}^2(t) + \eta\delta_1^2y_1^1 \\ w_{12}^2(t + 1) &= w_{12}^2(t) + \eta\delta_1^2y_2^1\end{aligned}$$

onde η é a taxa de aprendizagem.

A taxa de aprendizagem (η) mede a variação dos pesos sinápticos de uma iteração para outra, ou seja, a rapidez com que os pesos são atualizados indo em direção à minimização do erro (HAYKIN, 2001). Segundo Bullinaria (2014), a escolha de um bom valor para essa taxa é limitada por dois fatores opostos: se η é muito pequena, vai demorar muito tempo para chegar perto do mínimo da função de erro, e se η é muito grande, as atualizações de peso podem pular o erro mínimo e os pesos irão oscilar. Silva et al. (2010) recomendam que as taxas devem ser entre 0,05 e 0,75. Entretanto, o valor ideal é dependente do problema e da rede, por isso não se pode formular prescrições gerais de confiança, devendo testar uma faixa de diferentes valores (por exemplo, $\eta = 0,1, 0,01, 1,0, 0,0001$) (BULLINARIA, 2014).

Os gradientes locais dos neurônios da camada intermediária são calculados para ajustar os pesos que os ligam à camada de entrada. Diferentemente dos neurônios pertencentes à camada de saída, os neurônios da camada intermediária não têm acesso de forma direta aos valores desejados para suas saídas, sendo assim, os ajustes dos pesos são efetuados por intermédio de estimativas dos erros da camada de saída (SILVA et al., 2010). Então, o ajuste dos pesos da camada intermediária só poderá ser feito depois do ajuste dos neurônios da camada de saída.

$$\delta_1^1 = y_1^1(1 - y_1^2)w_{11}^2\delta_1^2$$

$$\delta_2^1 = y_2^1(1 - y_1^2)w_{12}^2\delta_1^2$$

E o reajuste dos pesos da camada intermediária que ligam a camada de entrada:

$$w_{10}^1(t + 1) = w_{10}^1(t) + \eta\delta_1^1x_0$$

$$w_{11}^1(t + 1) = w_{11}^1(t) + \eta\delta_1^1x_1$$

$$w_{20}^1(t + 1) = w_{20}^1(t) + \eta\delta_2^1x_0$$

$$w_{21}^1(t + 1) = w_{21}^1(t) + \eta\delta_2^1x_1$$

O ajuste dos pesos é feito até minimizar o erro. O algoritmo de treinamento irá parar quando atingir algum critério de parada pré-definido.

Existem algumas variações do algoritmo de retropropagação do erro. Uma delas insere o termo *momentum* ($\alpha\Delta W$) que pondera o quanto as matrizes dos pesos foram alteradas entre duas iterações sucessivas, sendo α a taxa de *momentum*, que afeta o processo de convergência (SILVA et al., 2010). O termo *momentum* pode acelerar a descida em direções com declividade constante e, conseqüentemente, acelerar o treinamento (HAYKIN, 2001). De acordo com a figura 14, quando a solução atual estiver longe da solução final, a variação em direção oposta ao gradiente será grande também, ou seja, será dado um passo maior em direção ao mínimo da função do erro. Caso contrário, o ajuste nas matrizes de peso terá maior contribuição da taxa de aprendizagem.

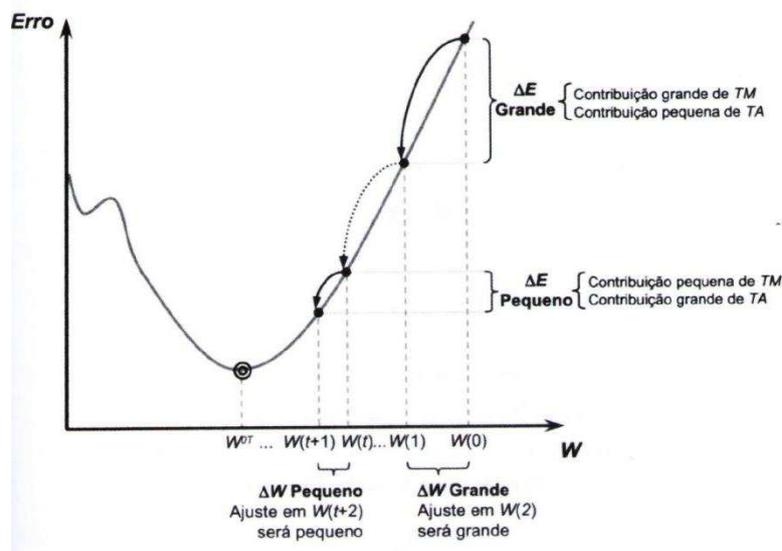


Figura 14 – Método de inserção do termo de *momentum* (Fonte: SILVA et al., 2010).

1.5.2. Algoritmo *Resilient Propagation*

Esse algoritmo é uma variação do algoritmo de retropropagação do erro, levando em consideração a variação do sinal do erro, ao invés da variação da magnitude do gradiente da função do erro (SILVA et al., 2010). De acordo com esses autores, a taxa de aprendizagem desse algoritmo será dinâmica, sendo incrementada (passos I, II, III e V da figura 15) quando os sinais dos gradientes forem os mesmos, ou reduzida quando os sinais forem diferentes (passos IV, VI e VII da figura 15), pois nesse caso o ponto de mínimo foi ultrapassado.

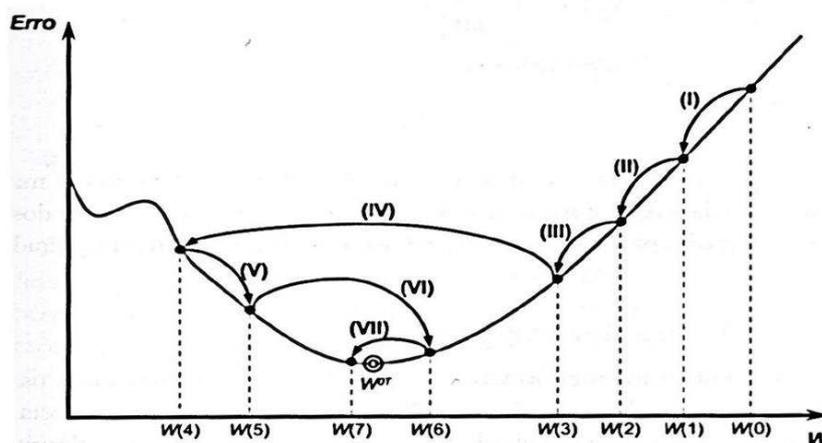


Figura 15 – Mecanismo de convergência para o algoritmo *Resilient Propagation* (Fonte: SILVA et al., 2010).

O algoritmo *Resilient Propagation* tem demonstrado resultados superiores aos dos demais algoritmos de treinamento para RNA do tipo Multilayer Perceptron (MLP) em aplicações na área florestal (BINOTI et al., 2014; MARTINS et al., 2016; LEITE et al., 2016).

1.5.3. Algoritmo *Quick Propagation*

Esse algoritmo baseia-se no método de Newton que é utilizado para obtenção de raízes de uma função e é tolerante a altas taxas de aprendizado (LEITE et al., 2016).

Segundo Braga et al. (2000), a principal diferença em relação ao *Backpropagation* é que para cada peso são utilizadas as inclinações anterior e atual da superfície do erro, considerada localmente quadrática, procurando saltar da posição atual para o ponto de mínimo da parábola. De acordo com esses autores, se a inclinação atual for menor que a anterior e na mesma direção, o peso será ajustado na mesma direção e o tamanho desse ajuste dependerá de quanto a inclinação foi reduzida no ajuste anterior. Se a inclinação atual for na direção oposta à

inclinação associada ao ajuste anterior, isto significa que o ponto de mínimo foi ultrapassado, assim, o próximo ajuste será para uma posição entre a posição anterior e a atual.

1.5.4. Algoritmo de treinamento Regra Delta.

Esse algoritmo é utilizado nas redes do tipo Adaline e visa obter os valores ótimos dos pesos para que o erro quadrático médio (EQM) do conjunto de treinamento seja o mínimo possível (SILVA et al., 2010).

Considerando a atualização do peso pelo algoritmo ao final da apresentação de cada amostra de treinamento, o ajuste do peso será:

$$w_{ji}(t + 1) = w_{ji}(t) + \eta(d_i - y_i)x_{ji}$$

onde i corresponde a i -ésima amostra de treinamento, j a j -ésima variável de entrada e η a taxa de aprendizagem.

1.6. Capacidade de generalização de uma rede neuronal artificial

Não é suficiente uma rede apenas apresentar bons resultados para o treinamento, ela deve ser capaz de ser aplicada a novos dados e apresentar bons resultados. Essa capacidade da rede treinada ser aplicada a um novo conjunto de dados com o mesmo problema e fornecer resultados satisfatórios é conhecida como generalização (BINOTI, 2010).

Segundo Haykin (2001) uma rede generaliza bem quando o mapeamento entrada-saída computado pela rede for correto para dados não utilizados no treinamento da rede, mesmo quando a entrada for um pouco diferente dos exemplos usados no treinamento da rede.

Deve-se ressaltar que para a RNA treinada ser aplicada a novos dados, esses devem ser do mesmo tipo de problema, ou seja, ter as mesmas variáveis de entrada e saída que foram utilizadas para treinar a rede, e devem estar dentro da mesma amplitude dos dados de treinamento para evitar extrapolação.

1.7. Referências bibliográficas

BHERING, L. L.; CRUZ, C. D.; PEIXOTO, L. D. A.; ROSADO, A. M.; LAVIOLA, B. G.; NASCIMENTO, M. Application of neural networks to predict volume in eucalyptus. **Crop Breeding and Applied Biotechnology**, v.15, n.3, p.125-131, 2015.

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

BINOTI, M.L.M.S. **Uso de redes neuronais artificiais para prognose da produção de povoamentos de eucalipto**. 2010. 54 f. Dissertação (Mestrado em Ciência Florestal)- Universidade Federal de Viçosa. 2010.

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

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

BISHOP, C.M. **Neuronal networks for pattern recognition**. Oxford University Press, 1995. 482 p.

BRAGA, A. de P.; CARVALHO, A. P. de L. F. de; LUDEMIR, T. B. **Redes Neuronais Artificiais: Teoria e Aplicações**. Rio de Janeiro, RJ. Editora LTC, 262 p. 2000.

BULLINARIA, J. A. **Introduction to Neuronal Computation**. Notas de aula. 2014. Disponível em: <<http://www.cs.bham.ac.uk/~jxb/inc.html>>. Acesso em: 27 de maio de 2015.

CERQUEIRA, E.O.; ANDRADE, J.C.; POPPI, R.J. Redes neuronais e suas aplicações em calibração multivariada. **Quim. Nova**, v. 24, n.6, p.864-873, 2001.

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

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

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

MARTINS, E.R.; BINOTI, M.L.M.S.; LEITE, H.G.; BINOTI, D.H.B.; DUTRA, G.C. Configuração de redes neurais artificiais para estimação da altura total de árvores de eucalipto. **Agrária**, v.11, n.2, p.117-123, 2016.

MUNIZ, A.L.N.; NEVES, C.A.M.S. **Redes Neurais Evolucionárias**. 2015. Disponível em: <https://www.researchgate.net/publication/267297071_Redex_Neurais_Evolucionarias>. Acesso em: 15 de junho de 2017.

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

PENG, C.; WEN, X. (1999). **Recent applications of artificial neural networks in forest resource management: an overview**. Disponível em: <<https://pdfs.semanticscholar.org/9e4c/948ab8b9cc0a1dedcdd1417c3da6a8042907.pdf>>. Acesso em: 03 de abril de 2017.

SILVA, I. N.; SPATTI, H. D.; FLAUZINO, R. A. **Redes Neuronais Artificiais: para engenharia e ciências aplicadas**. São Paulo: Artliber, 399 p. 2010.

SILVA RIBEIRO, R. B.; GAMA, J. R. V.; SOUZA, A. L.; LEITE, H. G.; SOARES, C. P. B.; SILVA, G. F. Métodos para estimar o volume de fustes e galhos na Floresta Nacional do Tapajós. **Revista Árvore**, v.40, n.1, p.81-88, 2016.

STATSOFT, INC. **Statistica** (Data Analysis Software System), Version 7, 2007.

VAHEDI, A. A. Monitoring soil carbon pool in the Hyrcanian coastal plain forest of Iran: Artificial neural network application in comparison with developing traditional models. **Catena**, v.152, p.182-189, 2017.

VON ZUBEN, F., DE CASTRO, L. **Regressão paramétrica e não-paramétrica**. Campinas: Unicamp, 2001. Disponível em:
<<http://www.dca.fee.unicamp.br/~vonzuben/courses/ia353.html>>. Acesso em: 2 de junho de 2015.

2. Fatores que influenciam o crescimento e a produtividade florestal

2.1.Introdução

Em meados de 2008, a área de florestas equiâneas no mundo correspondia a 4,8 % da área florestal total e 65 % da madeira consumida para fins industriais era proveniente de florestas inequiâneas (LERAYER et al., 2008). Com o passar dos anos, a exploração insustentável dos remanescentes florestais nativos tem sido combatida, ao mesmo tempo em que a demanda por produtos florestais madeireiros tem crescido. Um estudo realizado pela WWF (World Wide Fund for Nature) indica que a demanda global por madeira vai triplicar até 2050, chegando a 10 bilhões de metros cúbicos por ano (RYDLEWSKI, 2015).

Diante à crescente demanda por produtos florestais, e maior conscientização em relação à sustentabilidade, tem se buscado maximizar a produção, otimizando o uso dos recursos naturais. Maiores produtividades estão diretamente relacionadas à eficiência no uso de recursos naturais, como água, nutrientes do solo e luz, durante o crescimento da planta (TONELLO, 2010). Entender como esses fatores afetam a produtividade florestal é fundamental para possibilitar escolhas corretas em relação ao genótipo e pacote tecnológico que serão utilizados de acordo com a região de plantio. Entretanto, apesar de ser relativamente simples e fácil enumerar os fatores que influenciam o crescimento da floresta, o entendimento e a avaliação do somatório das interações desses fatores e os seus efeitos em escala de campo é difícil, uma vez que eles são dinâmicos e inter-relacionados (BILLINGS, 1952; BRAGA et al., 1999; MONTEZANO et al., 2006).

A produtividade florestal é resultante da interação entre os fatores bióticos, climáticos, edáficos e fisiográficos, e influenciada pelo manejo florestal e práticas silviculturais (BARROS, 1974). Segundo Campos (1970), a maioria dos fatores do meio ambiente atua de forma indireta no crescimento das plantas, afetando os processos fisiológicos. Esses processos são multi-condicionados, e sendo assim, é impossível falar de apenas uma condição de um fator como causa única de um efeito observado em um organismo (CAIN, 1944 citado por BILLINGS, 1952).

2.2. Fatores ambientais

Os fatores ambientais são segmentados em fatores fisiográficos, edáficos e climáticos, os quais são inter-relacionados.

2.2.1. Fatores climáticos

A radiação é a fonte primária de energia para a conversão do CO₂ e H₂O em compostos orgânicos, fotossíntese, sem a qual não existiriam as plantas (CAMPOS, 1970; MEURER, 2007). As plantas respondem a diferentes níveis de variação da radiação, tanto na escala de microclima devido a superfície de exposição e a declividade do terreno, e em um nível macro, com base no clima definido pelas diferentes altitudes (RODY et al., 2016). Segundo esses autores, essas diferenças levam a padrões específicos de crescimento florestal, culminando em produtividade diferenciada ao longo do ciclo de vida.

Em países tropicais, como o Brasil, a radiação é um fator abundante, sendo a disponibilidade hídrica um dos fatores mais limitantes à produtividade florestal de acordo com diversos estudos. Considerando as condições de clima em diferentes regiões brasileiras, Borges (2012) concluiu que a produtividade potencial de madeira de eucalipto aos seis anos de idade é influenciada pela precipitação pluviométrica, seguida da radiação solar, distribuição de chuvas e temperatura máxima.

Marcatti et al. (2017) utilizaram um índice ambiental, com informações climáticas e geográficas, para gerar uma recomendação ótima de genótipos de eucalipto para maximizar a produção volumétrica em uma determinada área. Em um primeiro momento, esses autores consideraram os fatores fisiográficos, mas depois os descartaram, uma vez que apresentaram alta correlação com as variáveis climáticas e baixa correlação com o volume do cultivo. Apesar desses autores levarem em consideração apenas as variáveis climáticas, o índice foi suficiente para representar o gradiente ambiental, sendo influenciado principalmente pela variação na precipitação.

Resultado semelhante foi observado por Ferreira (2009), que combinou as variáveis ambientais com os dados de inventário para a modelagem do índice de sítio e depois o utilizaram em modelos de crescimento e produção. Esse autor observou que a utilização do índice de sítio, estimado com as variáveis ambientais, melhorou a dispersão dos resíduos e a precisão do modelo, e que a precipitação mensal, o déficit hídrico e o excedente hídrico tiveram maiores correlações com o incremento corrente anual do volume, altura dominante e área basal de povoamentos de eucalipto no extremo sul da Bahia.

Segundo Martinkoski et al. (2015), a precipitação e a temperatura do ar se destacam como as variáveis climáticas que desempenham maior influência sobre a produtividade de diversas espécies de clima tropical. Correlação positiva entre a precipitação e a produtividade tem sido observada para diversas espécies arbóreas. De acordo com Oliveira et al. (2011),

quanto maior a precipitação durante a estação de crescimento, maiores serão os valores de incremento das árvores. À medida que o solo vai secando durante os períodos de menor pluviosidade, os processos fisiológicos vão se restringindo em consequência da falta de água no solo, resultando em menor crescimento vegetativo (ZANON e FINGER, 2010).

Otto et al. (2013) avaliaram a fotossíntese e a produtividade de quatro clones de *Eucalyptus* em duas áreas na Bahia: com precipitação bem distribuída ao longo do ano (área úmida) e com precipitação concentrada nos meses quentes do ano (área seca). A produtividade dos clones na área úmida foi 3,3 vezes superior à produtividade da área seca, devido a maior taxa fotossintética. Sette et al. (2010) também observaram relação entre o período de máximo crescimento das árvores de eucalipto com altos níveis de precipitação e temperatura, disponibilidade de água no solo, horas de luz/dia, e aumento da taxa fotossintética.

Martinkoski et al. (2015) utilizaram dendrocronologia para avaliar a influência de variáveis climáticas sobre o crescimento de *Araucaria angustifolia* em áreas de florestas nativas e observaram que, de forma geral, o fator mais limitante em um momento mais crítico, como o início da estação de crescimento, tende a expressar maior resposta, a qual é bastante atrelada as condições do local. Stape et al. (2008) avaliaram, durante dois anos, a influência da precipitação anual e a resposta à irrigação e fertilização no crescimento de plantios clonais de *Eucalyptus grandis* x *E. urophylla* no Brasil. Não foram observadas respostas à fertilização devido a fertilidade natural do solo e ciclagem eficiente de nutrientes, e a resposta à irrigação foi muito maior no ano mais seco, sendo que as parcelas irrigadas excederam a produção em 83 % em relação às parcelas controle, indicando uma forte resposta do eucalipto para o abastecimento de água durante a estação seca.

Gonçalves et al. (2014) avaliando a influência de fatores edáficos e climáticos sobre a produtividade da primeira (R1) e da segunda rotação (R2) de cultivo do eucalipto manejadas nos sistemas de alto fuste e talhadia, respectivamente, observaram grande variação da produtividade entre R1 e R2. O fator que mais influenciou as diferenças de produtividade entre as rotações de cultivo foi a precipitação. Em Inhambupe, a precipitação foi de 1100 mm ano⁻¹ em R1 e de 774 mm ano⁻¹ em R2, e o IMA foi 32 % menor em R2. Entretanto, nos locais onde a precipitação pluviométrica foi maior na segunda rotação de cultivo, a produtividade dessa rotação foi maior que a da primeira rotação.

Machado et al. (2014) estudaram o efeito de variáveis climáticas no crescimento em diâmetro e altura de *Pinus taeda* e *Araucaria angustifolia* no período de três anos e observaram forte relação do incremento corrente mensal com a temperatura, pressão atmosférica e

fotoperíodo. Zanon e Finger (2010) também correlacionaram o crescimento das árvores de *Araucaria angustifolia* com as variáveis meteorológicas e observaram que o aumento da temperatura e da precipitação influi positivamente no crescimento das árvores. Os maiores incrementos foram associados às maiores temperaturas médias mensais e também aos períodos em que houve maior precipitação.

A temperatura tem influência indireta no crescimento das plantas, uma vez que afeta os processos fisiológicos, influenciando diretamente na fotossíntese, respiração, permeabilidade da parede celular, absorção de água e nutrientes, transpiração, atividade enzimática e coagulação de proteínas (MEURER, 2007). O crescimento das plantas ocorre numa grande amplitude de temperatura, mas nessa faixa existe uma considerada ótima (CAMPOS, 1970), que é variável entre espécies e cultivares, de acordo com a idade e fase de desenvolvimento da planta (MEURER, 2007).

Temperaturas elevadas durante a estação de crescimento podem limitar a produção de enzimas e hormônios que são necessários para que determinados processos fisiológicos ocorram, afetando assim o crescimento e desenvolvimento das plantas (FRITTS, 1976, citado por MARTINKOSKI et al., 2015). Com a mudança climática, projeções para o final deste século sugerem que a temperatura global aumentará entre 1,8 e 4,0 °C (IPCC, 2007, citado por DAMATTA et al., 2010). Segundo esses autores, altas temperaturas reduzem o ganho líquido de carbono devido ao aumento da fotorrespiração, além disso, temperaturas mais altas estão normalmente relacionadas com fechamento dos estômatos, o que diminui ainda mais a fotossíntese devido ao menor influxo de CO₂, ocasionando redução na produtividade, que dependerá da latitude da região.

Apesar da influência comprovada das variáveis climáticas na produtividade florestal, Soares e Leite (2000) citam algumas dificuldades da utilização dessas variáveis em modelos de crescimento e produção como, por exemplo, problemas estatísticos relacionados à alta correlação entre as variáveis independentes do modelo e dificuldade na determinação das probabilidades de ocorrência de níveis das variáveis climáticas. Em contrapartida, não considerar os fatores climáticos pode causar interpretações erradas em relação ao crescimento final. Em experimentos avaliando o efeito de tratamentos culturais na produtividade, por exemplo, é mais fácil a comparação entre os produtos finais, porém, uma irregularidade climática que possa ter ocorrido durante o período avaliado pode mascarar o resultado ou induzir a uma conclusão errônea (FERRAZ, 1993).

2.2.2. Fatores edáficos e fisiográficos

O relevo de um local tem grande influência sobre os seus fatores climáticos, edáficos e bióticos. Os fatores fisiográficos são relacionados à geografia do local, e podem influenciar o solo da região, por exemplo, é esperado que as partes baixas do relevo possuam maior fertilidade devido ao processo de erosão nas encostas (CAMPOS, 1970). Braga et al. (1999) avaliaram as características ambientais determinantes da qualidade de sítios florestais para *Eucalyptus grandis* de 5,5 anos de idade em Minas Gerais e observaram que os sítios mais produtivos ocupavam áreas de menor declividade e altitude, pedofoma côncava, com maior insolação, e perfis de solo mais desenvolvidos e com horizonte superficial mais estruturado. O mesmo foi observado por Ortiz et al. (2006), que relacionaram o potencial produtivo de clones de *Eucalyptus grandis* aos 6,3 anos de idade, em São Paulo, com atributos do solo e relevo, e observaram que as áreas de maior potencial produtivo ocupavam posição menos elevada no relevo.

Segundo Camargo et al. (2004), o solo é o fator ambiental de maior relevância na produtividade vegetal. Suas propriedades físicas, químicas e biológicas influenciam o crescimento e desenvolvimento das plantas, uma vez que determinam a disponibilidade de oxigênio, água e nutrientes.

O material de origem do solo e o intemperismo, influenciado pelo clima e relevo, são determinantes na composição mineralógica e disponibilidade de nutrientes para as plantas. Os minerais existentes nos solos podem ser divididos em minerais primários e secundários. Os minerais primários tendem a ser herdados do material de origem e indicam a capacidade do solo em repor nutrientes para as plantas, e, na maioria dos solos brasileiros, concentram-se nas frações mais grosseiras (areia e silte); já os secundários originam-se por alteração da estrutura de minerais primários ou por síntese de produtos resultantes do intemperismo e são os constituintes principais da fração argila (CASTRO et al., 2010).

A propriedade que descreve o tamanho das partículas do solo, textura, é altamente relacionada com a estrutura do mesmo e tem grande importância nas relações solo-água-planta-atmosfera (MEURER, 2007), influenciando a disponibilidade hídrica, de oxigênio e nutrientes. Em solos de textura arenosa, mais grossa, apesar da aeração ser maior, a retenção de água é menor, devido ao pequeno espaço capilar (CAMPOS, 1970). Ortiz et al. (2006) observaram maior potencial produtivo de clones de *Eucalyptus grandis* em locais com maiores teores de areia total (aproximadamente 60 %), uma vez que esses locais possuem maior porosidade e permeabilidade, beneficiando a aeração, penetração e crescimento do sistema radicular,

favorecendo a absorção de água e nutrientes. Já, Gava e Gonçalves (2008), avaliando o efeito de atributos físicos e químicos do solo na produção de madeira de *Eucalyptus grandis* (6,5 a 7 anos de idade), concluíram que os atributos físicos do solo, sobretudo o teor de argila, diretamente relacionado à quantidade de água disponível, foram os que mais afetaram a produtividade e a qualidade da madeira.

A água é essencial para o crescimento das plantas, uma vez que faz parte de todos os processos fisiológicos e bioquímicos, representando quase 90 % do peso fresco dos tecidos em crescimento (CAMPOS, 1970). Tanto sua escassez como excesso prejudicam o crescimento e desenvolvimento das plantas. Castro et al. (2010) observaram diferença no incremento médio anual (IMA) de povoamentos de eucalipto com 7 anos de idade em função dos atributos dos solos, sendo que solos bem drenados tiveram o IMA ($\geq 46 \text{ m}^3 \text{ ha}^{-1}\text{ano}^{-1}$) maior que em solos com risco de anoxia ($40 \text{ m}^3 \text{ ha}^{-1}\text{ano}^{-1}$) e solos muito arenosos ($38 \text{ m}^3 \text{ ha}^{-1}\text{ano}^{-1}$).

A disponibilidade de água no solo afeta substancialmente a eficiência da utilização de recursos, bem como a biomassa total e sua alocação para as raízes, caules e folhas (STAPE et al., 2004). É importante enfatizar que o crescimento da planta não é diretamente controlado pela umidade do solo, mas pelo balanço de água na planta em função da absorção e transpiração, que são afetados pela água disponível no solo e umidade do ar (CAMPOS, 1970). A deficiência de água no solo diminui o potencial hídrico, fazendo com que os estômatos se fechem para que possa ser mantido um potencial de água da folha acima de um valor crítico (TONELLO, 2010), ocorrendo redução no influxo de CO_2 e, conseqüentemente, da fotossíntese. Além disso, a disponibilidade de água no sistema é fundamental para que a planta possa absorver os nutrientes, principalmente aqueles em que o transporte até as raízes ocorre por fluxo de massa.

Além da quantidade de água no sistema, é fundamental considerar o estado de energia da água no solo, uma vez que para a absorção de água acontecer, as células da epiderme das raízes devem estar num potencial mais negativo do que a água que está no solo (LOPES et al., 2011). Diversos fatores influenciam a absorção de água no solo, sendo eles referentes à planta (extensão e profundidade do sistema radicular, idade da raiz, atividade metabólica da planta), à atmosfera (umidade relativa do ar, radiação solar, vento, temperatura do ar), e solo (umidade, capacidade de água disponível, condutividade hidráulica, temperatura, aeração e salinidade da água no solo) (REICHARDT, 1976, 1978, citado por MEURER, 2007).

Em relação aos fatores de natureza química do solo, o pH é um dos mais importantes, pois influencia, direta ou indiretamente, os outros fatores, como a disponibilidade de nutrientes, solubilidade de elementos que podem ser tóxicos para as plantas, e atividade de microrganismos

(MEURER, 2007). Segundo esse autor, de maneira geral, o pH favorável ao crescimento da maioria das plantas está entre 5,5 e 6,5, e abaixo de 5,5 pode haver danos ao crescimento em função da elevada concentração de Al e Mn, elementos potencialmente tóxicos. Para o eucalipto, maiores produções são relacionadas a menores teores de alumínio (ORTIZ et al., 2006). Em pH mais ácidos a disponibilidade dos micronutrientes, com exceção do Mo e Cl, também é maior, já os macronutrientes N, P, K, Ca, Mg e S apresentam maior disponibilidade na faixa de 6,0 a 6,5 (MEURER, 2007).

A disponibilidade de nutrientes no solo é muito relevante para o desenvolvimento vegetal, sobretudo para as culturas de ciclo longo como o eucalipto, e pode ser avaliada por meio das análises química e física dos solos (CASTRO et al., 2010). Sgarbi (2002) avaliou o crescimento de eucalipto de 12 a 45 meses de idade, em três regiões distintas em São Paulo, em função da fertilidade do solo e obteve diferentes respostas nas regiões estudadas. Em Capão Bonito e Jacareí, os nutrientes mais limitantes para o crescimento de eucalipto foram o boro, fósforo e nitrogênio, e em Lençóis Paulistas, a limitação ocorreu devido aos menores teores de magnésio e potássio no solo. Borges (2012) concluiu que a produtividade potencial de madeira de eucalipto aos seis anos, no Brasil, varia quanto à demanda nutricional na seguinte ordem: Ca > N > K > Mg > P.

No entanto, a maioria dos solos brasileiros possui elevada acidez e baixa disponibilidade de nutrientes, principalmente fósforo, que pode ser responsável pelo menor desenvolvimento das plantas (FURTINI NETO et al., 1999). A baixa disponibilidade de P em solos tropicais ocorre devido ao elevado poder de adsorção/fixação desse nutriente (NOVAIS e SMYTH, 1999).

Apesar de limitarem o crescimento das plantas, a acidez do solo, compactação, disponibilidade de água e nutrientes podem ser manejados e corrigidos através do preparo do solo, adubação, correção do pH, irrigação, utilização de sistemas de cultivo mínimo, cobertura verde, entre outros.

2.3. Fatores bióticos

Como fatores bióticos entende-se a ação de animais e plantas, superiores ou não, que também possuem inter-relação com os fatores edáficos e climáticos (CAMPOS, 1970). Segundo esse autor, o homem é o mais importante dos fatores bióticos, por alterar os fatores biológicos e físicos do meio. A introdução, pelo homem, de espécies exóticas de ambientes distantes, mas semelhantes, em locais que apenas espécies e gêneros nativos da área tinham

acesso, modifica a composição e estrutura do ecossistema, uma vez que essas espécies podem se estabelecer e até desenvolver melhor que no seu local de origem (BILLINGS, 1952).

A influência dos fatores bióticos no crescimento e desenvolvimento das árvores pode ser benéfica ou não. Como exemplo de efeito positivo no crescimento do componente arbóreo, destacam-se a associação com bactérias fixadoras de N e fungos micorrízicos. As bactérias capazes de fixar N₂ atmosférico suprem a demanda desse nutriente pelas plantas, e os fungos micorrízicos podem aumentar a solubilidade de fontes menos solúveis de fosfatos (MEURER, 2007), além de aumentar o volume de solo explorado, favorecendo a absorção de nutrientes (SOUZA et al., 2006).

Como fator biótico limitante à produtividade florestal, Tarouco et al. (2010) destacam a presença de plantas daninhas. Segundo esses autores, a cultura de eucalipto é muito sensível à competição por água, luz e nutrientes, com as plantas daninhas, na fase de implantação do povoamento, particularmente com espécies de rápido crescimento como as gramíneas. Toledo et al. (2003) avaliaram a interferência das plantas daninhas sobre a produtividade de eucalipto e observaram uma redução de volume de madeira de 61,6 % aos 48 meses nas parcelas em que não houve controle das plantas daninhas.

Em relação à competição intraespecífica, a intensidade da competição vai variar de acordo com o genótipo, disponibilidade de recursos e distância entre os indivíduos. A quantidade de biomassa produzida pode ser influenciada pela competição imposta pelo espaçamento de plantio, e quanto mais adensados os plantios, maior a competição pelos recursos disponíveis (LAFETÁ, 2012). Resende et al. (2016) observaram que em condições de plantios mais densos (6 m² planta⁻¹) a relação de produtividade e competição foi maior que em plantios de menor densidade (10 m² planta⁻¹). Esses autores também observaram que a competição de árvores de eucalipto varia de acordo com a distância entre elas, sendo observado menor efeito da competição na diagonal que nas linhas e entrelinhas.

A posição sociológica e a vitalidade das árvores também influenciam a capacidade de aproveitamento dos recursos (ZANON e FINGER, 2010). Esses autores observaram que árvores dominadas de *Araucaria angustifolia* apresentaram um menor crescimento em relação às dominantes ou codominantes, mesmo em condições favoráveis de crescimento.

2.4. Genótipo

A produção vegetal é resultante dos fatores ambientais e do potencial hereditário da planta (CAMPOS, 1970). A distribuição geográfica de uma espécie ocorre de acordo com sua genética, que determina seus limites de tolerância aos fatores do ambiente (BILLINGS, 1952).

Assim, a seleção ótima de genótipos, de acordo com o ambiente, promove o aumento da produção sem necessariamente aumentar a área de plantio, o que é extremamente desejável, uma vez que a terra é um recurso cada vez mais escasso (MARCATTI et al., 2017). Esses autores ajustaram modelos para estimar o volume de povoamentos de eucalipto para uma determinada área e observaram que o modelo que considerou o genótipo teve capacidade preditiva melhor comparado ao que não considerava, indicando seu efeito significativo na produção.

Os genótipos são selecionados de acordo com sua produtividade, que está relacionada a capacidade de utilizar os recursos do meio ambiente e resistência a estresses bióticos e abióticos. Tonello e Teixeira Filho (2011) caracterizaram o comportamento ecofisiológico de dois clones comerciais de *Eucalyptus grandis* x *Eucalyptus urophylla*, com a mesma idade no mesmo local de plantio, e observaram diferenças nas respostas dos clones em função das variáveis ambientais, assim como em relação à eficiência do uso da água. Segundo os autores, esse tipo de informação pode ser utilizado na melhor adequação dos planos de manejo florestal de acordo com a especificidade ecofisiológica de cada clone.

A eficiência do uso de nutrientes varia de acordo com as espécies florestais, procedências e/ou clones, e sua avaliação de acordo com o genótipo auxilia o silvicultor na escolha do material a ser utilizado nos projetos florestais (CALDEIRA et al., 2002). Faria et al. (2008) avaliaram a eficiência de utilização de nutrientes de híbridos de *Eucalyptus* na região do Vale do Jequitinhonha, Minas Gerais, e observaram diferença na produtividade, absorção e utilização de N, P, K, Ca e Mg entre os híbridos. A absorção de nutrientes é influenciada pelas características da planta, morfológicas (eficiência e extensão sistema radicular, relação raiz/parte aérea, associação com bactérias ou micorrizas) e fisiológicas (habilidade da raiz modificar a rizosfera, taxa fotossintética, metabolismo) (MEURER, 2007).

O surgimento de novos genótipos, métodos de preparo de solo, espaçamento de plantio, fertilização mineral e controle de plantas daninhas proporcionaram grandes ganhos de produtividade, implicando na necessidade de alocação de genótipos específicos para cada área e nível tecnológico utilizado (GONÇALVES et al., 2014). Porém, na maioria das empresas florestais brasileiras, essa análise é ignorada e, em geral, o clone que apresenta melhor

produtividade e possui boa propagação em viveiro é plantado em larga escala, mas, muitas vezes, a empresa possui milhares de hectares e pode conter ambientes diferenciados, onde esses clones não apresentam desempenho conforme o esperado (SANTOS et al., 2015).

2.5. Práticas silviculturais e manejo

São diversas as práticas adotadas para possibilitar o melhor desenvolvimento do povoamento florestal, como preparo do solo (ROCHA et al., 2015), espaçamento de plantio (ASSIS et al., 2006; LAFETÁ, 2012), fertilização (SILVA et al., 2016; CAMPOE et al., 2013; STAPE et al., 2004; PULITO et al., 2015; SETTE JR et al., 2010), controle de matocompetição (TOLEDO et al., 2003; TAROUCO et al., 2010), entre outras.

Na fase inicial de crescimento, as plantas são mais sensíveis à competição por recursos do meio, sendo fundamental um bom preparo do solo e eficiente controle das plantas daninhas para garantir o sucesso da formação de florestas (TAROUCO et al., 2010).

O preparo do solo é feito para melhorar as condições físicas, eliminar plantas indesejáveis e camadas compactadas, promover o armazenamento de água no solo, incorporar fertilizantes, calcário, restos culturais, e fazer o nivelamento do solo facilitando o plantio, manutenção e colheita (PAIVA et al., 2011). A escolha do sistema de preparo de solo (mínimo ou convencional) deve levar em consideração as necessidades da cultura implantada e também as características edáficas e climáticas do local, uma vez que pode alterar as propriedades do solo e, conseqüentemente, as produtividades atuais e futuras.

Rocha et al. (2015) avaliaram as alterações nas propriedades físicas de um Argissolo Vermelho-Amarelo distrófico arênico e o crescimento de *Eucalyptus grandis* em função de diferentes métodos de preparo do solo (coveamento manual, escarificado, escarificado mais grade niveladora e enxada rotativa). Esses autores observaram que, após seis anos do preparo do solo, não ocorreu diferença significativa entre os tratamentos para as propriedades físicas do solo, nem para o crescimento do eucalipto, embora o coveamento manual tenha causado efeito negativo na sobrevivência das árvores. No entanto, não se pode deixar de enfatizar as vantagens do preparo reduzido do solo, como redução dos riscos de erosão, aumento do teor de MO na camada superficial e da CTC, redução do efeito fitotóxico do Al, melhoria das propriedades físicas do solo, e estímulo da atividade biológica (MEURER, 2007).

Entre os recursos requeridos para o crescimento das plantas, a disponibilidade de nutrientes é a mais fácil de manejar através da fertilização, práticas de preparo e conservação do solo (SILVA et al., 2016). A quantidade, tipo e a época da aplicação dos fertilizantes podem

alterar a produção e a qualidade da madeira, sendo que tais mudanças dependem da espécie e da fertilidade do solo (BERGER et al., 2002).

A amostragem do solo é a primeira e principal etapa de um programa de avaliação da fertilidade do solo, pois a interpretação e definição das doses de corretivos e fertilizantes são feitas de acordo com a análise química e física do solo (RIBEIRO et al., 1999). Para avaliar a efetividade das fertilizações e possibilitar ajustes que garantam a produtividade desejada, é feita a avaliação nutricional através da análise de tecido das plantas (LOURENÇO, 2012).

Em Minas Gerais, muitos solos apresentam alta saturação por Al, o que limita a exploração do solo pelas raízes na busca por umidade e nutrientes (VALE et al., 1996). A calagem tem sido uma prática bastante utilizada para corrigir essa propriedade do solo, possibilitando o melhor desenvolvimento das espécies cultivadas. A aplicação de corretivos tem como objetivo diminuir as concentrações tóxicas de Al e Mn, proporcionar condições favoráveis ao desenvolvimento de microrganismos decompositores da matéria orgânica, nitrificadores e fixadores de N, aumentar a disponibilidade de P e Mo, e fornecimento de Ca e Mg (MALAVOLTA, 1980).

Cabe ressaltar que as culturas e cultivares variam na sua tolerância ou sensibilidade à acidez do solo, saturação por bases e por alumínio, e disponibilidade de nutrientes (RIBEIRO et al., 1999). Dessa forma, na avaliação da fertilidade do solo, devem ser consideradas as exigências das espécies florestais.

Para otimizar os investimentos na silvicultura é fundamental entender as respostas espaciais da fertilização em florestas de produção (SILVA et al., 2016). Deve-se atentar para o risco em extrapolar resultados específicos, como a resposta de um material genético à fertilização efetuada em apenas um local (HAKAMADA, 2012).

Silva et al. (2016) avaliaram o crescimento de eucalipto em função da fertilização em diferentes condições edafoclimáticas no Brasil (três regiões na Bahia), sendo que a primeira e segunda regiões possuem solos bem arenosos (aproximadamente 90 % de areia e 10 % de argila), e a terceira possui solo com aproximadamente 41 % de argila e mais MO que as outras. Foi observado, no geral, aumento no incremento anual de 24 % nas parcelas que receberam fertilização (N, P, K, Ca e Mg), e que a terceira região teve o maior IMA devido à ausência de período seco nessa região e maior teor de argila e matéria orgânica, possibilitando maior retenção da umidade. Já na região 1, na qual a água é um fator limitante, o aumento na fertilização não proporcionou grande resposta na produtividade.

Recomendações silviculturais mais ajustadas, considerando as diferenças do sítio, e a execução das operações de forma eficiente resultam em fornecimento mais homogêneo dos recursos e, conseqüentemente, na uniformidade do povoamento (HAKAMADA et al., 2015). Resende et al. (2016) estudaram os padrões de crescimento de plantios clonais de *Eucalyptus* e observaram que sítios de maior uniformidade apresentaram maiores produtividades.

Soares et al. (2016) observaram correlação negativa entre a heterogeneidade do povoamento de eucalipto e a produtividade, e que essas variáveis aumentaram com maiores densidades de plantio. Em geral, no estudo citado, o efeito positivo da densidade sobre a produtividade foi maior que o efeito negativo da heterogeneidade resultante da intensificação da competição por recursos.

A escolha do espaçamento é uma etapa importante do projeto florestal, pois influencia o aproveitamento dos recursos de crescimento disponíveis, assim como a condução da floresta e sua produtividade final. Espaçamentos mais adensados, para a mesma condição edáfica e climática e mesmo genótipo, são inicialmente mais produtivos, tendem a estagnar o crescimento e atingir o potencial produtivo do local em idades mais jovens (LAFETÁ, 2012). Segundo esse autor, para a produção de carvão e celulose, têm sido recomendados espaçamentos em torno de seis a nove metros quadrados como os mais adequados economicamente. Entretanto, quando houver restrição de recursos, água e nutrientes, devem ser adotados plantios com menores densidades (LEITE et al., 1999).

A densidade populacional pode ser alterada com a utilização de desbastes, que consiste na remoção de algumas árvores de forma a favorecer o crescimento das árvores remanescentes, uma vez que diminui a competição por recursos no povoamento. A estagnação do crescimento tem sido utilizada como referência para decidir quando desbastar. Nos espaçamentos mais adensados, a estagnação do crescimento acontece mais precocemente, resultando em menores idades técnicas para a aplicação do desbaste (MEDEIROS, 2016). Esse autor observou, em plantios de teca, que apesar da produção total ser maior nos espaçamentos mais adensados, devido ao maior número de indivíduos, o volume individual das árvores foi menor, principalmente por apresentarem menor diâmetro.

Segundo Otto et al. (2014), a redução do número de indivíduos numa área é fundamental quando alguns fatores de crescimento são menos disponíveis, por exemplo, em locais com déficit hídrico, a manipulação da densidade em povoamentos de eucalipto pode minimizar o conflito entre o crescimento e o uso da água pelas plantas.

O desbaste pode mudar a distribuição de dominância na floresta, e, conseqüentemente, a heterogeneidade da mesma, uma vez que diminui a competição entre as árvores (SOARES et al., 2017). Esses autores concluíram que o desbaste por baixo em eucalipto reduziu o nível de heterogeneidade e dominância de crescimento, e que essa diminuição está diretamente relacionada à intensidade de desbaste. Já após o segundo desbaste, tanto a heterogeneidade como o domínio de crescimento foram reduzidos a níveis muito baixos, que permaneceram constantes ao longo do tempo ou diminuíram para a intensidade de desbaste mais intensa, indicando a homogeneização do povoamento devido a uma maior resposta de crescimento das árvores intermediárias. Isso pode ser explicado pelo fato das árvores dominantes já terem maior acesso à luz, assim o aumento da disponibilidade desse fator deve ser mais relevante para as árvores não-dominantes.

As mudanças na arquitetura da copa também influenciam o crescimento e a incidência de luz nos povoamentos, bem como a eficiência do uso de luz (LUE) (FORRESTER et al., 2013). Esses autores observaram aumento na LUE após a poda da parte inferior das copas das árvores de eucalipto e aumento na partição de C para a biomassa acima do solo, uma vez que as plantas, após a poda, tentam reestabelecer as copas e restaurar o equilíbrio entre elas e o sistema radicular.

Em relação à condução da floresta no Brasil, por muito tempo acreditou-se que o sistema de talhadia proporcionava menor produtividade que o de alto fuste. Após a crise econômica mundial, em 2008, a produção de madeira por meio da condução da brotação de eucalipto voltou a ser utilizada (GONÇALVES et al., 2014), e estudos tem observado produtividade semelhante entre os dois sistemas, desde que adotadas práticas silviculturais adequadas (fertilização, desbrota, por exemplo). Aumentar a eficiência do uso dos recursos naturais por meio da alocação adequada dos genótipos às condições edafoclimáticas e do uso adequado de práticas silviculturais é um desafio fundamental, no sentido de manter ou aumentar a produtividade da talhadia, uma vez que para reduzir despesas, muitas empresas pararam seus programas de implantação e reforma florestal, passando a adotar a talhadia como única forma de manejo (GONÇALVES et al., 2014).

Gadelha et al. (2015) avaliaram o desenvolvimento volumétrico de três clones de *Eucalyptus* spp. conduzidos sob os sistemas de alto fuste e talhadia, no espaçamento 3 x 2 m em Pernambuco. Foi observado que nos primeiros dois anos o sistema de talhadia apresentou maior produtividade que no de alto fuste para alguns clones, mas com o passar do tempo essa diferença reduziu. De acordo com Jerzolinsk (2006), a diferença na produção florestal entre

talhadia e alto fuste depende da capacidade produtiva do sítio e idade do povoamento. Em locais de alta capacidade produtiva, em idade próxima à idade técnica de corte, a perda em volume de eucalipto no regime de talhadia em relação ao regime de alto fuste é maior. Já, em idades jovens, a produção em talhadia pode ser maior que a produção em alto fuste, mesmo quando for deixado apenas um fuste por cepa. Com o passar do tempo, dependendo da capacidade produtiva do local, essa diferença diminui e até muda, sendo que a produção tende a se igualar entre talhadia e alto fuste em idades menores quanto maior a capacidade produtiva do local.

Quando se pensa em produtividade florestal, todos os fatores, bióticos e abióticos, devem ser levados em consideração, assim como a maneira que a floresta será conduzida e explorada. A colheita de uma floresta tem grande impacto na produtividade das próximas rotações, uma vez que, dependendo do sistema adotado, pode causar grande impacto nas propriedades do solo, promover maior exportação de nutrientes, e causar danos no crescimento de brotos em florestas nas quais será conduzida a talhadia.

De acordo com os atributos edáficos como a textura e a mineralogia do solo, os impactos relacionados ao tráfego de máquinas podem potencializar o processo de compactação do solo, alterando suas propriedades químicas, físicas e biológicas, como aumento da densidade e resistência à penetração, e redução na porosidade e condutividade hidráulica do solo (SILVA et al., 2008; JESUS et al., 2015). No entanto, algumas decisões podem ser adotadas para reduzir esse impacto negativo no ambiente. A permanência dos resíduos da colheita atenua a perda de produtividade causada pela compactação do solo, além de evitar a redução dos teores de C orgânico total e de frações mais lábeis de C e N do solo (JESUS et al., 2015).

Como pode ser visto, são inúmeros os fatores que influenciam, direta ou indiretamente, a produtividade florestal, e a maioria deles está inter-relacionada. Como discutido por Billings (1952), o crescimento de uma planta é dependente de quantidades mínimas de fatores ambientais durante seu ciclo de vida, entretanto, o ambiente em que uma planta cresce é constantemente alterado no tempo e espaço. Se um fator se torna crítico justamente na época crítica do ciclo de vida da planta, como germinação, crescimento inicial da muda, floração, frutificação, pode ocorrer a morte do indivíduo ou indivíduos no local. Ressalta-se que o crescimento vegetal não está limitado apenas pelas condições mínimas de um determinado fator, mas também quando ele está acima do nível de tolerância da mesma, variável de acordo com a espécie, e que um fator limitante para um genótipo, pode não ser limitante para outro (BILLINGS, 1952; CAMPOS, 1970).

Sendo assim, não existe uma receita geral estabelecida para a implantação e condução de um empreendimento florestal. Para obter florestas de alta produtividade, as características ambientais e necessidades da cultura devem ser sempre consideradas. O uso de alto nível tecnológico, com a utilização de genótipos selecionados, juntamente com práticas silviculturais e manejo adequado permitem ganhos em produtividade cerca de duas vezes comparando com plantios convencionais (GUIMARÃES et al., 2007).

2.6. Referências bibliográficas

ASSIS, R.L.; FERREIRA, M.M.; CARGNELUTTI FILHO; A. Estado nutricional de *Eucalyptus urophylla* S.T. Blake sob diferentes espaçamentos na região de cerrados de Minas Gerais. **Pesquisa Agropecuária Tropical**, v.36, n.3, p.151-157, 2006.

BARROS, N. F. **Contribuição ao relacionamento de características pedológicas e topográficas com a altura de *Eucalyptus alba*, na região de Santa Bárbara.** 1974. 89 f. Dissertação (Mestrado em Ciência Florestal) – Universidade Federal de Viçosa, 1974.

BERGER, R.; SCHNEIDER, P.R.; FINGER, C.A.G.; HASELEIN, C.R. Efeito do espaçamento e da adubação no crescimento de um clone de *Eucalyptus saligna* Smith. **Ciência Florestal**, v.12, n.2, p.75-87, 2002.

BILLINGS, W.D. The Environmental Complex in Relation to Plant Growth and Distribution. **The Quarterly Review of Biology**, v.27, n.3, p.251-265, 1952.

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

BRAGA, F.A.; BARROS, N. F.; SOUZA, A. L.; COSTA, L. M. Características ambientais determinantes da capacidade produtiva de sítios cultivados com eucalipto. **Revista Brasileira de Ciência do Solo**, v.23, p.291-298, 1999.

CALDEIRA, M. V. W.; RONDON NETO, R. M.; SCHUMACHER, M. V. Avaliação da eficiência nutricional de três procedências australianas de acácia-negra (*Acacia mearnsii* De Wild.). **Revista Árvore**, v. 26, n. 5, p. 615-620, 2002.

CAMARGO, M. L. P. de; MORAES, C. B. de; MORI, E. S.; GUERRINI, I. A.; MELLO, E. J. de; ODA, S. Considerations on nutritional efficiency in *Eucalyptus*. **Científica**, v.32, n.2, p.191-196, 2004.

CAMPOE, O.T.; STAPE, J.L.; ALBAUGH, T.J.; ALLEN, H.L.; FOX, T.R.; RUBILAR, R.; BINKLEY, D. Fertilization and irrigation effects on tree level aboveground net primary production, light interception and light use efficiency in a loblolly pine plantation. **Forest Ecology and Management**, v.288, p.43-48, 2013.

CAMPOS, J.C.C. Principais fatores do meio que afetam o crescimento das árvores. **Floresta**, v. 2, n. 3, p.45-52, 1970.

CASTRO, P.P.; CURI, N., FURTINI NETO, A.E.; RESENDE, A.V.; GUILHERME, L.R.G.; MENEZES, M.D.; ARAÚJO, E.F.; FREITAS, D.A.F.; MELLO, C.R.; SILVA, S.H.G.

Química e mineralogia de solos cultivados com Eucalipto (*Eucalyptus* sp.). **Scientia Forestalis**, v. 38, n. 88, p. 645-657, 2010.

DAMATTA, F. M.; GRANDIS, A.; ARENQUE, B. C.; BUCKERIDGE, M. S. Impacts of climate changes on crop physiology and food quality. **Food Research International**, v.43, n.7, p.1814-1823, 2010.

FARIA, G. E.; BARROS, N. F.; CUNHA, V. L. P.; MARTINS, I. S.; MARTINS, R. D. C. C. Avaliação da produtividade, conteúdo e eficiência de utilização de nutrientes em genótipos de *Eucalyptus* spp. no vale do Jequitinhonha, MG. **Ciência Florestal**, v. 18, n. 3, p. 363-373, 2008.

FERRAZ, E.S.B. A influência da precipitação na produção de matéria seca de eucaliptos. **IPEF**, n.46, p.32-42, 1993.

FERREIRA, M.Z. **Modelagem da influência de variáveis ambientais no crescimento e produção de *Eucalyptus* sp.** 2009. 101f. Tese (Mestrado em Ciências Florestais) - Universidade Federal de Lavras, 2009.

FORRESTER, D.I.; COLLOPY, J.J.; BEADLE, C.L.; BAKER, T.G. Effect of thinning, pruning and nitrogen fertiliser application on light interception and light-use efficiency in a young *Eucalyptus nitens* plantation. **Forest Ecology and Management**, v.288, p.21–30, 2013.

FURTINI NETO, A. E.; RESENDE, A. V.; VALE, F. R.; FAQUIN, V.; FERNANDES, L. A. Acidez do solo, crescimento e nutrição mineral de algumas espécies arbóreas, na fase de muda. **Cerne**, Lavras, v.5, n.2, p.01-12, 1999.

GADELHA, F. H.L.; DA SILVA, J. A. A.; FERREIRA, R. L. C.; DOS SANTOS, R. C.; TAVARES, J. A. Produtividade de clones de eucaliptos em diferentes sistemas de manejo para fins energéticos. **Pesquisa Florestal Brasileira**, v.35, n.83, p.263-270, 2015.

GAVA, J. L.; GONÇALVES, J.L.M. Soil attributes and wood quality for pulp production in plantations of *Eucalyptus grandis* clone. **Scientia Agricola**, v.65, n.3, p.306-313, 2008.

GONÇALVES, J. L. M.; ALVARES, C. A.; BEHLING, M.; ALVES, J. M.; PIZZI, G. T.; ANGELI, A. Produtividade de plantações de eucalipto manejadas nos sistemas de alto fuste e talhadia, em função de fatores edafoclimáticos. **Scientia Forestalis**, v. 42, n. 103, p. 411-419, 2014.

GUIMARÃES, D.P.; SILVA, G.G.C.; SANS, L.M.A.; LEITE, F.P. Uso do modelo de crescimento 3-PG para o zoneamento do potencial produtivo do eucalipto no estado de Minas Gerais. **Revista Brasileira de Agrometeorologia**, v.15, n.2, p. 192-197, 2007.

HAKAMADA, R.E. **Uso do inventário florestal como ferramenta de monitoramento da qualidade silvicultural em povoamentos clonais de *Eucalyptus*.** 2012. 114 p. Dissertação (Mestrado em Recursos Florestais) - Escola Superior de Agricultura “Luiz de Queiroz”, 2012.

HAKAMADA, R.E.; STAPE, J.L.; LEMOS, C.C.Z; ALMEIDA, A.E.A; SILVA, L.F. Uniformidade entre árvores durante uma rotação e sua relação com a produtividade em *Eucalyptus* clonais. **Cerne**, v. 21, n. 3, p. 465-472, 2015.

JEROZOLIMSKI, R. **Crescimento e produtividade de eucalipto em regimes de alto fuste e de talhadia**. 2006. 17f. Monografia (Graduação em Engenharia Florestal) - Universidade Federal de Viçosa, Viçosa, MG, 2006.

JESUS, G. L.; SILVA, I.R.; ALMEIDA, L. F.J.; SANTOS, M.A.; LEITE, F.P.; NEVES, J. C.L. produtividade do eucalipto, atributos físicos do solo e frações da matéria orgânica influenciadas pela intensidade de tráfego e resíduos de colheita. **Revista Brasileira de Ciência do Solo**, v. 39, n. 4, p. 1190-120, 2015.

LAFETÁ, B. O. **Eficiência nutricional, área foliar e produtividade de plantações de eucalipto em diferentes espaçamentos estimados com redes neurais artificiais**. 2012.76f. Dissertação (Mestrado em Ciência Florestal) - Universidade Federal dos Vales do Jequitinhonha e Mucuri,2012.

LEITE, F. P.; BARROS, N. F.; NOVAIS, R. F.; SANS, L. M. A.; FABRES, A. S. Relações hídricas em povoamento de eucalipto com diferentes densidades populacionais. **Revista Brasileira de Ciência do Solo**, v. 23, n. 1, p. 9–16, 1999.

LERAYER, A. **Guia do Eucalipto: oportunidades para um desenvolvimento sustentável**. São Paulo: Conselho de Informações sobre Biotecnologia. 2008. Disponível em: http://cib.org.br/wp-content/uploads/2011/10/Guia_do_Eucalipto_junho_2008.pdf. Acesso em: 12 de novembro de 2016.

LOPES, J.L.W.; GUERRINI, I.A.; SILVA, M.R.; SAAD, J.C.C.; LOPES, C.F. Estresse hídrico em plantio de *Eucalyptus grandis* vs. *Eucalyptus urophylla*, em função do solo, substrato e manejo hídrico de viveiro. **Revista Árvore**, v.35, n.1, p.31-39, 2011.

LOURENÇO, H.M. **Diagnose nutricional de eucalipto e impacto da disponibilidade de água e nutrientes nos estoques de carbono do povoamento**. 2012. 113f. Tese (Doutorado em Solos e Nutrição de Plantas) – Universidade Federal de Viçosa. 2012.

MACHADO, A.S.; ZAMIN, N.T.; NASCIMENTO, R.G.M.; SANTOS, A.A.P. Efeito de Variáveis Climáticas no Crescimento Mensal de *Pinus taeda* e *Araucaria angustifolia* em Fase Juvenil. **Floresta e Ambiente**, v.21, n.2, p.170-181, 2014.

MALAVOLTA, E. **Elementos de nutrição mineral de plantas**. São Paulo: Ceres, 1980. 251p.

MARCATTI, G. E.; RESENDE, R. T.; RESENDE, M. D. V.; RIBEIRO, C. A. A.; DOS SANTOS, A. R.; DA CRUZ, J. P.; LEITE, H. G. GIS-based approach applied to optimizing recommendations of *Eucalyptus* genotypes. **Forest Ecology and Management**, v.392, 144-153, 2017.

MARTINKOSKI, L.; VOGEL, G. F.; JADOSKI, S. O.. Influência do clima no crescimento diamétrico de *Araucária angustifolia*: revisão bibliográfica. **Revista Brasileira de Tecnologia Aplicada nas Ciências Agrárias**, v. 8, n. 2, p.104-111, 2015.

MEDEIROS, R. A. **Potencial produtivo, manejo e experimentação em povoamentos de *Tectona grandis* Lf no Estado de Mato Grosso**. 2016. 182f. Tese (Doutorado em Ciência Florestal) - Universidade Federal de Viçosa, Viçosa, MG, 2016.

- MEURER, E. J. Fatores que influenciam o crescimento e o desenvolvimento de plantas. In: NOVAIS, R. F.; VENEGAS, V. H. A.; BARROS, N. F.; FONTES, R. L. F.; CANTARUTTI, R. B.; NEVES, J. C. L. (Ed.). **Fertilidade do solo**. Viçosa: SBCS, 2007. p. 65–90.
- MONTEZANO, Z. F.; CORAZZA, E. J.; MURAOKA, T. Variabilidade espacial da fertilidade do solo em área cultivada e manejada homoganeamente. **Revista Brasileira de Ciência do Solo**, v.30, p.839-847, 2006.
- NOVAIS, R. F.; SMYTH, T. J. **Fósforo em solo e planta em condições tropicais**. Viçosa: Sociedade Brasileira de Ciência do Solo, 1999. 399p.
- OLIVEIRA, B. R. U.; DE FIGUEIREDO LATORRACA, J. V.; TOMAZELLO FILHO, M.; GARCIA, R. A.; DE CARVALHO, A. M. Correlações dendroclimatológicas do *Eucalyptus grandis* Hill ex Maiden na região de Rio Claro, RJ. **Ciência Florestal**, v.21, n.3, p.499-508, 2011.
- ORTIZ, J. L.; VETTORAZZI, C. A.; COUTO, H. T. Z.; GONÇALVES, J. L. M. Relações espaciais entre o potencial produtivo de um povoamento de eucalipto e atributos do solo e do relevo. **Scientia Forestalis**, n. 72, p. 67-79, 2006.
- OTTO, M.S.G.; VERGANI, A.R.; GONÇALVES, A.N.; VRECHI, A.; SILVA, S.R.; E STAPE, J.L. Fotossíntese, condutância estomática e produtividade de clones de *Eucalyptus* sob diferentes condições edafoclimáticas. **Revista Árvore**, Viçosa-MG, v.36, v.37, n.3, p.431-439, 2013.
- OTTO, M.S.G.; HUBBARD, R.M.; BINKLEY, D.; STAPE, J.L. Dominant clonal *Eucalyptus grandis* x *urophylla* trees use water more efficiently. **Forest Ecology and Management**, v.328, p.117–121, 2014.
- PAIVA, H.N.; JACOVINE, L.A.G.; TRINDADE, C.; RIBEIRO, G.T. **Cultivo de eucalipto: Implantação e manejo**. 2 ed. Editora Aprenda Fácil, Viçosa, 2011.
- PULITO, A. P.; GONÇALVES, J.L.M.; SMETHURST, P.J.; ARTHUR JUNIOR, J.C.; ALVARES, C.A.; ROCHA, J.H.T.; HÜBNER, A.; MORAES, L.F.; MIRANDA, A.C.; KAMOGAWA, M.Y.; GAVA, J.L.; CHAVES, R.; SILVA, C.R. Available nitrogen and responses to nitrogen fertilizer in Brazilian eucalypt plantations on soils of contrasting texture. **Forests**, v.6, n.4, p.973-991, 2015.
- RESENDE, R. T.; MARCATTI, G. E.; PINTO, D. S.; TAKAHASHI, E. K.; CRUZ, C. D.; RESENDE, M. D. V. Intra-genotypic competition of *Eucalyptus* clones generated by environmental heterogeneity can optimize productivity in forest stands. **Forest Ecology and Management**, v. 380, p. 50-58, 2016.
- RIBEIRO, A. C; GUIMARÃES, P.T.G.; ALVAREZ V., V.H. **Recomendações para o uso de corretivos e fertilizantes em Minas Gerais: 5. Aproximação**. Viçosa: Comissão de fertilidade do solo do estado de Minas Gerais. 1999. 359p.
- RYDLEWSKI, C. **Os dilemas do primeiro eucalipto transgênico do mundo**. 2015. Disponível em: <http://epocanegocios.globo.com/Informacao/Dilemas/noticia/2015/01/os-dilemas-do-primeiro-eucalipto-transgenico-do-mundo.html>. Acesso em: 5 de dezembro de 2016.

- ROCHA, S. P.; PREVEDELLO, J.; REINERT, D. J.; FLEIG, F. D.; VOGELMANN, E. S.; SOARES, J. C. W.; HEINZ, B. B. Propriedades físicas do solo e crescimento de eucalipto implantado em diferentes métodos de preparo do solo. **Scientia Forestalis**. v. 43, n. 108, p. 965-977, 2015.
- RODY, Y. P.; RIBEIRO, A.; OLIVEIRA, A. S. D.; LEITE, F. P. Modeling and simulation of relief influence on *Eucalyptus* forests: interaction between solar irradiance and productivity. **Revista Árvore**, v.40, n.2, p.319-327, 2016.
- SANTOS, G. A.; RESENDE, M. D. V.; SILVA, L. D.; HIGA, A.; ASSIS, T. F. Interação genótipos x ambientes para produtividade de clones de *Eucalyptus* L'hér. no estado do Rio Grande do Sul. **Revista Árvore**, v.39, n.1, p.81-91, 2015.
- SETTE JR, C.R.; TOMAZELLO FILHO, M.; DIAS, C.T.S.; LACLAU, J.P. Crescimento em diâmetro do tronco das árvores de *Eucalyptus grandis* W. Hill. ex. Maiden e relação com as variáveis climáticas e fertilização mineral. **Revista Árvore**, v.34, n.6, p.979-990, 2010.
- SGARBI, F. **Produtividade do *Eucalyptus* sp. em função do estado nutricional e da fertilidade do solo em diferentes regiões do estado de São Paulo**. 2002. 101f. Dissertação (Mestrado em Recursos Florestais) - Escola Superior de Agricultura "Luiz de Queiroz", 2002.
- SILVA, R.M.L.; HAKAMADA, R.E.; BAZANI, J.H.; OTTO, M.S.G.; STAPE, J.L. Fertilization response, light use, and growth efficiency in *Eucalyptus* plantations across soil and climate gradients in Brazil. **Forests**, v.7, n.117, p.1-12, 2016.
- SILVA, S. R. D.; BARROS, N. F. D.; COSTA, L. M. D.; LEITE, F. P. Soil compaction and eucalyptus growth in response to forwarder traffic intensity and load. **Revista brasileira de ciência do solo**, v.32, n.3, p.921-932, 2008.
- SOARES, C.P.B.; LEITE, H.G. Predição da produção de madeira de eucalipto em região com alta variabilidade pluviométrica. **Scientia Florestalis**, n.58, p.41-48, 2000.
- SOARES, A.A.V.; LEITE, H.G.; SOUZA, A.L.; SILVA, S.R.; LOURENÇO, H.M.; FORRESTER, D.I. Increasing stand structural heterogeneity reduces productivity in Brazilian *Eucalyptus* monoclonal stands. **Forest Ecology and Management**, v.373, p.26-32, 2016.
- SOARES, A.V.V.; LEITE, H.G.; CRUZ, J.P.; FORRESTER, D.I. Development of stand structural heterogeneity and growth dominance in thinned *Eucalyptus* stands in Brazil. **Forest Ecology and Management**, v.384, p.339-346, 2017.
- SOUZA, V. C.; SILVA, R. A.; CARDOSO, G. D.; BARRETO, A. F. Estudos sobre fungos micorrízicos. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.10, n.3, p.612-618, 2006.
- 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**, v.193, p.17-31, 2004.
- STAPE, J.L.; BINKLEY, D.; RYAN, M.G. Production and carbon allocation in a clonal *Eucalyptus* plantation with water and nutrient manipulations. **Forest Ecology and Management**, v.255, p.920-930, 2008.

TAROUCO, C. P.; AGOSTINETTO, D.; PANOZZO, L. E.; DOS SANTOS, L. S.; VIGNOLO, G. K.; OLIVEIRA RAMOS, L. O. Períodos de interferência de plantas daninhas na fase inicial de crescimento do eucalipto. **Pesquisa Agropecuária Brasileira**, v.44, n.9, p. 1131-1137, 2010.

TOLEDO, R. E. B.; VICTORIA FILHO, R.; BEZUTTE, A. J.; PITELLI, R. A.; DA COSTA AGUIAR ALVES, P. L.; DO VALLE, C. F.; ALVARENGA, S. F. Períodos de controle de *Brachiaria* sp e seus reflexos na produtividade de *Eucalyptus grandis*. **Scientia Forestalis**, n. 63, p. 221-232, 2003.

TONELLO, K. C. **Comportamento ecofisiológico de clones de *Eucalyptus***. 2010. 161f. Tese (Doutorado em Engenharia Agrícola) - Universidade Estadual de Campinas.

TONELLO, K. C.; TEIXEIRA FILHO, J. Efeito das variáveis ambientais no comportamento ecofisiológico de dois clones de *Eucalyptus grandis* x *Eucalyptus urophylla*: condições de campo. **Scientia Forestalis**, v.39, n. 92, p. 419-431, 2011.

VALE, F. R. et al. Crescimento radicular de espécies florestais em solo ácido. **Pesquisa Agropecuária Brasileira**, Brasília, v.31, n.9, p.609-616, set. 1996.

ZANON, M.L.B.; FINGER, C.A.G. Relação de variáveis meteorológicas com o crescimento das árvores de *Araucaria angustifolia* (Bertol.) Kuntze em povoamentos implantados. **Ciência Florestal**, v. 20, n. 3, p. 467-476, 2010.

CAPÍTULO 2: Redes neuronais artificiais para estimação da produtividade de eucalipto em função do genótipo, fatores ambientais e práticas silviculturais.

1. Introdução

O setor florestal (florestas equiâneas) tem grande importância na economia brasileira, sendo responsável, em 2015, pela geração de R\$ 11,3 bilhões em tributos federais, estaduais e municipais (IBÁ, 2016). Dentre os gêneros de espécies arbóreas cultivadas, destaca-se o *Eucalyptus*, cujos plantios vêm se expandindo para atender à demanda por produtos madeireiros, aliada a sua plasticidade em relação às condições ambientais, rápido crescimento, diversidade de usos e amplo conhecimento em relação ao seu cultivo. Dos 7,8 milhões de hectares plantados com espécies arbóreas no Brasil em 2015, aproximadamente 72 % são de eucalipto, localizados principalmente nos estados de Minas Gerais (25 %), São Paulo (17 %) e Mato Grosso do Sul (15 %) (IBÁ, 2016).

A produtividade florestal é resultante da interação entre os fatores edáficos, climáticos, fisiográficos e bióticos (CAMPOS, 1970), e influenciada pelo manejo florestal e práticas silviculturais. Apesar de ser relativamente simples e fácil enumerar os fatores que influenciam o crescimento da floresta, o entendimento e a avaliação do somatório das interações desses fatores e os seus efeitos no sítio são complexos (BRAGA et al., 1999). Billings (1952) ressalta que, do ponto de vista ecológico, nenhum fator ambiental, quando estudado sozinho, pode ser muito significativo. Entretanto, é praticamente impossível isolar ou medir, em escala de campo, todos os componentes bióticos e abióticos que influenciam o desenvolvimento de uma cultura (MONTEZANO et al., 2006).

No Brasil, os principais fatores limitantes à produtividade florestal são o déficit hídrico e a baixa disponibilidade de nutrientes, uma vez que em países tropicais a radiação é abundante. Apesar da maioria dos plantios florestais ocupar áreas com solos ácidos e com baixa disponibilidade de nutrientes, a fertilidade do solo pode ser manejada, sendo a fertilização uma das ações mais efetivas para melhorar a qualidade do local e aumentar a produtividade. Em condições com fornecimento adequado de água e nutrientes, ou plantios manejados em locais favoráveis, a produtividade costuma ser alta (WHITEHEAD e BEADLE, 2004).

O aspecto nutricional é apenas um dos que devem ser observados, uma vez que os fatores que afetam o crescimento e a produção florestal são dinâmicos e inter-relacionados. Diversos estudos têm demonstrado a influência do genótipo, espaçamento, variáveis edáficas e climáticas, e fertilização na produtividade florestal, seja de modo isolado ou pela interação de alguns desses fatores, através de modelos de crescimento e produção, e ecofisiológicos

(BERGER et al., 2002; STAPE et al., 2004a; STAPE et al., 2004b; ORTIZ et al., 2006; FERREIRA, 2009; BORGES, 2012; CAMPOE et al., 2013; MARCATTI et al., 2017). Os modelos de crescimento e produção são definidos como um conjunto de relações matemáticas que descrevem quantitativamente um determinado sistema, por exemplo, o povoamento florestal (BERGER et al., 2002). A simulação de crescimento de uma árvore ou povoamento permite analisar seu comportamento em determinadas condições, fornecendo informações importantes para o gestor florestal tomar decisões (MAESTRI et al., 2013).

Entre os modelos ecofisiológicos, destaca-se o 3-PG, que possibilita a predição do potencial produtivo florestal em função das variáveis ambientais e das práticas de manejo utilizadas (ALMEIDA et al., 2004; STAPE et al., 2004b; GUIMARÃES et al., 2007; FERREIRA, 2009; BORGES, 2012). Apesar de generalistas, esses modelos são complexos, com grande número de parâmetros necessários, o que limita sua aplicação prática (MAESTRI et al., 2013). Outra consideração importante é que a produtividade potencial obtida por esses modelos geralmente não é alcançada devido às limitações nutricionais e hídricas que podem ocorrer durante a rotação (WHITEHEAD e BEADLE, 2004).

Em relação aos modelos descritivos, a inclusão de variáveis ambientais permite maior explicação da variabilidade encontrada, e a melhoria na capacidade de generalização desses modelos (MAESTRI et al., 2013). No entanto, a modelagem habitual é dificultada pela inclusão de variáveis categóricas, assim como pelo grande número de variáveis independentes e as relações complexas geralmente não lineares com a variável dependente. Nesse sentido, as Redes Neurais Artificiais (RNA) têm se mostrado uma boa ferramenta para modelar a relação entre a produtividade florestal e os diversos fatores, bióticos e abióticos, que a influenciam (LAFETÁ, 2012; OZÇELIK et al., 2013; BINOTI et al., 2013; BINOTI et al., 2015; ALCÂNTARA, 2015; MEDEIROS, 2016; CAMPOS et al., 2016; SILVA RIBEIRO et al., 2016; MARTINS et al., 2016; VAHEDI, 2017).

A RNA é um sistema computacional paralelo composto por vários elementos de processamento simples (neurônios artificiais) conectados entre si de uma maneira específica para executar uma determinada tarefa (BULLINARIA, 2014). Entre as vantagens das RNA, Haykin (2001) destaca a capacidade de aprendizagem e generalização, permitindo a resolução de problemas complexos, e a tolerância a ruídos.

Entre as tarefas resolvidas pelas RNA, a aproximação de função consiste em modelar a relação entre as variáveis de um sistema a partir de um conjunto conhecido de seus valores representativos (SILVA et al., 2010). A aproximação de funções é aplicável nas situações em

que existe relação entre as variáveis preditoras e preditas, sendo que as RNA são capazes de modelar funções complexas, como as não lineares, com grande número de variáveis, inclusive categóricas (DELL INC., 2015).

Com o emprego de RNA é possível relacionar a produtividade com os fatores bióticos e abióticos, podendo identificar se as práticas adotadas garantirão o adequado desenvolvimento dos povoamentos (ALCÂNTARA, 2015; MEDEIROS, 2016). O acompanhamento e o gerenciamento de dados, que variam com o espaço e tempo, tornam possível fazer intervenções precisas nas florestas, objetivando o rendimento máximo de acordo com as potencialidades do solo e dos fatores ambientais (BRANDELERO et al., 2007).

Nesse sentido, o objetivo desse estudo foi configurar, treinar e validar redes neurais artificiais para estimar a produtividade de povoamentos de eucalipto em Minas Gerais, utilizando como variáveis de entrada os fatores ambientais (climáticos e edáficos), genótipo, espaçamento e fertilização, e inferir sobre os fatores mais influentes.

2. Material e métodos

Os dados desse estudo foram obtidos em povoamentos de eucalipto, pertencentes à empresa Gerdau, localizados em diferentes regiões de Minas Gerais (Figura 1). Foram utilizados dados de 507 talhões, com tamanho entre 3 e 79 ha.

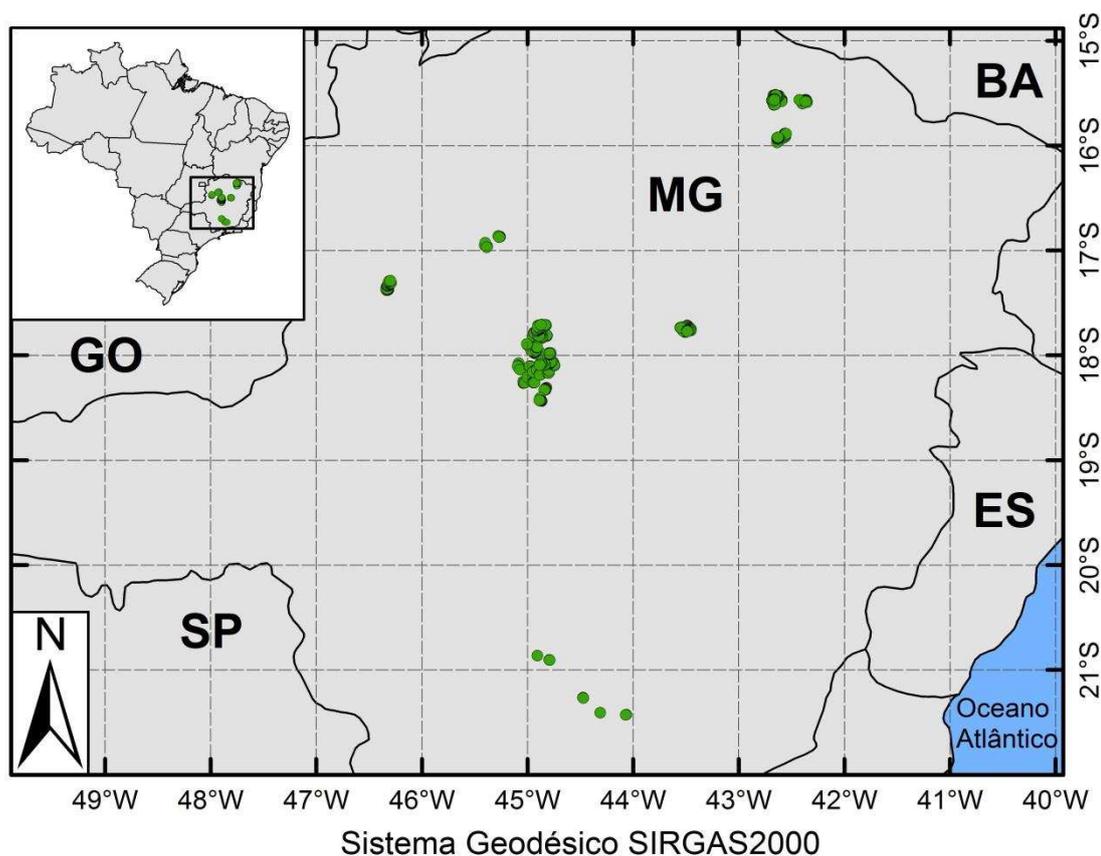


Figura 1 – Localização dos centróides dos talhões.

Os dados utilizados são referentes ao incremento médio anual em volume de madeira com casca estimado por meio de inventário florestal contínuo (IFC), em que a medição foi iniciada aos três anos de idade em nível de árvore em cada parcela permanente, que é remeida anualmente até o ano de corte.

Outro banco de dados, contendo as informações da análise química e física do solo, realizada entre o primeiro e terceiro ano do plantio florestal, e as fertilizações realizadas (base, arranque, cobertura e reposição) durante a rotação, foi acrescentado ao banco de dados do IFC. Como as análises do solo foram realizadas em parcelas temporárias, antes da inicialização do IFC, essas não coincidem com as parcelas permanentes do inventário. Sendo assim, os dados foram trabalhados em nível de talhão, utilizando as médias das parcelas em dado talhão.

Os dados climáticos (precipitação pluviométrica, temperatura, umidade relativa, velocidade do vento, radiação solar e evapotranspiração potencial) foram obtidos para os talhões, considerando a localização geográfica dos seus centróides, através de um banco de dados desenvolvido por Xavier et al. (2015). Esses autores utilizaram informações de 3625 pluviômetros e 735 estações (convencionais e automáticas) para estimar dados para todo o

Brasil através de métodos de interpolação. Foi gerado um *grid* (resolução do pixel de 0,25° x 0,25° (Lat x Long)) para todo o Brasil, com dados diários no período de 01/01/1980 a 31/12/2013. Assim, talhões próximos, que estão no mesmo pixel, possuem os mesmos valores para as variáveis climáticas.

Com os dados de precipitação pluviométrica e evapotranspiração potencial foi calculado o balanço hídrico climatológico normal (1980-2013) e sequencial (oito anos anteriores ao sexto ano do plantio) pelo método de Thornthwaite e Mather (1955), exemplificado por Pereira et al. (2002), utilizando uma CAD (capacidade máxima de armazenamento) de 300 mm, como sugerido pelos mesmos autores.

Foram considerados os dados dos oito anos anteriores ao sexto ano do plantio para a precipitação pluviométrica e déficit hídrico, ou seja, dois anos anteriores ao plantio, uma vez que o ritmo de crescimento não depende exclusivamente das condições climáticas do ano de avaliação, mas também das condições anteriores. E para as outras variáveis foram consideradas as médias dos seis anos da rotação, pois a variação ao longo desses anos é pequena (Anexo). Também foram obtidas as médias do período 1980-2013 para as variáveis climáticas.

Um resumo dos dados utilizados para treinar as redes pode ser observado na Tabela 1.

Tabela 1 – Variáveis utilizadas para treinar as redes neuronais artificiais

Variável de saída	Unidade	Mínimo	Quartil 1	Quartil 2	Quartil 3	Máximo
IMA6 - Incremento médio anual aos 6 anos de idade	m ³ ha ⁻¹ ano ⁻¹	16,43	27,54	31,96	36,54	50,99
Variáveis Categóricas		Categorias				
Genótipo			GG0100			
			GG0157			
			GG2335			
			GG0680			
			GG0702			
			MULTICLONAL			
Espaçamento (m)			3,5 x 2,0			
			3,5 x 2,5			
			3,0 x 3,0			
			3,0 x 2,5			
			4,0 x 2,0			
			3,0 x 2,0			
Variáveis contínuas	Unidade	Mínimo	Quartil 1	Quartil 2	Quartil 3	Máximo
AT - Areia total (0-20 cm)	%	8,78	39,84	69,52	78,26	87,70
AG - Areia grossa (0-20 cm)	%	3,68	15,16	27,06	35,35	72,40
AF - Areia fina (0-20 cm)	%	3,06	18,36	28,29	45,86	66,12
ARG- Argila (0-20 cm)	%	6,00	14,00	20,00	50,00	76,00
SIL- Silte (0-20 cm)	%	1,90	6,58	8,92	11,11	36,69
m - Saturação por alumínio (0-20 cm)	%	0,72	50,91	66,00	77,72	93,90
V - Saturação por bases (0-20 cm)	%	0,81	3,92	7,39	12,4	49,17
P - Fósforo disponível (0-20 cm)	mg dm ⁻³	0,47	1,48	1,88	2,34	16,86
K - Potássio disponível (0-20 cm)	mg dm ⁻³	2,52	17,84	25,39	33,62	239,08
pH (H ₂ O) – pH medido em água (0-20 cm)	-	3,99	4,6	4,77	4,97	6,14
pH (CaCl ₂) – pH medido em solução de CaCl ₂ (0-20 cm)	-	3,80	4,03	4,10	4,19	5,10

CTC - Capacidade de troca catiônica a pH 7,0 (0-20 cm)	cmol _c dm ⁻³	2,19	3,73	5,15	7,72	17,16
H+Al - Acidez potencial (0-20 cm)	cmol _c dm ⁻³	1,82	3,30	4,46	7,26	16,83
Al - Acidez trocável (0-20 cm)	cmol _c dm ⁻³	0,02	0,48	0,67	1,01	2,76
Mg - Magnésio trocável (0-20 cm)	cmol _c dm ⁻³	0,01	0,09	0,13	0,19	0,92
Ca - Cálcio trocável (0-20 cm)	cmol _c dm ⁻³	0,01	0,10	0,18	0,29	1,87
MO - Matéria orgânica (0-20 cm)	dag kg ⁻¹	0,70	1,34	2,07	3,15	8,17
Prem - Fósforo remanescente (0-20 cm)	mg L ⁻¹	2,01	11,33	22,41	29,81	47,93
Pre1 - Precipitação pluviométrica do quinto ano após o plantio	mm ano ⁻¹	732,92	938,56	1067,76	1241,59	1946,25
Pre2 - Precipitação pluviométrica do quarto ano após o plantio	mm ano ⁻¹	620,68	801,82	1053,23	1370,56	2037,49
Pre3 - Precipitação pluviométrica do terceiro ano após o plantio	mm ano ⁻¹	620,68	801,82	1157,90	1333,00	2137,08
Pre4 - Precipitação pluviométrica do segundo ano após o plantio	mm ano ⁻¹	620,68	783,54	1207,13	1384,08	1878,03
Pre5 - Precipitação pluviométrica do primeiro ano após o plantio	mm ano ⁻¹	557,37	1024,38	1184,64	1323,46	2137,08
Pre6 - Precipitação pluviométrica do ano de plantio	mm ano ⁻¹	677,52	924,01	1110,67	1286,92	1741,40
Pre7 - Precipitação pluviométrica do ano anterior ao plantio	mm ano ⁻¹	647,24	1050,42	1139,99	1359,53	1915,64
Pre8 - Precipitação pluviométrica de dois anos antes do plantio	mm ano ⁻¹	647,24	924,01	999,91	1272,41	1682,24
Pre_soma (8 anos) – Precipitação pluviométrica total dos seis anos da rotação mais dois anos anteriores ao plantio	mm	6756,12	8013,66	8969,07	10887,58	13151,69
Tmax - Temperatura máxima (média dos 6 anos do plantio)	°C	25,19	29,56	30,04	30,82	31,10
Tmin - Temperatura mínima (média dos 6 anos do plantio)	°C	14,43	17,57	17,95	18,64	19,14
Tmed - Temperatura média (média dos 6 anos do plantio)	°C	20,03	23,61	24,00	24,79	25,12
vv - Velocidade do vento (média dos 6 anos do plantio)	m s ⁻¹	1,17	1,29	1,33	1,38	1,73
Etp - Evapotranspiração potencial (média dos 6 anos do plantio)	mm ano ⁻¹	1191,81	1478,4	1515,26	1555,46	1615,72
UR - Umidade Relativa (média dos 6 anos do plantio)	%	62,98	63,66	66,67	67,32	78,35
Rad – Radiação solar (média dos 6 anos do plantio)	MJ m ⁻²	16,35	19,37	19,55	19,59	20,45
DH1 - Déficit hídrico do quinto ano após o plantio	mm ano ⁻¹	185,20	406,01	548,15	624,63	857,42
DH2 - Déficit hídrico do quarto ano após o plantio	mm ano ⁻¹	146,52	343,31	421,03	736,54	1000,66
DH3 - Déficit hídrico do terceiro ano após o plantio	mm ano ⁻¹	76,62	324,52	543,27	753,95	1000,66

DH4 - Déficit hídrico do segundo ano após o plantio	mm ano ⁻¹	122,66	354,38	475,09	753,95	1000,66
DH5 - Déficit hídrico do primeiro ano após o plantio	mm ano ⁻¹	184,67	412,83	485,89	685,00	869,22
DH6 - Déficit hídrico do ano de plantio	mm ano ⁻¹	146,88	373,86	524,92	735,49	915,52
DH7 - Déficit hídrico do ano anterior ao plantio	mm ano ⁻¹	65,39	354,38	420,50	479,41	915,52
DH8 - Déficit hídrico de dois anos antes do plantio	mm ano ⁻¹	78,49	387,96	497,66	532,40	838,73
Pre_nor – Precipitação pluviométrica (média de 1980 a 2013)	mm ano ⁻¹	812,63	861,5	1153,33	1194,62	1513,39
Tmax_nor - Temperatura máxima (média de 1980 a 2013)	°C	25,87	29,53	29,91	30,50	30,75
Tmin_nor - Temperatura mínima (média de 1980 a 2013)	°C	14,66	17,08	17,53	18,56	18,99
Tmed_nor - Temperatura média (média de 1980 a 2013)	°C	20,32	23,3	23,72	24,59	24,87
vv_nor - Velocidade do vento (média de 1980 a 2013)	m s ⁻¹	1,18	1,24	1,26	1,38	1,44
Etp_nor - Evapotranspiração potencial (média de 1980 a 2013)	mm ano ⁻¹	1182,81	1401,67	1435,15	1537,24	1582,27
UR_nor - Umidade Relativa (média de 1980 a 2013)	%	63,84	64,70	69,75	70,00	78,02
DH_nor - Déficit hídrico (média de 1980 a 2013)	mm ano ⁻¹	111	339	377	672	799
Rad_nor – Radiação solar (média de 1980 a 2013)	MJ m ⁻²	16,26	18,61	18,88	19,08	19,26
N_fert - N total adicionado durante os 6 anos	kg ha ⁻¹	0,00	18,71	21,40	30,60	60,93
P_fert - P ₂ O ₅ total adicionado durante os 6 anos	kg ha ⁻¹	0,00	141,92	156,02	178,95	325,81
K_fert - K ₂ O total adicionado durante os 6 anos	kg ha ⁻¹	53,71	141,25	158,81	215,05	512,14
Ca_fert - CaO total adicionado durante os 6 anos	kg ha ⁻¹	0,00	338	498,79	542,03	1100,78
Mg_fert - MgO total adicionado durante os 6 anos	kg ha ⁻¹	0,00	71,79	90	134,91	255,45
S_fert - S total adicionado durante os 6 anos	kg ha ⁻¹	0,00	0	0	0	45,92
B_fert - B total adicionado durante os 6 anos	kg ha ⁻¹	0,00	2,77	3,55	4,25	9,26
Cu_fert - Cu total adicionado durante os 6 anos	kg ha ⁻¹	0,00	0	0,41	0,75	5,75
Zn_fert – Zn total adicionado durante os 6 anos	kg ha ⁻¹	0,00	0,75	1,49	3,09	7,72

Foi utilizada a análise de correlação entre as variáveis com o objetivo de reduzir o número de variáveis de entrada, assim como a redundância de informação (Anexo). Nesse sentido, as características do solo da camada de 20-40 cm não foram consideradas para esse estudo, uma vez que apresentaram alta correlação com as características da camada de 0-20 cm.

As redes treinadas foram do tipo Perceptron de Múltiplas Camadas (MLP), que consistem de duas camadas de neurônios artificiais que processam os dados (camada intermediária e camada de saída) e uma camada de neurônios artificiais que recebe os dados (camada de entrada) e direciona-os à camada intermediária. Para obtenção das redes neuronais artificiais, utilizou-se o software Neuroforest, versão 4.0 (<http://neuroforest.ucoz.com/>).

As redes foram treinadas alterando as variáveis de entrada (redes com todas as variáveis; sem as variáveis altamente correlacionadas; utilizando os valores anuais, a somatória ou a média dos 8, 7 ou 6 anos anteriores ao sexto ano do plantio para as variáveis precipitação pluviométrica e déficit hídrico); número de neurônios na camada oculta, sendo que o número de neurônios na camada de entrada variou em função do número de variáveis independentes consideradas em cada configuração; algoritmos de treinamento (Backpropagation, Resilient Propagation (Rprop+), e Quick Propagation); porcentagem de dados no subconjunto de treino (90 a 50 %) e validação, nos quais a seleção foi feita aleatoriamente; e as funções de ativação (logística, tangente hiperbólica, linear) nas camadas intermediárias (exceto função linear) e de saída. Foram treinadas 250 redes para cada configuração, totalizando 85.750 redes.

O critério de parada utilizado foi o número de ciclos (entre 2000 e 5000) e o erro médio (0,0001), ou seja, o treinamento da rede foi interrompido ao atingir algum desses critérios.

As redes foram selecionadas com base na correlação entre o IMA6 observado e o estimado ($r_{y\hat{y}}$), raiz quadrada do erro quadrático médio em porcentagem (REQM (%)) (equação 1) e histograma da frequência percentual dos erros percentuais (equação 2).

$$REQM(\%) = \frac{100}{\bar{y}} \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad (\text{Equação 1})$$

$$Erro(\%) = \frac{(\hat{y}_i - y_i)}{y_i} \times 100 \quad (\text{Equação 2})$$

em que \bar{y} é a média dos valores totais observados; n o número total de observações; y_i o valor observado e \hat{y}_i o valor estimado.

A REQM avalia a precisão da estimativa, e quanto menor, mais preciso, e a correlação indica o grau e a direção da associação entre o IMA estimado e o observado.

3. Resultados

De todas as configurações executadas (ANEXO), foram selecionadas as 10 melhores redes (Tabela 2), as quais apresentaram $r_{y\hat{y}}$ maior que 85 % na validação. Todas as redes foram obtidas com o algoritmo de treinamento Resilient Propagation (Rprop+), utilizando a função logística, tanto na camada oculta (6 e 8 neurônios) como na de entrada. Os melhores resultados da $r_{y\hat{y}}$ e REQM (%) foram obtidos utilizando 90 % dos dados para o treinamento.

As melhores redes foram aquelas em que, para as variáveis precipitação pluviométrica e déficit hídrico, foram considerados os oito anos (seis anos da rotação mais dois anos anteriores ao plantio), ao invés de apenas os seis anos da rotação.

A rede considerando todas as variáveis edáficas na camada de 0-20 cm de profundidade e climáticas (RN14) teve resultados semelhantes às redes que excluíram as variáveis altamente correlacionadas. A RN44, que levou em consideração as normais climatológicas (1980-2013), também apresentou resultados satisfatórios. Entretanto, as redes RN53 e RN99, com menor REQM (%) e maior coeficiente de correlação na validação, respectivamente, foram treinadas com as precipitações anuais dos oito anos, sendo que a diferença entre elas consistiu nas variáveis edáficas utilizadas e o número de ciclos como critério de parada.

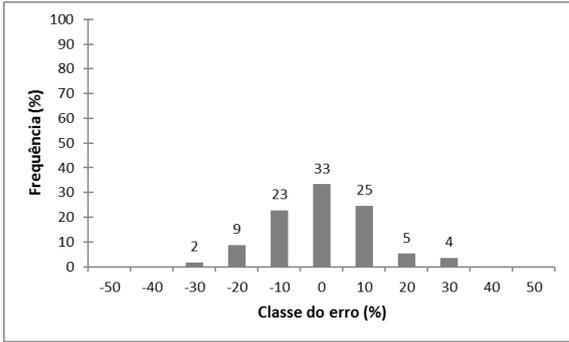
Conforme os histogramas das frequências percentuais dos erros percentuais das estimativas do IMA6 na validação (Figura 2), aproximadamente 50 % dos erros na RN53 concentraram-se em ± 5 %. Todas as redes selecionadas apresentaram mais de 75 % dos erros percentuais entre -15 % e 15 %, sendo que a RN99 apresentou maior frequência nessa faixa (85 %).

Tabela 2 - Características e precisão das redes neuronais artificiais (RNA) selecionadas para estimar o IMA6 (incremento médio anual aos 6 anos de idade) de povoamentos de eucalipto em Minas Gerais

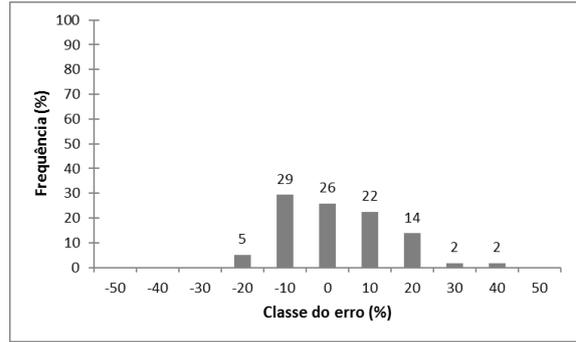
Código	% Treino	% Validação	Variáveis categóricas	Variáveis contínuas	Número de ciclos	Algoritmo de treinamento	MLP	Função de ativação		Treino		Validação	
								Camada oculta	Camada de saída	$r_{y\hat{y}}$	REQM (%)	$r_{y\hat{y}}$	REQM (%)
RN14	90	10	Genótipo; espaçamento	AG; AF; ARG; SIL; m; V; P; K; pH(H ₂ O); pH(CaCl ₂); CTC; H+Al; Al; Mg; Ca; MO; Prem; Pre1; Pre2; Pre3; Pre4; Pre5; Pre6; Pre7; Pre8; Tmax; Tmin; vv; Etp; UR; Rad; DH1; DH2; DH3; DH4; DH5; DH6; DH7; DH8; N_fert; P_fert; K_fert; Ca_fert; Mg_fert; S_fert; B_fert; Cu_fert; Zn_fert	3000	Resilient Propagation (Rprop+)	61:8:1	Logística	Logística	0,9137	8,9209	0,8704	11,4007
RN16	90	10	Genótipo; espaçamento	AG; AF; ARG; SIL; m; V; P; K; pH(H ₂ O); pH(CaCl ₂); CTC; H+Al; Al; Mg; Ca; MO; Prem; vv; DH1; DH2; DH3; DH4; DH5; DH6; DH7; DH8; N_fert; P_fert; K_fert; Ca_fert; Mg_fert; S_fert; B_fert; Cu_fert; Zn_fert	3000	Resilient Propagation (Rprop+)	48:8:1	Logística	Logística	0,8887	10,0522	0,8585	11,4044
RN29	90	10	Genótipo; espaçamento	ARG; P; K; pH(H ₂ O); Mg; Ca; Pre_soma(8anos);Tmax; N_fert; P_fert; K_fert; Ca_fert; Mg_fert; S_fert; B_fert; Cu_fert; Zn_fert	3000	Resilient Propagation (Rprop+)	30:8:1	Logística	Logística	0,8636	11,0679	0,8503	11,6922
RN44	90	10	Genótipo; espaçamento	AG; AF; ARG; SIL; m; V; P; K; pH(H ₂ O); pH(CaCl ₂); CTC; H+Al; Al; Mg; Ca; MO; Prem; Pre_nor; Tmax_nor; Tmin_nor; vv_nor; Etp_nor; UR_nor; Rad_nor; DH_nor; N_fert; P_fert; K_fert; Ca_fert; Mg_fert; S_fert; B_fert; Cu_fert; Zn_fert	3000	Resilient Propagation (Rprop+)	47:8:1	Logística	Logística	0,8153	12,6230	0,8621	11,9371
RN53	90	10	Genótipo; espaçamento	P; K; pH(H ₂ O); Mg; Ca; MO; Pre1;Pre2;Pre3;Pre4; Pre5;Pre6;Pre7;Pre8; Tmin;	3000	Resilient Propagation (Rprop+)	37:8:1	Logística	Logística	0,9071	9,2803	0,8583	10,8172

				N_fert; P_fert; K_fert; Ca_fert; Mg_fert; S_fert; B_fert; Cu_fert; Zn_fert									
RN66	90	10	Genótipo; espaçamento	V; P; K; CTC; Pre1; Pre2; Pre3; Pre4; Pre5; Pre6; Pre7; Pre8; N_fert; P_fert; K_fert; Ca_fert; Mg_fert; S_fert; B_fert; Cu_fert; Zn_fert	3000	Resilient Propagation (Rprop+)	34:8:1	Logística	Logística	0,9076	9,2578	0,8621	11,5354
RN68	90	10	Genótipo; espaçamento	ARG; m; P; K; DH1; DH2; DH3; DH4; DH5; DH6; DH7; DH8; N_fert; P_fert; K_fert; Ca_fert; Mg_fert; S_fert; B_fert; Cu_fert; Zn_fert	3000	Resilient Propagation (Rprop+)	34:6:1	Logística	Logística	0,8864	10,1323	0,8633	11,8688
RN74	90	10	Genótipo; espaçamento	ARG; m; P; K; Pre_soma(8anos); Tmin; N_fert; P_fert; K_fert; Ca_fert; Mg_fert; S_fert; B_fert; Cu_fert; Zn_fert	3000	Resilient Propagation (Rprop+)	28:6:1	Logística	Logística	0,8258	12,3178	0,8876	11,1252
RN95	90	10	Genótipo; espaçamento	P; K; pH(H ₂ O); Mg; Ca; MO; DH1; DH2; DH3; DH4; DH5; DH6; DH7; DH8; N_fert; P_fert; K_fert; Ca_fert; Mg_fert; S_fert; B_fert; Cu_fert; Zn_fert	2000	Resilient Propagation (Rprop+)	36:8:1	Logística	Logística	0,8851	10,2569	0,8525	11,2832
RN99	90	10	Genótipo; espaçamento	V; P; K; CTC; Pre1; Pre2; Pre3; Pre4; Pre5; Pre6; Pre7; Pre8; Tmin; N_fert; P_fert; K_fert; Ca_fert; Mg_fert; S_fert; B_fert; Cu_fert; Zn_fert	2000	Resilient Propagation (Rprop+)	35:8:1	Logística	Logística	0,8875	9,9585	0,8927	11,3177

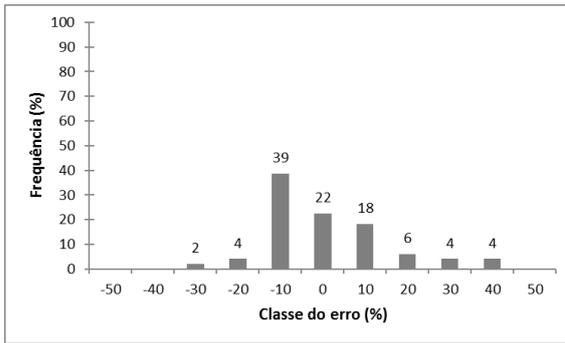
Genótipo (GG0100; GG0157; GG2335; GG0680; GG0702; MULTICLONAL); espaçamento (3,5 x 2,0; 3,5 x 2,5; 3,0 x 3,0; 3,0 x 2,5; 4,0 x 2,0; 3,0 x 2,0); AG - Areia grossa (0-20 cm); AF - Areia fina (0-20 cm); ARG - Argila (0-20 cm); SIL - Silte (0-20 cm); m - Saturação por alumínio (0-20 cm); V - Saturação por bases (0-20 cm); P - Fósforo disponível (0-20 cm); K - Potássio disponível (0-20 cm); pH (H₂O) - pH medido em água (0-20 cm); pH (CaCl₂) - pH medido em solução de CaCl₂ (0-20 cm); CTC - Capacidade de troca catiônica a pH 7,0 (0-20 cm); H+Al - Acidez potencial (0-20 cm); Al - Acidez trocável (0-20 cm); Mg - Magnésio trocável (0-20 cm); Ca - Cálcio trocável (0-20 cm); MO - Matéria orgânica (0-20 cm); Prem - Fósforo remanescente (0-20 cm); Pre1 - Precipitação pluviométrica do quinto ano após o plantio; Pre2 - Precipitação pluviométrica do quarto ano após o plantio; Pre3 - Precipitação pluviométrica do terceiro ano após o plantio; Pre4 - Precipitação pluviométrica do segundo ano após o plantio; Pre5 - Precipitação pluviométrica do primeiro ano após o plantio; Pre6 - Precipitação pluviométrica do ano de plantio; Pre7 - Precipitação pluviométrica do ano anterior ao plantio; Pre8 - Precipitação pluviométrica de dois anos antes do plantio; Pre_soma (8 anos) - Precipitação pluviométrica total dos seis anos da rotação mais dois anos anteriores ao plantio; Tmax - Temperatura máxima (média dos 6 anos do plantio); Tmin - Temperatura mínima (média dos 6 anos do plantio); vv - Velocidade do vento (média dos 6 anos do plantio); Etp - Evapotranspiração potencial (média dos 6 anos do plantio); UR - Umidade Relativa (média dos 6 anos do plantio); Rad - Radiação (média dos 6 anos do plantio); DH1 - Déficit hídrico do quinto ano após o plantio; DH2 - Déficit hídrico do quarto ano após o plantio; DH3 - Déficit hídrico do terceiro ano após o plantio; DH4 - Déficit hídrico do segundo ano após o plantio; DH5 - Déficit hídrico do primeiro ano após o plantio; DH6 - Déficit hídrico do ano de plantio; DH7 - Déficit hídrico do ano anterior ao plantio; DH8 - Déficit hídrico de dois anos antes do plantio; Pre_nor - Precipitação pluviométrica (média de 1980 a 2013); Tmax_nor - Temperatura máxima (média de 1980 a 2013); Tmin_nor - Temperatura mínima (média de 1980 a 2013); vv_nor - Velocidade do vento (média de 1980 a 2013); Etp_nor - Evapotranspiração potencial (média de 1980 a 2013); UR_nor - Umidade Relativa (média de 1980 a 2013); DH_nor - Déficit hídrico (média de 1980 a 2013); Rad_nor - Radiação (média de 1980 a 2013); N_fert - N total adicionado durante os 6 anos; P_fert - P2O5 total adicionado durante os 6 anos; K_fert - K2O total adicionado durante os 6 anos; Ca_fert - CaO total adicionado durante os 6 anos; Mg_fert - MgO total adicionado durante os 6 anos; S_fert - S total adicionado durante os 6 anos; B_fert - B total adicionado durante os 6 anos; Cu_fert - Cu total adicionado durante os 6 anos; Zn_fert - Zn total adicionado durante os 6 anos.



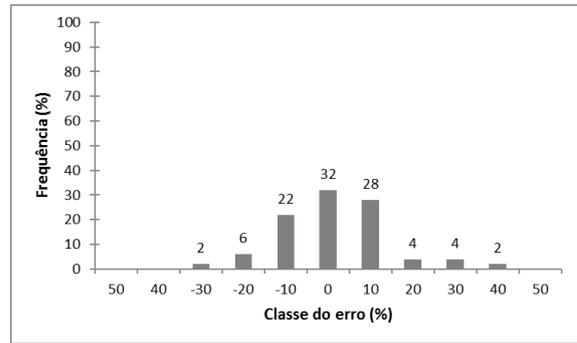
(RN14)



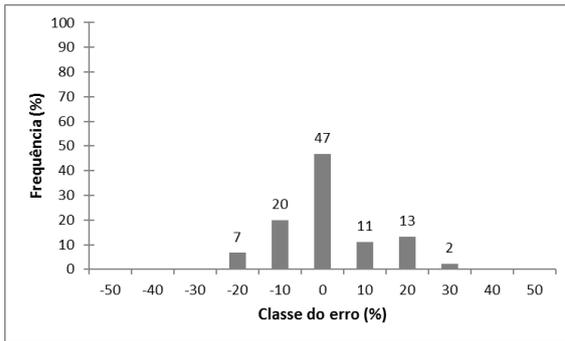
(RN16)



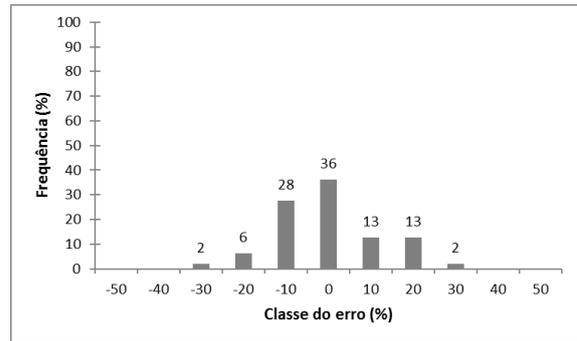
(RN29)



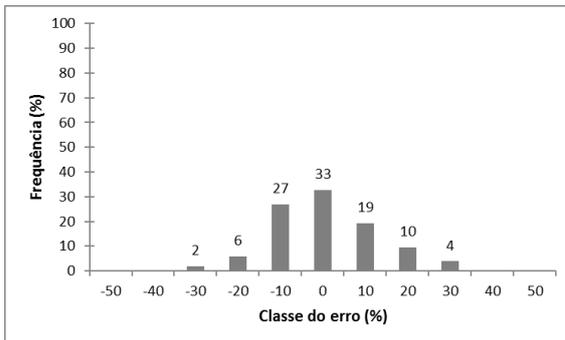
(RN44)



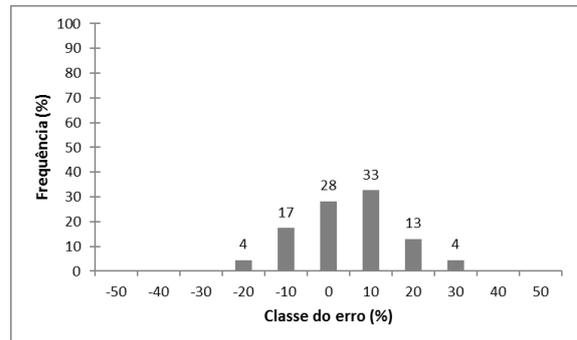
(RN53)



(RN66)



(RN68)



(RN74)

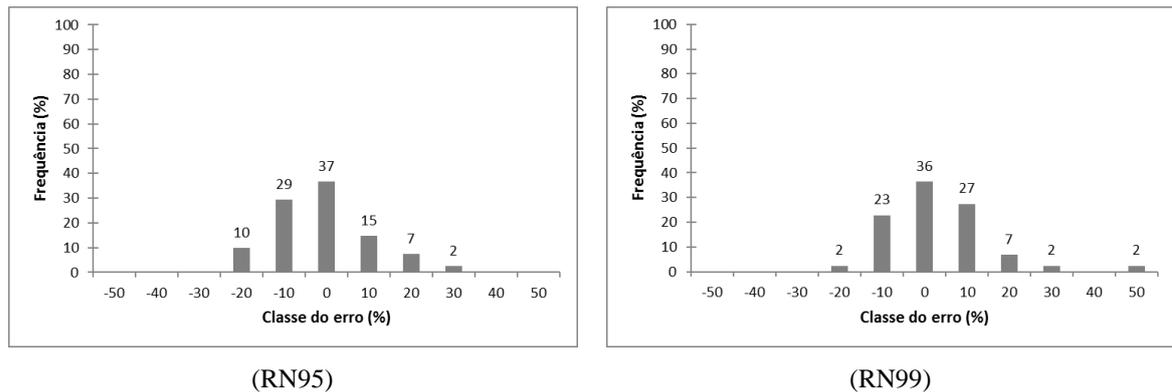


Figura 2 – Percentual de casos por classe do erro percentual das estimativas de IMA6 obtidos com os dados de validação.

Foi gerado um mapa para o IMA6 estimado pela rede RN53 (Figura 3) para os 507 talhões de eucalipto, e os menores valores do IMA6 ($18,7$ a $28 \text{ m}^3 \text{ ha}^{-1} \text{ ano}^{-1}$) foram observados, em predominância, na região Norte do estado.

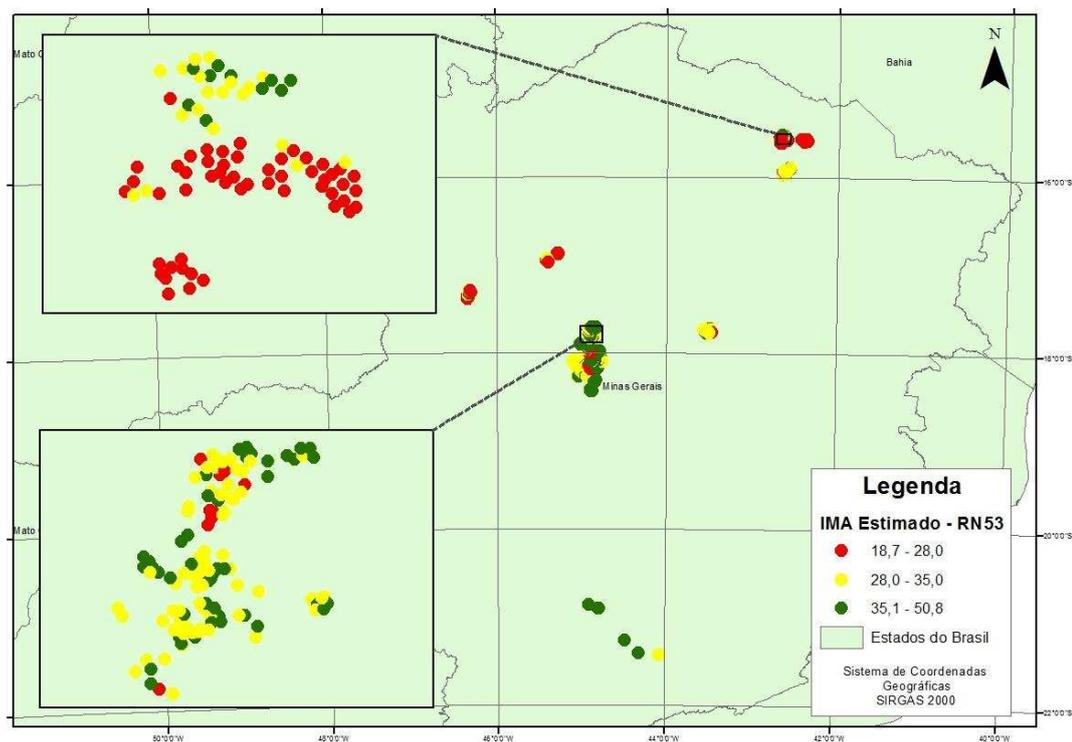


Figura 3 – Produtividade média de povoamentos de eucalipto aos 6 anos de idade (IMA6), em MG, estimada pela rede neuronal artificial RN53.

4. Discussão

Diversos trabalhos apresentam melhor precisão das estimativas de variáveis relacionadas à produção florestal com a utilização de redes neurais artificiais comparadas

com modelos de regressão (OZÇELIK et al., 2010; DIAMANTOPOULOU, 2012; BHERING et al. 2015; SILVA RIBEIRO et al., 2016; VAHEDI; 2017). Ozçelik et al. (2013), ao estimarem a altura de árvores de *Juniperus* em função do diâmetro, observaram que a RNA reduziu a REQM em mais de 20 % comparado com um modelo de regressão não linear. Esses autores destacam, entre as vantagens das redes, a capacidade de detectar relações não lineares complexas entre as variáveis dependentes e independentes, e não ser necessário o conhecimento prévio a respeito da função que será estimada.

A maioria desses estudos utiliza dados dendrométricos na base de treinamento das RNA, o que gera melhor correlação e precisão das estimativas. Binoti et al. (2015) realizaram a prognose da produção de povoamentos de eucalipto utilizando variáveis quantitativas (idade, área basal, volume) e categóricas (classe de solo, textura, espaçamento, relevo, projeto, clone). Esses autores obtiveram, na validação, REQM menor que 5 % e correlação maior que 95 %, resultado semelhante ao encontrado por Alcântara (2015), que utilizou dados climáticos e do IFC no treinamento. A utilização de variáveis ambientais, somadas aos dados de IFC, como variáveis de entrada numa RNA, é importante, pois considera os efeitos naturais atípicos, como um ano com alto déficit hídrico, além de poder simular previsões de comportamentos fora do padrão (ALCÂNTARA, 2015).

Embora apresentem precisão inferior às redes que incluem dados do IFC na estimação da produtividade florestal, as redes que consideram apenas os fatores ambientais, genótipo e manejo permitem melhor análise da influência desses fatores na produtividade. A utilização dessas redes também possibilita a estimação da produtividade em locais sem dados de inventário ou que não possuem plantios (ALCÂNTARA, 2015).

Em relação às melhores configurações das RNA, assim como nesse estudo, outros trabalhos têm demonstrado melhor desempenho do algoritmo Resilient Propagation na resolução de problemas florestais. Martins et al. (2016) também observaram bom desempenho desse algoritmo para estimar a altura de eucalipto. Já o número de neurônios da camada oculta e o número de ciclos foram alterados de acordo com a observação de sub ou sobre-treinamento (baixo EQM no treinamento, e o contrário na validação). Segundo Martins et al. (2016) um número elevado de ciclos pode ocasionar o sobre-treinamento, além de aumentar o tempo de processamento, e um número reduzido de ciclos pode ocasionar o sub-treinamento. O mesmo ocorre para o número de neurônios na camada oculta e quantidade de camadas ocultas.

A porcentagem dos dados usada para o treinamento da rede influenciou a precisão da estimativa e associação entre os valores estimados e observados na validação. À medida que os

dados utilizados no treino foram reduzidos, houve aumento da REQM (%) e redução da $r_{y\hat{y}}$. A necessidade de maior porcentagem de dados para o treinamento (90 %) pode ser devido ao grande número de variáveis de entrada, abrangendo, assim, a maior variabilidade delas, e melhorando a capacidade da rede em generalizar. O mesmo foi observado por Alcântara (2015), que utilizou dados climáticos (2006 a 2013), além das variáveis categóricas (clone, espaçamento, idade, rotação, solo predominante), para estimar o IMA7 de povoamentos de eucalipto em Minas Gerais. Essa autora recomendou a utilização de toda a base de dados, quando as variáveis de entrada não possuem dados do IFC, para gerar estimativas melhores.

Com a maior utilização do banco de dados para o treino das redes, as mesmas apresentaram boa precisão da estimativa do IMA6 e correlação com os dados observados, considerando que não foram utilizados dados do IFC como variáveis preditoras, e que os dados utilizados foram em nível de talhão. Alcântara (2015), sem utilizar dados de IFC como variáveis preditoras, obteve redes com a REQM de 12 % no treinamento e 22 % na validação, utilizando 90 % dos dados para o treinamento, já a correlação na validação foi de aproximadamente 54 %. As melhores estimativas do IMA no presente estudo, em relação ao trabalho mencionado, pode ser devido à inclusão da fertilização e variáveis edáficas como variáveis de entrada, uma vez que essas têm grande influência na produtividade florestal.

A maioria das redes selecionadas levou em consideração as variáveis: argila, matéria orgânica ou CTC na camada de 0-20 cm de profundidade do solo, sendo essas variáveis fortemente correlacionadas. Gava e Gonçalves (2008) avaliaram o efeito de atributos físicos e químicos do solo na produtividade e qualidade da madeira de *Eucalyptus grandis* (6,5 a 7 anos de idade) e concluíram que dentre os atributos físicos do solo, o teor de argila, diretamente relacionado à quantidade de água e nutrientes disponíveis, foi o mais relevante. Esses autores não encontraram relação significativa entre a produção madeireira e os teores de P, Ca e K do solo, mas foi observada alta correlação com a matéria orgânica, Al trocável e CTC do solo.

Todas as redes selecionadas levaram em consideração a quantidade de nutrientes adicionados durante a rotação, e quando as redes foram rodadas com a mesma configuração das melhores redes e sem a inclusão da fertilização como variável de entrada, essas apresentaram menor $r_{y\hat{y}}$ e maior REQM. Silva et al. (2016) observaram um aumento no incremento anual de 24 % em povoamentos de eucalipto fertilizados (N, P, K, Ca e Mg), e que a resposta foi influenciada pelas características do solo, principalmente pelo teor de argila e matéria orgânica. A maior resposta à fertilização ocorreu em regiões que não apresentaram déficit hídrico e com maior teor de argila, possibilitando maior retenção da umidade, e matéria orgânica. Outros

estudos com espécies florestais também demonstram a maior resposta à fertilização relacionada à quantidade disponível de água. Campoe et al. (2013) observaram que o tratamento de fertilização mais irrigação aumentou em 79 % o índice de área foliar em povoamentos de pinus, e em 57 % no tratamento com fertilização, comparados com o tratamento controle e com irrigação apenas.

Como observado nos estudos citados, as variáveis climáticas têm grande influência no aproveitamento dos recursos ambientais pelas espécies arbóreas e, conseqüentemente, na produtividade florestal. Stape et al. (2004a) avaliaram a produção de madeira em povoamentos de eucalipto em função da disponibilidade de água durante dois anos e observaram a sua influência no crescimento das árvores. O crescimento no tratamento controle (sem irrigação) correspondeu a 86 % e 42 % do crescimento nas parcelas irrigadas no ano de pluviosidade superior (1770 mm ano⁻¹) e inferior (1210 mm ano⁻¹), respectivamente. O mesmo foi observado por Otto et al. (2014) em plantios clonais de eucalipto, localizados em regiões com temperatura média anual de 23,6 °C e precipitação média anual de 1390 mm, em que a produção primária líquida em parcelas sem irrigação foi 17 a 36 % menor que nas parcelas com irrigação.

O menor IMA6 (< 30 m³ ha⁻¹ ano⁻¹) observado no Norte do estado de Minas Gerais (Figura 3) pode ser devido a menor precipitação pluviométrica da região (média de 800 mm ano⁻¹) comparada com as outras regiões do estado, comprovando a importância desse fator ambiental na produtividade do eucalipto. Lemos Filho et al. (2007), analisando dados climáticos de 17 anos (1961 a 1978), observaram que os menores valores totais anuais médios de chuva no estado de Minas Gerais foram registrados na região Norte, chegando ao valor mínimo de 512 mm ano⁻¹ no extremo norte, enquanto, os maiores valores totais anuais médios de chuva foram registrados na região Sul, chegando ao valor máximo de 1.748 mm ano⁻¹ no extremo sul.

Apesar dos vários estudos que comprovam a importância de considerar as variáveis climáticas em modelos de crescimento e produção florestal, Soares e Leite (2000) citam algumas dificuldades da utilização das mesmas, como problemas estatísticos relacionados à alta correlação entre as variáveis independentes do modelo. Em contrapartida, não considerar os fatores climáticos pode causar interpretações erradas em relação ao crescimento final. Em estudos para avaliar os tratamentos culturais, por exemplo, é mais fácil a comparação entre a produção final, porém, uma irregularidade climática que possa ter ocorrido durante o período avaliado pode mascarar o resultado ou induzir a uma conclusão errada (FERRAZ, 1993).

Sette Jr et al. (2010) avaliaram o incremento em diâmetro de árvores de *Eucalyptus grandis* por 24 meses em função das variáveis climáticas e fertilização mineral. Esses autores

observaram que o período de máximo crescimento do tronco das árvores foi relacionado com os altos níveis de precipitação, temperatura, disponibilidade de água no solo e de horas de luz/dia. Durante o período de avaliação, a taxa de incremento em diâmetro foi alta em um mês com baixas pluviosidade e temperatura, sendo resultante da absorção de água armazenada nas camadas mais profundas do solo. Assim, segundo os autores, as árvores expressam o crescimento do tronco em resposta às variáveis climáticas após um intervalo de tempo, considerado como período de defasagem.

Nesse sentido é interessante considerar os fatores climáticos anuais, uma vez que ao considerar as normais climatológicas, uma alteração da produtividade florestal causada por algum extremo climático em um determinado ano poderá ser atribuída erroneamente a outros fatores. Além disso, de acordo com as configurações das melhores redes do presente estudo, também é importante levar em consideração os dados climáticos de um período anterior ao plantio.

Em relação às variáveis categóricas utilizadas para treinar as redes, o espaçamento e o genótipo mostraram-se muito importantes para a obtenção de estimativas mais precisas, pois as redes sem a inclusão dessas variáveis tiveram redução na correlação e maior diferença entre os valores de IMA6 observados e estimados. Binoti et al. (2015) utilizaram RNA para projetar o volume de eucalipto e observaram que entre as variáveis categóricas (classe de solo, textura, espaçamento, relevo, projeto e genótipo), o genótipo foi selecionado em todas as redes pelo algoritmo de otimização.

Apesar de todas as redes selecionadas (usando todas as variáveis de clima e solo; eliminando as variáveis altamente correlacionadas; utilizando as normais climatológicas) terem apresentado resultados semelhantes, sugere-se optar por aquelas com menor quantidade de variáveis e que são de fácil obtenção, otimizando e facilitando o processamento dos dados, além de considerar as variáveis climáticas de um período anterior ao plantio, além do período da rotação.

A obtenção de RNA, sem a inclusão de dados de IFC como variáveis preditoras, tem importância de ordem prática, servindo para elaborar planos estratégicos e táticos de manejo, nos quais é necessário contar com estimativas de produtividade na idade definida para fins de regulação da produção (ALCÂNTARA, 2015). Entender a influência dos fatores ambientais na produtividade possibilita ao gestor florestal escolher a melhor localização para o plantio, selecionar os melhores genótipos para determinada condição, e manejar as florestas de modo a aproveitar melhor os recursos disponíveis.

A possibilidade de inclusão de inúmeras variáveis preditoras, até mesmo categóricas, tornam as RNA uma ferramenta mais generalista. Assim, com a rede treinada é possível obter a produtividade média de eucalipto em áreas onde não existem plantios, utilizando valores para as variáveis preditoras dentro dos limites máximos e mínimos utilizados para treinar a rede, possibilitando a minimização de erros na tomada de decisão em relação a plantios florestais em um determinado local.

5. Conclusões

A utilização de RNA possibilita a estimação do IMA6 de povoamentos de eucalipto com boa precisão, apesar da complexidade dos dados, incluindo muitas variáveis preditoras, até mesmo categóricas.

Entre as variáveis explicativas que possuem maior importância para a estimação da produtividade do eucalipto ao final da rotação, destacam-se o genótipo, o espaçamento, as características edáficas: argila, matéria orgânica e CTC, as características climáticas: precipitação pluviométrica, temperatura e déficit hídrico, e a fertilização realizada durante a rotação.

A produtividade do eucalipto na região Norte de Minas Gerais é limitada pelo déficit hídrico.

6. Referências bibliográficas

ALCÂNTARA, A.E.M. **Redes neurais artificiais para prognose do crescimento e da produção de povoamentos de eucalipto em Minas Gerais**. 2015. 43f. Tese (Doutorado em Ciência Florestal) - Universidade Federal de Viçosa, Viçosa, MG, 2015.

ALMEIDA, A. C.; LANDSBERG, J. J.; SANDS, P. J. Parameterisation of 3-PG model for fast-growing *Eucalyptus grandis* plantations. **Forest Ecology and Management**, v.193, n.1-2, p.179-195, 2004.

BERGER, R.; SCHNEIDER, P.R.; FINGER, C.A.G.; HASELEIN, C.R. Efeito do espaçamento e da adubação no crescimento de um clone de *Eucalyptus saligna* Smith. **Ciência Florestal**, v.12, n.2, p.75-87, 2002.

BHERING, L. L.; CRUZ, C. D.; PEIXOTO, L. D. A.; ROSADO, A. M.; LAVIOLA, B. G., NASCIMENTO, M. Application of neural networks to predict volume in eucalyptus. **Crop Breeding and Applied Biotechnology**, v.15, n.3, p.125-131, 2015.

BILLINGS, W. D. The environmental complex in relation to plant growth and distribution. **Quarterly Review of Biology**, v.27, n.3, p. 251-265, 1952.

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

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

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

BRAGA, F.A.; BARROS, N. F.; SOUZA, A. L.; COSTA, L. M. Características ambientais determinantes da capacidade produtiva de sítios cultivados com eucalipto. **Revista Brasileira de Ciência do Solo**, v.23, n., p.291-298, 1999.

BRANDELERO, C.; ANTUNES, M. U. F.; GIOTTO, E. Silvicultura de precisão: nova tecnologia para o desenvolvimento florestal. **Ambiência**, v.3, n. 2, p. 269-281, 2007.

BULLINARIA, J. A. **Introduction to Neural Computation**. Notas de aula. 2014. Disponível em: <<http://www.cs.bham.ac.uk/~jxb/inc.html>>. Acesso em: 27 de maio de 2015.

CAMPOE, O.T.; STAPE, J.L.; ALBAUGH, T.J.; ALLEN, H.L.; FOX, T.R.; RUBILAR, R.; BINKLEY, D. Fertilization and irrigation effects on tree level aboveground net primary production, light interception and light use efficiency in a loblolly pine plantation. **Forest Ecology and Management**, v.288, p.43–48, 2013.

CAMPOS, J.C.C. Principais fatores do meio que afetam o crescimento das árvores. **Floresta**, v. 2, n. 3, p.45-52 1970.

CAMPOS, B. P. F.; DA SILVA, G. F.; BINOTI, D. H. B.; DE MENDONÇA, A. R.; LEITE, H. G. Predição da altura total de árvores em plantios de diferentes espécies por meio de redes neurais artificiais. **Pesquisa Florestal Brasileira**, v.3, n.88, p.375-385, 2016.

DELL INC. **Dell Statistica (data analysis software system)**, versão 13, 2015.

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

FERRAZ, E.S.B. A influência da precipitação na produção de matéria seca de eucaliptos. **IPEF**, n.46, p.32-42, 1993.

FERREIRA, M.Z. **Modelagem da influência de variáveis ambientais no crescimento e produção de *Eucalyptus sp.*** 2009. 101f. Tese (Mestrado em Ciências Florestais) - Universidade Federal de Lavras, 2009.

GAVA, J. L.; GONÇALVES, J.L.M. Soil attributes and wood quality for pulp production in plantations of *Eucalyptus grandis* clone. **Scientia Agricola**, v.65, n.3, p.306-313, 2008.

GUIMARÃES, D.P.; SILVA, G.G.C.; SANS, L.M.A.; LEITE, F.P. Uso do modelo de crescimento 3-PG para o zoneamento do potencial produtivo do eucalipto no estado de Minas Gerais. **Revista Brasileira de Agrometeorologia**, v.15, n.2, p. 192-197, 2007.

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

IBÁ - Indústria Brasileira de Árvores. **Relatório Anual 2016**. Disponível em: http://iba.org/images/shared/Biblioteca/IBA_RelatorioAnual2016_.pdf. Acesso em: 22 de set. de 2016.

LAFETÁ, B. O. **Eficiência nutricional, área foliar e produtividade de plantações de eucalipto em diferentes espaçamentos estimados com redes neurais artificiais**. 2012.76f. Dissertação (Mestrado em Ciência Florestal) - Universidade Federal dos Vales do Jequitinhonha e Mucuri,2012.

LEMO FILHO, L. C. D. A.; CARVALHO, L. G. D.; EVANGELISTA, A. W., CARVALHO, L. M. T. D.; DANTAS, A. A. Análise espaço-temporal da evapotranspiração de referência para Minas Gerais. **Ciência e Agrotecnologia**, v.31, n.5, 2007

MAESTRI, R. et al. Modelagem do crescimento florestal considerando variáveis do ambiente: revisão. **Scientia Agraria**, v.14, n.3, p.103-110, 2013.

MARCATTI, G. E.; RESENDE, R. T.; RESENDE, M. D. V.; RIBEIRO, C. A. A.; DOS SANTOS, A. R.; DA CRUZ, J. P.; LEITE, H. G. GIS-based approach applied to optimizing recommendations of *Eucalyptus* genotypes. **Forest Ecology and Management**, v.392, 144-153, 2017.

MARTINS, E.R.; BINOTI, M.L.M.S.; LEITE, H.G.; BINOTI, D.H.B.; DUTRA, G.C. Configuração de redes neurais artificiais para estimação da altura total de árvores de eucalipto. **Agrária**, v.11, n.2, p.117-123, 2016.

MEDEIROS, R. A. **Potencial produtivo, manejo e experimentação em povoamentos de *Tectona grandis* Lf no Estado de Mato Grosso**. 2016. 182f. Tese (Doutorado em Ciência Florestal) - Universidade Federal de Viçosa, Viçosa, MG, 2016.

MONTEZANO, Z. F.; CORAZZA, E. J.; MURAOKA, T. Variabilidade espacial da fertilidade do solo em área cultivada e manejada homoganeamente. **Revista Brasileira de Ciência do Solo**, v.30, n., p.839-847, 2006.

ORTIZ, J. L.; VETTORAZZI, C. A.; COUTO, H. T. Z.; GONÇALVES, J. L. M. Relações espaciais entre o potencial produtivo de um povoamento de eucalipto e atributos do solo e do relevo. **Scientia Forestalis**, n. 72, p. 67-79, 2006.

OTTO, M.S.G.; HUBBARD,R.M.; BINKLEY,D.; STAPE,J.L. Dominant clonal *Eucalyptus grandis x urophylla* trees use water more efficiently. **Forest Ecology and Management**, v.328, p.117–121, 2014.

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

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

- PEREIRA, A.R.; ANGELOCCI, L.R.; SENTELHAS, P.C. **Agrometeorologia – Fundamentos e Aplicações**. Guaíba: Editora Agropecuária, 478 p., 2002.
- SETTE JR, C.R.; TOMAZELLO FILHO, M.; DIAS, C.T.S.; LACLAU, J.P. Crescimento em diâmetro do tronco das árvores de *Eucalyptus grandis* W. Hill. ex. Maiden e relação com as variáveis climáticas e fertilização mineral. **Revista Árvore**, v.34, n.6, p.979-990, 2010.
- SILVA, I. N.; SPATTI, H. D.; FLAUZINO, R. A. **Redes Neurais Artificiais: para engenharia e ciências aplicadas**. São Paulo: Artliber, 399 p. 2010.
- SILVA, R.M.L.; HAKAMADA, R.E.; BAZANI, J.H.; OTTO, M.S.G.; STAPE, J.L. Fertilization response, light use, and growth efficiency in *Eucalyptus* plantations across soil and climate gradients in Brazil. **Forests**, v.7, n.117, p.1-12, 2016.
- SILVA RIBEIRO, R. B.; GAMA, J. R. V.; DE SOUZA, A. L.; LEITE, H. G.; SOARES, C. P. B.; SILVA, G. F. Métodos para estimar o volume de fustes e galhos na Floresta Nacional do Tapajós. **Revista Árvore**, v. 40, n. 1, p. 81-88, 2016.
- SOARES, C.P.B.; LEITE, H.G. Predição da produção de madeira de eucalipto em região com alta variabilidade pluviométrica. **Scientia Florestalis**, n.58, p.41-48, 2000.
- STAPE, J.L.; BINKLEY, D.; RYAN, M.G.; GOMES, A.N. Water use, water limitation, and water use efficiency in a *Eucalyptus* plantation. **Bosque**, v. 25, n.2, p. 35-41, 2004a.
- STAPE, J. L.; RYAN, M. G.; BINKLEY, D. Testing the utility of the 3-PG model for growth of *Eucalyptus grandis* x *urophylla* with natural and manipulated supplies of water and nutrients. **Forest Ecology and Management**, Amsterdam, v. 193, p. 219-234, 2004b.
- VAHEDI, A. A. Monitoring soil carbon pool in the Hyrcanian coastal plain forest of Iran: Artificial neural network application in comparison with developing traditional models. **Catena**, v.152, p.182-189, 2017
- XAVIER, A.C.; KING, C.W.; SCANLON, B.R. Daily gridded meteorological variables in Brazil (1980–2013). **International Journal of Climatology**, v.36, n.6, p.2644–2659, 2015.
- WHITEHEAD, D.; BEADLE, C.L. Physiological regulation of productivity and water use in *Eucalyptus*: a review. **Forest Ecology and Management**, v.193, p.113–140, 2004.

CAPÍTULO 3: Importância das variáveis preditoras na estimação da produtividade de eucalipto através de redes neurais artificiais

1. Introdução

As redes neurais artificiais (RNA) são sistemas computacionais paralelos compostos por vários elementos de processamento simples, neurônios artificiais, conectados entre si, sendo essas conexões associadas a pesos, de uma maneira específica para executar uma determinada tarefa (BULLINARIA, 2014). Segundo esse autor, entre as vantagens da utilização das redes, destacam-se a capacidade de aprender a partir de um conjunto de dados de treinamento, em que os pesos das conexões entre os neurônios são ajustados para que a resposta da rede seja mais próxima à desejada, e a possibilidade do uso mais generalizado.

As RNA têm apresentado melhor desempenho, comparadas à regressão múltipla, na predição de respostas que envolvem relação não linear e interação de efeitos entre as variáveis independentes (LEK, 1996; FISHER, 2015). Outra vantagem das redes é que elas não necessitam de pressupostos sobre a distribuição das variáveis independentes (GIAM e OLDEN, 2015). Por esses motivos e a possibilidade de inclusão de inúmeras variáveis, inclusive as categóricas, as RNA têm sido bastante utilizadas em estudos de crescimento e produção florestal (OZÇELIK et al., 2010; DIAMANTOPOULOU, 2012; LAFETÁ, 2012; BINOTI et al., 2013; BINOTI et al., 2015; ALCÂNTARA, 2015; CAMPOS et al., 2016; MARTINS et al., 2016; BHERING et al., 2015; MEDEIROS, 2016; SILVA RIBEIRO et al., 2016), uma vez que a produtividade dos povoamentos florestais é resultante da relação complexa entre diversos fatores, bióticos e abióticos, e influenciada pelo manejo florestal e práticas silviculturais.

Apesar das vantagens citadas, as redes neurais artificiais não permitem estabelecer uma relação causa-efeito das variáveis preditoras na resposta da rede, assim como o entendimento das suas inter-relações (OLDEN e JACKSON, 2002). Para contornar algumas das desvantagens do uso das RNA, comparado aos modelos de regressão, alguns autores sugerem a inversão de redes, que objetiva obter as entradas que fornecem uma determinada saída. No entanto, o problema associado a esta técnica é que ela resulta em um mapeamento de um para muitos entre a saída e as entradas, pois diferentes entradas podem produzir uma mesma saída, além dos resultados obtidos pela inversão não serem perfeitos e de existir erros associados (DUA e GUPTA, 2000).

Algumas metodologias foram desenvolvidas, principalmente em função dos pesos das conexões, para fornecer a contribuição das variáveis independentes no resultado da RNA. Olden e Jackson (2002) citam algumas delas:

- Algoritmo de Garson: avalia a importância relativa das variáveis explicativas para uma única variável resposta. É feito o particionamento dos pesos através da identificação de todas as conexões que ligam uma determinada variável à camada de saída, sendo feito para todas as variáveis explicativas. As conexões são contabilizadas para cada variável de entrada e dimensionadas em relação a todas as outras entradas, e um único valor de importância relativa é obtido para cada variável explicativa. Esse algoritmo utiliza o valor absoluto do peso, não fornecendo a direção da relação entre x e y.
- Análise de sensibilidade pelo método Lekprofile: calcula a resposta retornada pelo modelo para um intervalo (máximo e mínimo) de cada variável explicativa, enquanto mantém as outras constantes (por exemplo, mínimo, percentil, máximo).
- NID (Diagrama de Interpretação Neuronal): diagrama que representa, através dos pesos, a contribuição das variáveis de entrada na rede. A magnitude de cada peso é representada pela espessura das linhas das conexões entre os neurônios, e a direção é representada pelo sombreado das mesmas.

Semelhante ao algoritmo de Garson, o algoritmo de Olden também leva em consideração os pesos das conexões entre os neurônios para definir a importância das variáveis. Esse algoritmo usa o produto dos pesos brutos das conexões das camadas entrada-oculta e oculta-saída para cada variável de entrada e cada neurônio da camada oculta, e soma os produtos de todos os neurônios ocultos (BECK, 2015). De acordo com esse autor, a vantagem desse método, comparado ao de Garson, é que a contribuição de cada peso é mantida em termos de magnitude e sinal. Assim, quando os pesos mudam de sinal da conexão entrada-oculta para a oculta-saída, esses possuem um efeito de cancelamento, enquanto que o algoritmo de Garson pode fornecer resultados enganadores com base na magnitude absoluta.

Outra metodologia utilizada para ranquear a importância das variáveis é a Análise de Sensibilidade Global, realizada pelo programa Statistica (DELL INC., 2015). Nessa análise, o conjunto de dados é enviado para a rede várias vezes, com cada variável, por vez, substituída pelo seu valor médio. Se uma variável é importante para a rede em questão, o erro da rede com os valores alterados é maior que o da rede com os valores normais. Esse método é citado por Gevrey et al. (2003) como um *stepwise* aperfeiçoado, com a vantagem de apenas um modelo ser treinado e cada variável ser processada por vez para avaliar o erro associado à sua alteração. Já no *stepwise* clássico, um modelo é gerado em cada passo e requer ser treinado.

Apesar da existência dessas metodologias, que possibilitam avaliar o comportamento e a influência das variáveis preditoras na resposta da RNA, não existem estudos na área florestal que tenham feito a utilização delas. Nesse sentido, o objetivo desse estudo foi utilizar as metodologias NID, Olden, Garson, Lekprofile e Análise de Sensibilidade Global para avaliar a importância de variáveis ambientais, espaçamento e fertilizações realizadas, em uma RNA treinada para estimar o IMA6 de povoamentos de um clone de eucalipto em Minas Gerais.

2. Material e Métodos

Os dados utilizados são provenientes de plantios de eucalipto da empresa Gerdau, existentes em distintas regiões de Minas Gerais. Foram utilizados dados de incremento médio anual em volume de madeira com casca obtido por meio de inventário florestal contínuo (IFC) de 193 talhões do clone GG100. Além das informações do IFC, foram utilizadas informações sobre a textura do solo e fertilizações realizadas nos talhões durante os seis anos da rotação.

Os dados climáticos foram obtidos para as coordenadas dos centroides dos talhões através de um banco de dados desenvolvido por Xavier et al. (2015). Foram considerados os dados de precipitação pluviométrica total dos oito anos anteriores à obtenção do IMA6 (seis anos da rotação mais dois anos anteriores ao plantio) e a temperatura média dos seis anos após o plantio. As variáveis utilizadas para treinar as redes estão na Tabela 1.

Não foram utilizadas variáveis categóricas para treinar as redes, uma vez que para esse tipo de variável é utilizada a codificação 1-de-c (BISHOP, 1995). Assim, a análise da importância das variáveis preditoras seria feita para cada classe (por exemplo, para cada clone ou espaçamento) e não para a variável, o que não faria muito sentido nesse estudo.

Tabela 1 – Variáveis utilizadas para treinar as redes neuronais artificiais

Variável de saída	Unidade	Mínimo	Quartil 1	Quartil 2	Quartil 3	Máximo
IMA6 = Incremento médio anual aos 6 anos de idade	m ³ ha ⁻¹ ano ⁻¹	17,55	28,55	33,76	37,60	50,71
Variáveis Contínuas	Unidade	Mínimo	Quartil 1	Quartil 2	Quartil 3	Máximo
Esp = Espaçamento	m ² planta ⁻¹	6,00	7,50	8,75	9,00	9,00
ARG = Argila (0-20 cm)	%	6,00	14,50	34,00	50,00	74,00
Prec_sum = Precipitação pluviométrica total dos 8 anos anteriores a obtenção do IMA6	mm	6756,12	8013,66	9101,61	10765,68	12883,39
Tmax = Temperatura máxima (média dos 6 anos do plantio)	° C	25,19	29,56	30,046	30,796	31,10
Tmin = Temperatura mínima (média dos 6 anos do plantio)	° C	14,43	17,58	17,95	18,64	19,14
Tmed = Temperatura média (média dos 6 anos do plantio)	° C	20,03	23,61	24,00	24,70	25,12
N_ad = N total adicionado durante os 6 anos	kg ha ⁻¹	0,00	20,11	21,40	23,74	60,93
P_ad = P ₂ O ₅ total adicionado durante os 6 anos	kg ha ⁻¹	0,00	143,15	156,78	180,7	258,96
K_ad = K ₂ O total adicionado durante os 6 anos	kg ha ⁻¹	53,71	142,02	153,37	205,34	314,56
Ca_ad = CaO total adicionado durante os 6 anos	kg ha ⁻¹	0,00	343,92	459,79	520,3	907,69
Mg_ad = MgO total adicionado durante os 6 anos	kg ha ⁻¹	0,00	69,80	90,00	122,24	240,06
S_ad = S total adicionado durante os 6 anos	kg ha ⁻¹	0,00	0,00	0,00	0,00	45,92
B_ad = B total adicionado durante os 6 anos	kg ha ⁻¹	0,00	2,79	3,56	4,36	6,25
Cu_ad = Cu total adicionado durante os 6 anos	kg ha ⁻¹	0,00	0,00	0,45	0,75	5,75
Zn_ad = Zn total adicionado durante os 6 anos	kg ha ⁻¹	0,00	1,30	2,01	4,26	7,72

Antes de treinar as redes, os dados foram normalizados considerando o valor mínimo e máximo de cada variável em um intervalo fechado (0-1), conforme a equação 1.

$$x' = \frac{(x-x_{min})(b-a)}{(x_{max}-x_{min})} + a \quad (\text{Equação 1}),$$

em que: x' é o valor normalizado; x é o valor original da variável; x_{min} é o valor mínimo da variável; x_{max} é o valor máximo da variável; a é o limite inferior do intervalo de normalização e b é o limite superior do intervalo de normalização.

As redes foram treinadas e validadas no programa R, usando o pacote Neuralnet (FRITSCH e GÜNTHER, 2012). Foram treinadas redes do tipo Perceptron de Múltiplas Camadas (MLP), com a função de ativação logística nas camadas oculta e de saída. O critério de parada utilizado foi o erro médio (0,01) e o algoritmo de treinamento foi o Resilient Propagation (Rprop+). Como o número de observações para o clone GG100 é pequeno, optou-se por definir o conjunto de treinamento em 70 % dos dados, para restarem dados suficientes para o subconjunto de validação.

Foram rodadas 100 redes para cada configuração (variando o número de neurônios na camada oculta e as variáveis independentes), e as melhores redes foram escolhidas de acordo com o coeficiente de correlação entre o IMA6 observado e o estimado ($r_{y\hat{y}}$) e a raiz quadrada do erro quadrático médio em porcentagem (REQM (%)) (equação 2).

$$RQEM(\%) = \frac{100}{\bar{y}} \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad (\text{Equação 2}),$$

em que \bar{y} é a média dos valores observados; n o número total de observações; y_i o valor observado e \hat{y}_i o valor estimado.

Para a melhor rede, foi feita a análise da importância das variáveis preditoras, utilizando as funções: Olden, Garson, Lekprofile (utilizando os valores mínimos, quartil 1, quartil 2, quartil 3 e máximos das variáveis como valores constantes), e Plotnet (que gera o NID) do pacote NeuralNetTools (BECK, 2015). Para o melhor entendimento dos algoritmos de Garson e Olden, no anexo está o passo a passo para o cálculo da importância das variáveis preditoras na estimativa do IMA6 pela rede escolhida, conforme descrito por Olden e Jackson (2002).

A Análise de Sensibilidade Global segue as seguintes etapas de execução:

1º = Normalização dos dados das variáveis dependentes e independentes para o intervalo 0-1;

2° = Separação aleatória dos dados para comporem os subconjuntos de treino e validação;

3° = Treinamento da RNA com o subconjunto treino;

4° = Cálculo do erro quadrático médio;

5° = Substituição dos valores de uma determinada variável explicativa para um valor constante (média) no subconjunto treino;

6° = Obtenção através da rede treinada no passo 3, as estimativas da variável dependente (IMA6) com o banco de dados alterado no passo 5, e obtenção do erro quadrático médio;

7° = Cálculo da razão de sensibilidade para a variável explicativa que teve seus valores substituídos por uma constante (Equação 3).

$$\text{Razão de sensibilidade} = \frac{EQM_{\text{passo 4}}}{EQM_{\text{passo 6}}} \quad (\text{Equação 3})$$

8° = Repetição dos passos 5, 6 e 7 para cada variável explicativa, até que se obtenha a razão de sensibilidade de todas.

Assim, se a variável for importante para a rede, a razão de sensibilidade será maior que um, ou seja, o EQM da rede com a alteração dos valores da variável avaliada será maior que o EQM do subconjunto treino, e quanto maior essa razão, maior a importância.

3. Resultados

Para as melhores redes, menor REQM (%) e maior $r_{y\hat{y}}$, foram necessários apenas três neurônios na camada oculta (Tabela 2). A rede utilizada para fazer a análise de importância das variáveis preditoras foi a RN2, uma vez que as outras redes podem ter sofrido *overfitting*, pela observação da maior redução do coeficiente de correlação no conjunto de validação em relação ao conjunto treino, ou seja, pior capacidade de generalização.

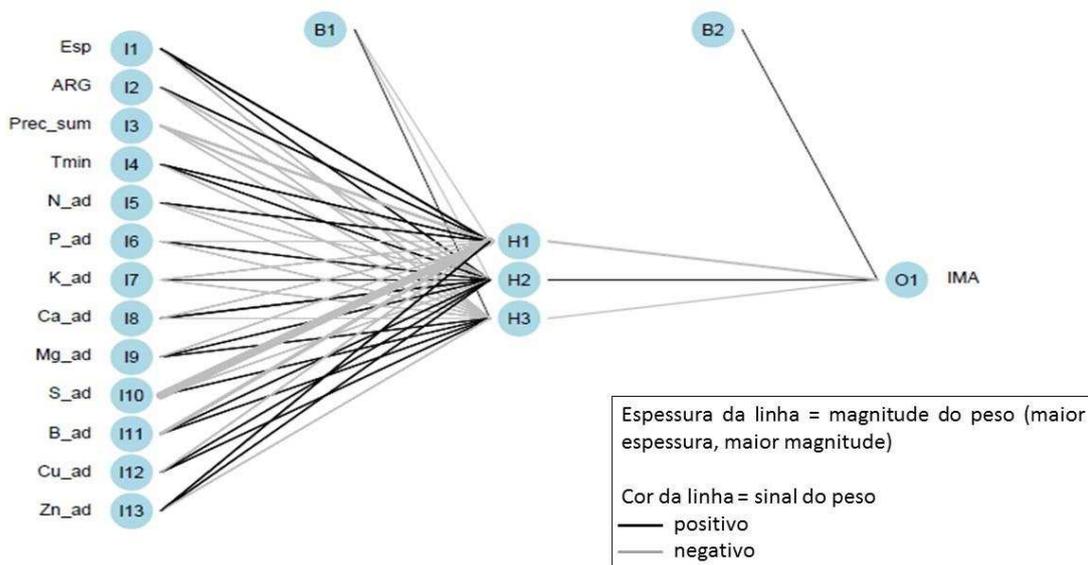
Tabela 2 - Características e precisão da RNA selecionada para estimar o IMA6 em plantios de GG100 em Minas Gerais

Rede	Variáveis	Ciclos	MLP	Treino		Validação	
				$r_{y\hat{y}}$	REQM (%)	$r_{y\hat{y}}$	REQM (%)
RN1	Argila, Precipitação pluviométrica total, Temperatura máxima, Fertilizações	884	13:3:1	0,82	12,73	0,64	17,43
RN2	Argila, Precipitação pluviométrica total, Temperatura mínima, Fertilizações	1432	13:3:1	0,78	13,15	0,71	17,44

RN3	Argila, Precipitação pluviométrica total, Temperatura média, Fertilizações	1213	13:3:1	0,83	12,80	0,62	17,98
-----	---	------	--------	------	-------	------	-------

Argila (%) - camada de 0-20 cm; Precipitação pluviométrica total (mm) – soma da precipitação pluviométrica dos 8 anos anteriores à obtenção do IMA6; Temperatura máxima (° C) - média dos 6 anos da rotação; Temperatura mínima (° C) - média dos 6 anos da rotação; Temperatura média (° C) - média dos 6 anos da rotação; Fertilizações (kg ha⁻¹) - N, P₂O₅, K₂O, CaO, MgO, S, B, Cu, e Zn total adicionados durante os 6 anos da rotação.

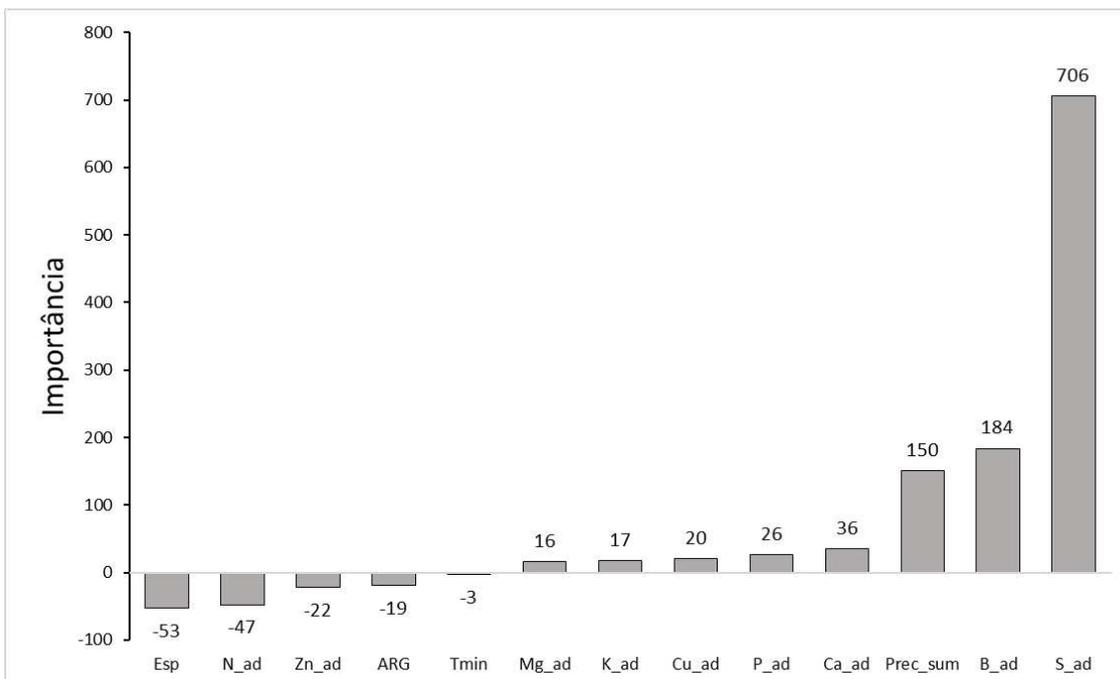
Através do NID (Diagrama de Interpretação Neuronal) (Figura 1) foi possível observar quais pesos são positivos (linha preta) e quais são negativos (linha cinza), assim como suas magnitudes, representadas pela espessura das linhas (maior espessura, maior peso). Para essa rede destacou-se a magnitude do peso negativo (conexão entre o neurônio da camada de entrada (I10) e o neurônio da camada oculta (H1)) da fertilização com S.



Esp – Espaçamento; ARG - Argila (0-20 cm); Prec_sum - Precipitação pluviométrica total dos 8 anos anteriores à obtenção do IMA6; Tmin - Temperatura mínima (média dos 6 anos do plantio); N_ad - N total adicionado durante os 6 anos; P_ad - P₂O₅ total adicionado durante os 6 anos; K_ad - K₂O total adicionado durante os 6 anos; Ca_ad - CaO total adicionado durante os 6 anos; Mg_ad - MgO total adicionado durante os 6 anos; S_ad - S total adicionado durante os 6 anos; B_ad - B total adicionado durante os 6 anos; Cu_ad - Cu total adicionado durante os 6 anos; Zn_ad - Zn total adicionado durante os 6 anos.

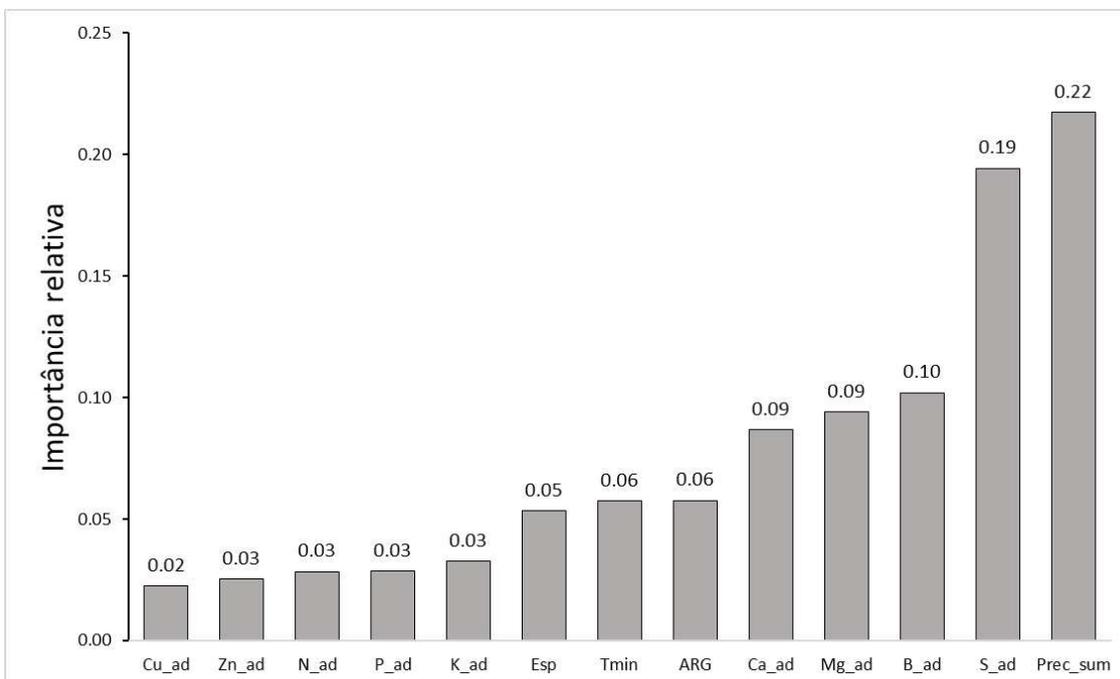
Figura 1 - NID (Diagrama de Interpretação Neuronal) para a rede selecionada (RN2) para estimar o IMA6 de plantios de GG100 em Minas Gerais.

Em relação à importância das variáveis predictoras na rede selecionada observou-se, pelo algoritmo de Olden (Figura 2), que a fertilização com S e B e a precipitação pluviométrica total (oito anos anteriores à obtenção do IMA6) são as mais importantes, ao contrário da temperatura mínima. Já pelo algoritmo de Garson (Figura 3) a precipitação pluviométrica total foi a variável mais importante, seguida da fertilização com S.



Esp – Espaçamento; ARG - Argila (0-20 cm); Prec_sum - Precipitação pluviométrica total dos 8 anos anteriores à obtenção do IMA6; Tmin - Temperatura mínima (média dos 6 anos do plantio); N_ad - N total adicionado durante os 6 anos; P_ad - P2O5 total adicionado durante os 6 anos; K_ad - K2O total adicionado durante os 6 anos; Ca_ad - CaO total adicionado durante os 6 anos; Mg_ad - MgO total adicionado durante os 6 anos; S_ad - S total adicionado durante os 6 anos; B_ad - B total adicionado durante os 6 anos; Cu_ad - Cu total adicionado durante os 6 anos; Zn_ad - Zn total adicionado durante os 6 anos.

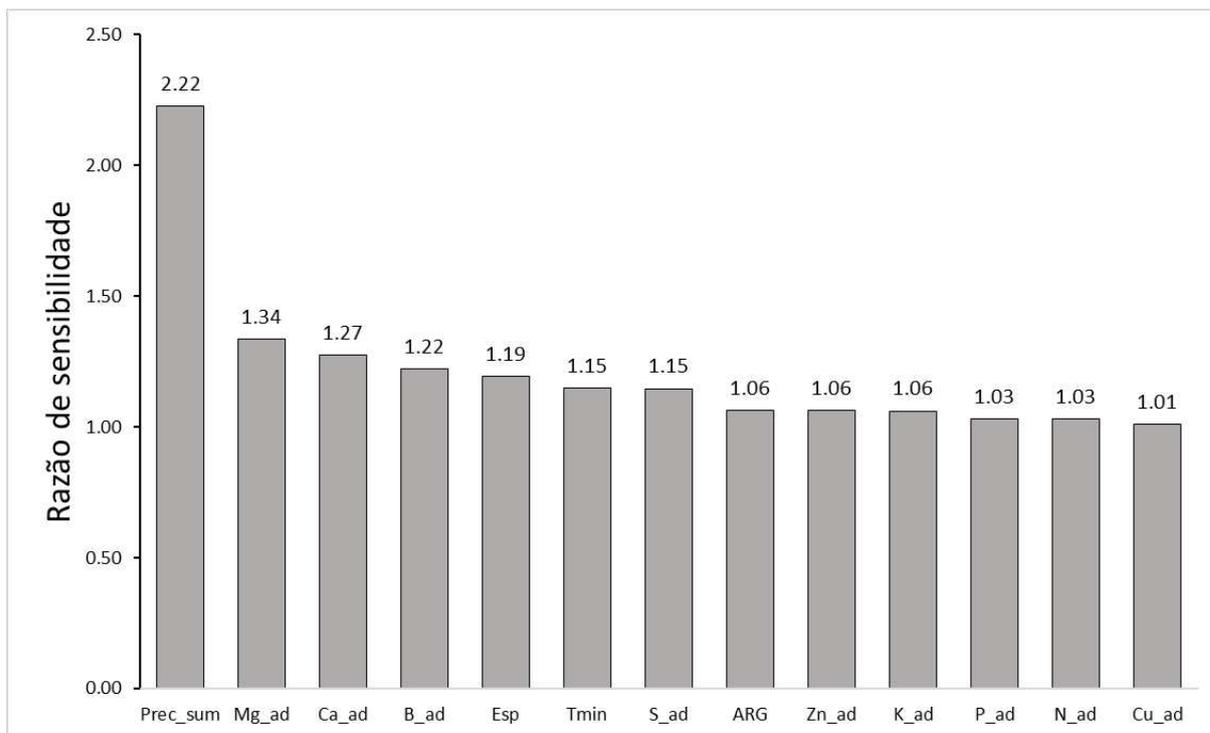
Figura 2 – Algoritmo de Olden para definir a importância das variáveis predictoras na resposta (IMA6) da rede neuronal selecionada (RN2).



Esp – Espaçamento; ARG - Argila (0-20 cm); Prec_sum - Precipitação pluviométrica total dos 8 anos anteriores à obtenção do IMA6; Tmin - Temperatura mínima (média dos 6 anos do plantio); N_ad - N total adicionado durante os 6 anos; P_ad - P2O5 total adicionado durante os 6 anos; K_ad - K2O total adicionado durante os 6 anos; Ca_ad - CaO total adicionado durante os 6 anos; Mg_ad - MgO total adicionado durante os 6 anos; S_ad - S total adicionado durante os 6 anos; B_ad - B total adicionado durante os 6 anos; Cu_ad - Cu total adicionado durante os 6 anos; Zn_ad - Zn total adicionado durante os 6 anos.

Figura 3 – Algoritmo de Garson para definir a importância das variáveis predictoras na resposta (IMA6) da rede neuronal selecionada (RN2).

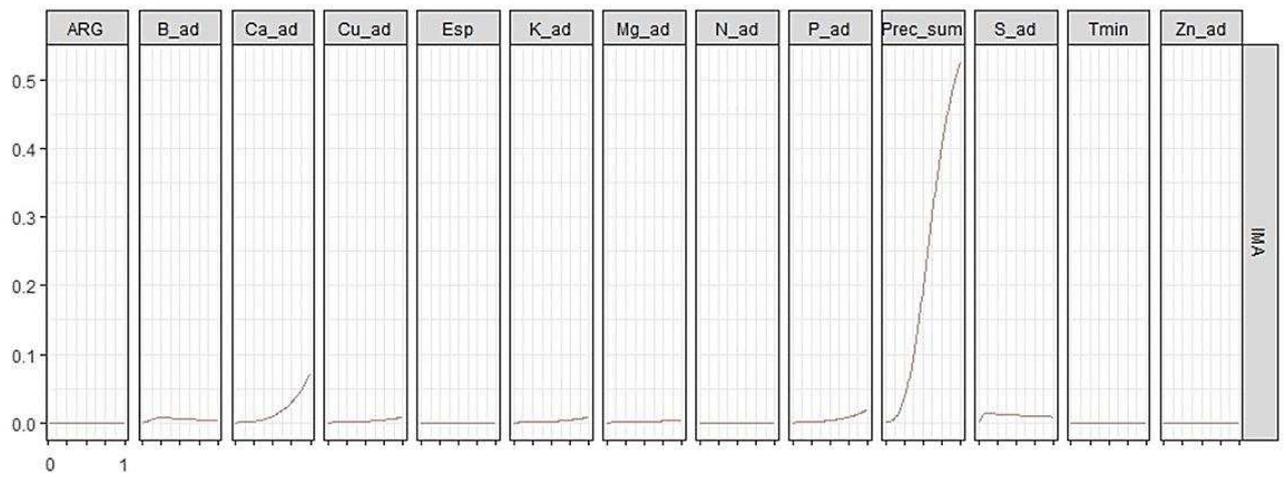
A Análise de Sensibilidade Global (Figura 4) forneceu resultados mais parecidos com os obtidos pelo algoritmo de Garson, sendo que a precipitação pluviométrica total também foi a variável mais importante para a RNA selecionada. Variáveis com razão de sensibilidade igual ou menor que um são menos importantes, uma vez que o erro permanece constante ou diminui com a alteração dos seus valores para uma constante (média).



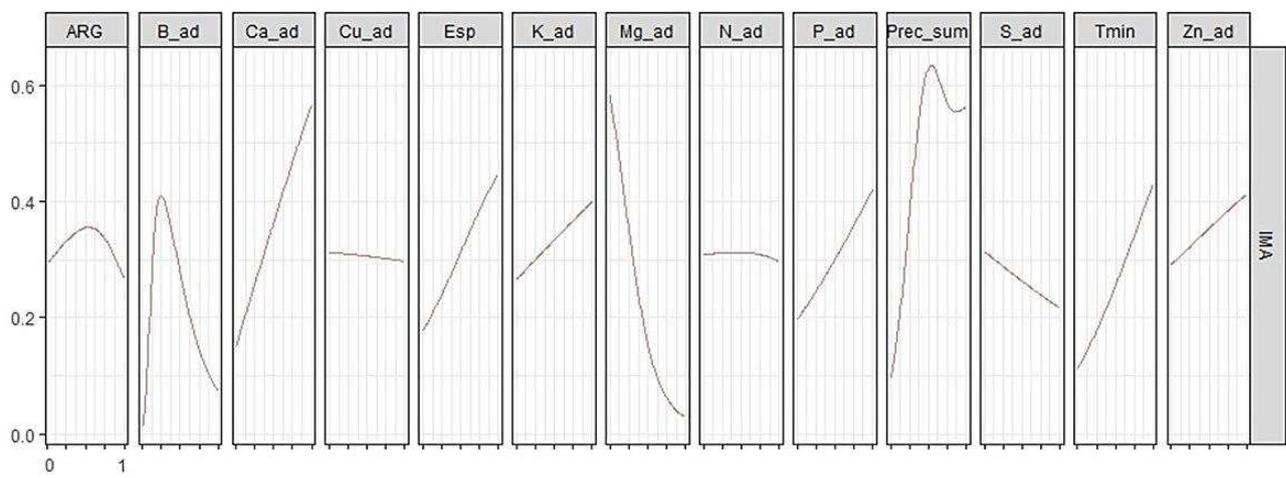
Esp - Espaçamento; ARG - Argila (0-20 cm); Prec_sum - Precipitação pluviométrica total dos 8 anos anteriores à obtenção do IMA6; Tmin - Temperatura mínima (média dos 6 anos do plantio); N_ad - N total adicionado durante os 6 anos; P_ad - P2O5 total adicionado durante os 6 anos; K_ad - K2O total adicionado durante os 6 anos; Ca_ad - CaO total adicionado durante os 6 anos; Mg_ad - MgO total adicionado durante os 6 anos; S_ad - S total adicionado durante os 6 anos; B_ad - B total adicionado durante os 6 anos; Cu_ad - Cu total adicionado durante os 6 anos; Zn_ad - Zn total adicionado durante os 6 anos.

Figura 4 – Análise de sensibilidade global para as variáveis explicativas utilizadas para treinar a RNA selecionada (RN2)

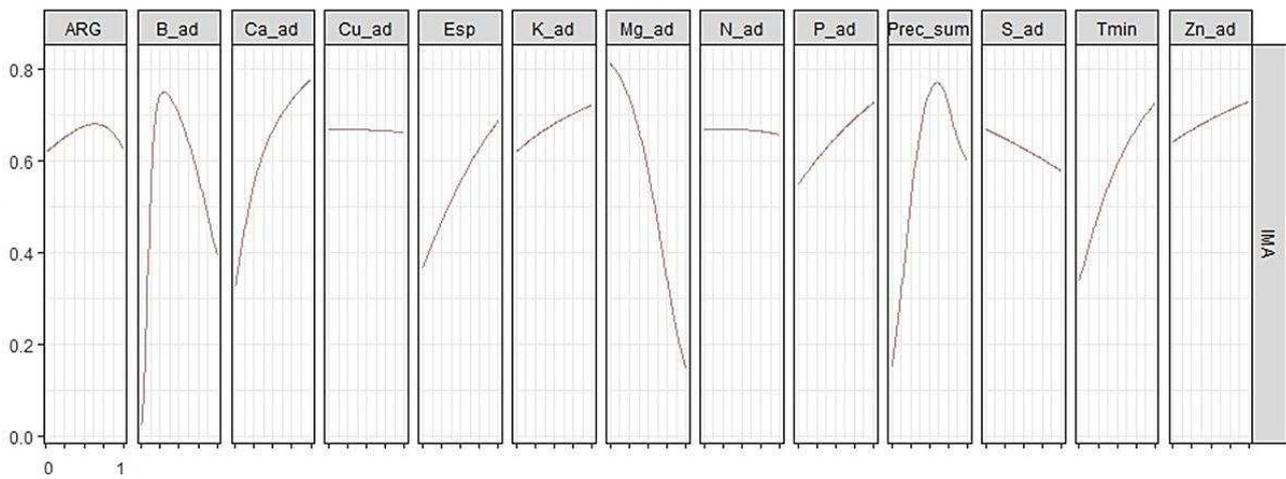
Através do método Lekprofile foi possível observar o comportamento do IMA6 para cada variável explicativa, mantendo os valores das outras variáveis constantes (Figura 5). Quando as variáveis foram mantidas constantes no valor mínimo, as únicas variáveis que promoveram o aumento do IMA6 foram a adição de Ca, em menor magnitude, e a precipitação pluviométrica total. Quando os valores das variáveis foram mantidos constantes nos valores do quartil 1, 2, 3 e máximos, a maioria das variáveis promoveu aumento do IMA6.



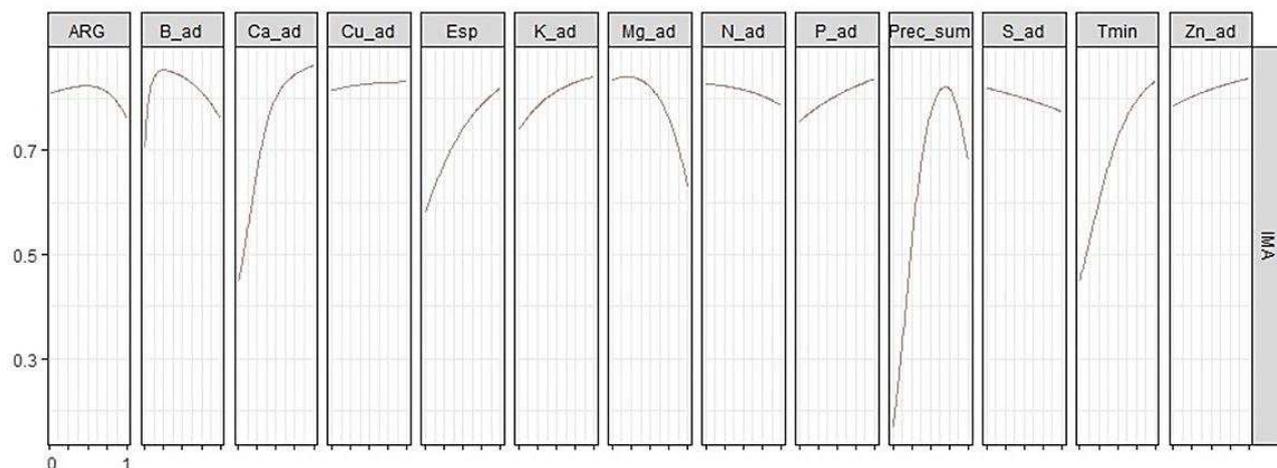
(a)



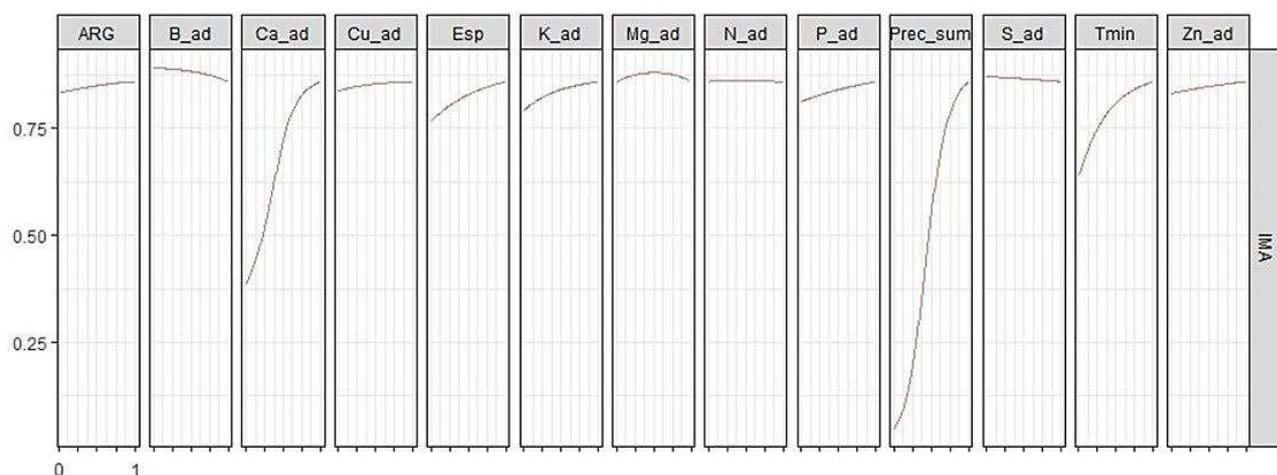
(b)



(c)



(d)



(e)

Esp – Espaçamento; ARG - Argila (0-20 cm); Prec_sum - Precipitação pluviométrica total dos 8 anos anteriores à obtenção do IMA6; Tmin - Temperatura mínima (média dos 6 anos do plantio); N_ad - N total adicionado durante os 6 anos; P_ad - P2O5 total adicionado durante os 6 anos; K_ad - K2O total adicionado durante os 6 anos; Ca_ad - CaO total adicionado durante os 6 anos; Mg_ad - MgO total adicionado durante os 6 anos; S_ad - S total adicionado durante os 6 anos; B_ad - B total adicionado durante os 6 anos; Cu_ad - Cu total adicionado durante os 6 anos; Zn_ad - Zn total adicionado durante os 6 anos.

Figura 5 – Análise de sensibilidade pelo método Lekprofile, em que na análise de cada variável preditora as outras foram mantidas nos seus valores (a) mínimos, (b) quartil 1, (c) quartil 2, (d) quartil 3, (e) máximos.

4. Discussão

Considerando que não foram incluídas variáveis do IFC como predictoras, a rede selecionada apresentou precisão satisfatória da estimativa do IMA6 para o clone GG100. Alcântara (2015) usou dados quantitativos (climáticos) e categóricos (clone, espaçamento, idade, rotação e solo predominante) para estimar o IMA7 de povoamentos de eucalipto em Minas Gerais através de RNA. Essa autora obteve REQm de 22 % e correlação de 54 % na validação, usando 90 % dos dados no subconjunto de treinamento.

Embora as RNA têm se mostrado uma ferramenta interessante para modelar relações não lineares e complexas entre as variáveis, alguns autores destacam suas limitações. As redes

neurônios artificiais são vistas como "black boxes", pois os pesos não são interpretáveis devido à presença de camadas ocultas e à não-linearidade da função de ativação, ou seja, elas não são autoexplicativas (LEITE et al., 2011; PENG e WEN, 1999). No entanto, algumas metodologias foram desenvolvidas para resolver esses problemas.

Segundo Beck (2015), os pesos das redes são semelhantes aos parâmetros das regressões, e a diferença é o maior número de pesos que a rede possui, o que a torna mais flexível para modelar relações não lineares e com múltiplas interações. Nesse sentido, a maioria das metodologias, que avaliam a importância das variáveis preditoras nas RNA, levam em consideração os pesos das conexões entre os neurônios.

O NID apresenta uma visualização simples da magnitude e sinal dos pesos das conexões, assim como da arquitetura da rede. Entretanto, esse diagrama não é de fácil compreensão devido à complexidade das conexões, principalmente em redes com muitas variáveis e neurônios na camada oculta (OLDEN e JACKSON, 2002).

Em relação aos algoritmos de Olden e Garson, o ranqueamento da importância das variáveis explicativas na estimativa do IMA6 pela RNA foi diferente. Gevrey et al. (2003) testaram algumas metodologias para obter a importância das variáveis e observaram que os métodos baseados nos pesos das conexões são instáveis. Segundo esses autores, esses métodos podem ser usados, mas é preciso ter conhecimento sobre o problema estudado ou ter a opinião de alguém da área para avaliar se o ranking tem sentido biológico.

Existem alguns trabalhos comparando a acurácia de ambos algoritmos na determinação da importância das variáveis preditoras. Fisher (2015) mostrou que Garson é melhor que Olden quando os modelos envolvem relações não lineares. Porém, Giam e Olden (2015) demonstraram que nenhum dos dois algoritmos teve 100 % de acurácia para ranquear a importância de variáveis explicativas, e que o algoritmo de Olden apresentou maior acurácia comparado ao de Garson. Como pode ser observado, existe uma incerteza de qual algoritmo realmente gera resultados melhores. Segundo Fisher (2015), a maioria dos trabalhos que comprovam a eficácia desses algoritmos usa dados simulados, os quais são restritos a relações lineares e semi-lineares, e aqueles que utilizam dados reais usam modelo de regressão linear como método de referência para avaliar a importância das variáveis explicativas.

Considerando o resultado das outras metodologias usadas nesse estudo, o algoritmo de Garson apresentou melhores resultados na classificação da importância das variáveis preditoras, sendo que a precipitação pluviométrica total e a fertilização com S e B apresentaram maior importância na estimativa do IMA6. Embora os nutrientes avaliados de modo individual terem

mostrado menor importância relativa pelo algoritmo de Garson, a soma da importância dos nove nutrientes adicionados resulta numa importância relativa de 0,61, mostrando a fertilização como um condicionante da produção florestal. Alguns estudos vêm demonstrando o aumento da produtividade florestal por meio da fertilização. Silva et al. (2016) obtiveram um aumento no 24 % no incremento anual médio em volume de povoamentos de eucalipto fertilizados (N, P, K, Ca e Mg) comparado com aqueles nos quais não foi realizada a fertilização.

A análise de sensibilidade global também mostrou a maior importância da precipitação pluviométrica total e a menor importância da fertilização com N e Cu para a estimativa do IMA6, assim como o método Lekprofile. Segundo Grevey et al. (2003), a análise de sensibilidade global (chamada pelo autor de *stepwise* melhorado) tem a desvantagem de gerar apenas a ordem de importância das variáveis. Já o método Lekprofile, além de se mostrar mais condizente com a realidade, permitiu avaliar a importância das variáveis preditoras e como elas influenciam a produtividade do eucalipto ao final da rotação.

Para a maioria das variáveis preditoras, o aumento da sua disponibilidade, quando as outras foram fixadas no mínimo, não promoveu resposta positiva no IMA6, exceto para a precipitação pluviométrica total, em maior magnitude, e para a adição de Ca. Tal fato pode ser explicado pela Lei da Interação, em que cada fator de produção é mais eficaz quando os outros estão perto de seus ótimos.

A medida que aumentou a disponibilidade dos fatores de produção (quartil 1, quartil 2, quartil 3) é possível perceber o aumento do IMA6 em função da maior disponibilidade da maioria das variáveis, principalmente para o Ca adicionado, temperatura mínima e precipitação pluviométrica total. Borges (2012) avaliou os fatores que influenciam a produtividade florestal, condições de clima e fertilidade do solo, em diferentes regiões no Brasil, e concluiu que a precipitação, a radiação solar, a distribuição de chuvas e a temperatura máxima influenciam, nessa ordem, a produtividade potencial de eucalipto; e quanto à demanda nutricional obteve-se a seguinte ordem: $Ca > N > K > Mg > P$. Entretanto, quando os valores das variáveis explicativas foram fixados no máximo, pode-se observar que não houve aumento no IMA6 para o acréscimo da maioria dos nutrientes, o que pode ser explicado pelo fato do excesso de um nutriente no solo reduzir a eficácia de outro, além do fato que o aumento do teor de argila e precipitação pode reduzir a disponibilidade dos mesmos no solo (fixação, lixiviação, por exemplo).

Fica evidente a maior importância da precipitação pluviométrica na produtividade do clone GG100, uma vez que essa variável ambiental ocasionou aumento no IMA6

independentemente dos valores das outras variáveis consideradas. Marcatti et al. (2017) utilizaram um índice ambiental, com informações climáticas, para gerar uma recomendação ótima de genótipos de eucalipto para maximizar a produção volumétrica em uma determinada área, e observaram que esse índice foi influenciado principalmente pela variação na precipitação pluviométrica. Outros trabalhos também comprovam a importância da disponibilidade hídrica na produtividade de povoamentos de eucalipto (STAPE et al., 2008; SETTE JR et. al, 2010; BORGES, 2012; OTTO et al., 2013; OTTO et al., 2014). A disponibilidade de água afeta substancialmente a eficiência da utilização de outros recursos, bem como a biomassa total e sua alocação para raízes, caule e folhas (STAPE et al., 2004), uma vez que é fundamental para a fotossíntese e absorção de nutrientes, principalmente aqueles em que o transporte até as raízes ocorre por fluxo de massa.

Foi observado que houve baixa resposta do IMA6 com o aumento da área útil por planta quando os fatores de produtividade estudados foram fixados no máximo. Entretanto, quando esses valores reduziram (quartil 1, 2 e 3), houve aumento do IMA6 à medida que a área útil por planta aumentou, o que é esperado, uma vez que com a restrição dos recursos necessários ao crescimento (água e nutrientes), a maior área útil por planta pode reduzir a competição por eles.

Para a fertilização com N e Cu, não houve aumento do IMA6, mostrando que os outros fatores estudados foram os responsáveis pelo ganho em produtividade ao final da rotação. Outros trabalhos têm demonstrado a ausência de resposta à fertilização com N em povoamentos de eucalipto ao final da rotação. Pulito et al. (2015) avaliaram o crescimento de eucalipto em função da fertilização nitrogenada e observaram que em idades iniciais a fertilização pode acelerar o crescimento das árvores quando a taxa de mineralização, maior nos solos argilosos, não é suficiente para suprir a demanda das árvores, mas essas respostas tendem a desaparecer com o tempo. Esses autores ressaltam que em locais com baixa disponibilidade de MO e N, ou em rotações subsequentes, o povoamento pode responder à fertilização nitrogenada.

Quando os valores foram fixados no quartil 1, o teor de argila que proporcionou a redução do IMA6 foi menor que na ocasião em que os valores das outras variáveis foram fixados no quartil 2, ou seja, quando se tem menor disponibilidade de nutrientes (por exemplo, fósforo) ou água, menor será o teor crítico de argila para a produtividade florestal. Silva et al. (2016) avaliaram o crescimento de eucalipto em três regiões na Bahia, sendo que a primeira e segunda regiões possuem solos bem arenosos (aproximadamente 90 % de areia e 10 % de argila), e a terceira possui solo com aproximadamente 41 % de argila e mais MO que as outras. Esses autores observaram maior IMA na terceira região devido à ausência de déficit hídrico

nessa região e maior teor de argila e matéria orgânica, possibilitando maior retenção da umidade.

Com o aumento da adição de B e Mg ocorreu redução do IMA6, a qual foi influenciada pela disponibilidade dos outros fatores, sendo que para ambos nutrientes, a redução na produtividade foi em menor magnitude quando os outros fatores foram fixados nos valores máximos. A redução da produtividade pode ser explicada pela aplicação em excesso de nutrientes. A tentativa de contornar a seca de ponteiros em regiões com pronunciado déficit hídrico tem levado algumas empresas a aplicar B em excesso, sendo que a faixa de suficiência para boro é estreita, comparada à de outros nutrientes.

5. Conclusões

Apesar de muitos autores chamarem as RNA de “black boxes”, é possível avaliar a importância das variáveis preditoras na resposta da rede, assim como o comportamento da variável dependente em função das variáveis explicativas.

O método Lekprofile é eficiente em demonstrar quais são as variáveis preditoras mais importantes e como elas influenciam a produtividade do eucalipto.

O IMA6 responde positivamente ao aumento da maioria das variáveis estudadas (fertilização, espaçamento, teor de argila, temperatura mínima do ar e precipitação pluviométrica), quando as outras variáveis explicativas não estão nos seus valores mínimos.

As variáveis que mais influenciam a produtividade média do clone GG100 em Minas Gerais são a precipitação pluviométrica total, o cálcio adicionado e a temperatura mínima do ar.

6. Referências bibliográficas

ALCÂNTARA, A.E.M. **Redes neurais artificiais para prognose do crescimento e da produção de povoamentos de eucalipto em Minas Gerais**. 2015. 43f. Tese (Doutorado em Ciência Florestal) - Universidade Federal de Viçosa, Viçosa, MG, 2015.

BECK, M.W. **NeuralNetTools: Visualization and Analysis Tools for Neural Networks**. R Foundation for Statistical Computing, 2015. R Package.

BHERING, L. L.; CRUZ, C. D.; PEIXOTO, L. D. A.; ROSADO, A. M.; LAVIOLA, B. G., NASCIMENTO, M. Application of neural networks to predict volume in eucalyptus. **Crop Breeding and Applied Biotechnology**, v.15, n.3, p.125-131, 2015.

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

- BINOTI, M. L. M. D. S.; LEITE, H. G.; BINOTI, D. H. B.; GLERIANI, J. M. Prognose em nível de povoamento de clones de eucalipto empregando redes neurais artificiais. **Cerne**, v. 21, n. 1, p. 97-105, 2015.
- BISHOP, C.M. **Neuronal networks for pattern recognition**. Oxford University Press, 1995. 482 p.
- BORGES, J.S. **Modulador edáfico para uso em modelo ecofisiológico e produtividade potencial de povoamentos de eucalipto**. 70f. 2012. Tese (Doutorado em Solos e Nutrição de Plantas) – Universidade Federal de Viçosa, 2012.
- BULLINARIA, J. A. **Introduction to Neural Computation**. Notas de aula. 2014. Disponível em: <<http://www.cs.bham.ac.uk/~jxb/inc.html>>. Acesso em: 27 de maio de 2015.
- CAMPOS, B. P. F.; DA SILVA, G. F.; BINOTI, D. H. B.; DE MENDONÇA, A. R.; LEITE, H. G. Predição da altura total de árvores em plantios de diferentes espécies por meio de redes neurais artificiais. **Pesquisa Florestal Brasileira**, v.3, n.88, p.375-385, 2016.
- DELL INC. **Dell Statistica (data analysis software system)**, versão 13, 2015.
- DIAMANTOPOULOU, M. J. Assessing a reliable modeling approach of features of trees through neural network models for sustainable forests. **Sustainable Computing: Informatics and Systems**, v.2, n.4, p.190-197, 2012.
- DUA, A., GUPTA, A. **Inversion of Neural Networks: A Solution to the Problems Encountered by a Steel Corporation**. 2000. Disponível em: <http://web.mit.edu/profit/PDFS/DuaA.pdf>. Acesso em: 10 de abril de 2017.
- FISCHER, A. How to determine the unique contributions of input-variables to the nonlinear regression function of a multilayer perceptron. **Ecological Modelling**, v.309–310, p.60–63, 2015.
- FRITSCH, S.; GÜNTHER, F. **Neuralnet: Training of Neural Networks**. R Foundation for Statistical Computing, 2012. R Package.
- GIAM, X.; OLDEN, J.D. A new R^2 -based metric to shed greater insight on variable importance in artificial neural networks. **Ecological Modelling**, v.313, p.307–313, 2015.
- GEVREY, M.; DIMOPOULOS, I.; LEK, S. Review and comparison of methods to study the contribution of variables in artificial neural network models. **Ecological modelling**, v. 160, n. 3, p. 249-264, 2003.
- LAFETÁ, B. O. **Eficiência nutricional, área foliar e produtividade de plantações de eucalipto em diferentes espaçamentos estimados com redes neurais artificiais**. 2012.76f. Dissertação (Mestrado em Ciência Florestal) - Universidade Federal dos Vales do Jequitinhonha e Mucuri,2012.
- LEITE, H. G.; DA SILVA, M. L. M.; BINOTI, D. H. B.; FARDIN, L.; TAKIZAWA, F. H. Estimation of inside-bark diameter and heartwood diameter for *Tectona grandis* Linn. trees using artificial neural networks. **European Journal of Forest Research**, v.130, n.2, p.263-269, 2011.

LEK, S.; DELACOSTE, M.; BARAN, P.; DIMOPOULOS, I.; LAUGA, J.; AULAGNIER, S. Application of neural networks to modelling nonlinear relationships in ecology. **Ecological Modelling**, v.90, p. 39-52, 1996.

MARCATTI, G. E.; RESENDE, R. T.; RESENDE, M. D. V.; RIBEIRO, C. A. A.; DOS SANTOS, A. R.; DA CRUZ, J. P.; LEITE, H. G. GIS-based approach applied to optimizing recommendations of *Eucalyptus* genotypes. **Forest Ecology and Management**, v.392, 144-153, 2017.

MARTINS, E.R.; DA SILVA BINOTI, M. L. M.; LEITE, H. G.; BINOTI, D. H. B.; DUTRA, G. C. Configuração de redes neurais artificiais para estimação da altura total de árvores de eucalipto. **Revista Brasileira de Ciências Agrárias**, v.11, n.2, p.117-123, 2016.

MEDEIROS, R. A. **Potencial produtivo, manejo e experimentação em povoamentos de *Tectona grandis* Lf no Estado de Mato Grosso**. 2016. 182f. Tese (Doutorado em Ciência Florestal) - Universidade Federal de Viçosa, Viçosa, MG, 2016.

OLDEN, J.D.; JACKSON, D.A. Illuminating the “black box”: a randomization approach for understanding variable contributions in artificial neural networks. **Ecological Modelling**, v.154, p.135–150, 2002.

OTTO, M.S.G.; VERGANI, A.R.; GONÇALVES, A.N.; VRECHI, A.; SILVA, S.R.; E STAPE, J.L. Fotossíntese, condutância estomática e produtividade de clones de *Eucalyptus* sob diferentes condições edafoclimáticas. **Revista Árvore**, v.36, v.37, n.3, p.431-439, 2013.

OTTO, M.S.G.; HUBBARD, R.M.; BINKLEY, D.; STAPE, J.L. Dominant clonal *Eucalyptus grandis* x *urophylla* trees use water more efficiently. **Forest Ecology and Management**, v.328, p.117–121, 2014.

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

PENG, C.; WEN, X. **Recent applications of artificial neural networks in forest resource management: an overview**. 1999. Disponível em: <https://vvvww.aaai.org/Papers/Workshops/1999/WS-99-07/WS99-07-003.pdf>. Acesso em 15 de março de 2016.

PULITO, A. P.; GONÇALVES, J.L.M.; SMETHURST, P.J.; ARTHUR JUNIOR, J.C.; ALVARES, C.A.; ROCHA, J.H.T.; HÜBNER, A.; MORAES, L.F.; MIRANDA, A.C.; KAMOGAWA, M.Y.; GAVA, J.L.; CHAVES, R.; SILVA, C.R. Available nitrogen and responses to nitrogen fertilizer in Brazilian eucalypt plantations on soils of contrasting texture. **Forests**, v.6, n.4, p.973-991, 2015.

SETTE JR, C.R.; TOMAZELLO FILHO, M.; DIAS, C.T.S.; LACLAU, J.P. Crescimento em diâmetro do tronco das árvores de *Eucalyptus grandis* W. Hill. ex. Maiden e relação com as variáveis climáticas e fertilização mineral. **Revista Árvore**, v.34, n.6, p.979-990, 2010.

SILVA RIBEIRO, R. B.; GAMA, J. R. V.; DE SOUZA, A. L.; LEITE, H. G.; SOARES, C. P. B.; SILVA, G. F. Métodos para estimar o volume de fustes e galhos na Floresta Nacional do Tapajós. **Revista Árvore**, v. 40, n. 1, p. 81-88, 2016.

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**, v.193, p.17–31, 2004.

STAPE, J.L.; BINKLEY, D.; RYAN, M.G. Production and carbon allocation in a clonal *Eucalyptus* plantation with water and nutrient manipulations. **Forest Ecology and Management**, v.255, p.920–930, 2008.

XAVIER, A.C.; KING, C.W.; SCANLON, B.R. Daily gridded meteorological variables in Brazil (1980–2013). **International Journal of Climatology**, v.36, n.6, p.2644–2659, 2015.

CONCLUSÕES GERAIS

As redes neurais artificiais (RNA) são ferramentas mais generalistas, uma vez que permitem a utilização da rede treinada para estimar a produtividade em outras regiões, desde que as variáveis utilizadas sejam as mesmas usadas para treinar a rede, e que seja observada a amplitude dos dados utilizados no seu treinamento.

As RNA são eficientes para modelar relações complexas, com inúmeras informações, além de permitir a inclusão de variáveis categóricas com facilidade.

As variáveis mais importantes para estimar a produtividade de eucalipto ao final da rotação em Minas Gerais são o genótipo, espaçamento, argila, matéria orgânica e CTC, precipitação pluviométrica, temperatura do ar, déficit hídrico e fertilizações realizadas durante a rotação.

A produtividade do eucalipto na região Norte de Minas Gerais é limitada pelo déficit hídrico.

Apesar de questionamentos sobre a avaliação da importância das variáveis preditoras na resposta de RNA, a utilização da metodologia Lekprofile permite com eficiência, não apenas analisar a importância das variáveis preditoras, mas também o comportamento da variável dependente, IMA6, em função das variáveis explicativas.

A precipitação pluviométrica total, a fertilização com cálcio, e a temperatura mínima do ar são as variáveis que apresentam maior importância na produtividade do clone GG100 ao final da rotação, ocorrendo resposta positiva do IMA6 com o acréscimo dessas variáveis.

ANEXOS

Tabela 1 - Faixa do coeficiente de variação, considerando períodos anteriores ao IMA6

Variável climática	Coeficiente de variação (%)
Precipitação pluviométrica total (8 anos anteriores ao IMA6)	11,42 - 25,54
Temperatura máxima (6 anos anteriores ao IMA6)	0,99 - 1,94
Temperatura mínima (6 anos anteriores ao IMA6)	1,04 - 3,44
Temperatura média (6 anos anteriores ao IMA6)	0,66 - 1,71
Velocidade do vento (6 anos anteriores ao IMA6)	1,85 - 14,99
Evapotranspiração potencial (6 anos anteriores ao IMA6)	3,48 - 8,37
Umidade relativa (6 anos anteriores ao IMA6)	2,45 - 4,85
Radiação solar (6 anos anteriores ao IMA6)	1,97 - 6,06
Déficit hídrico (8 anos anteriores ao IMA6)	20,05 - 47,22

Tabela 2 - Correlação de Pearson entre as variáveis do solo da camada 0-20 e 20-40 cm de profundidade.

Variável	Coeficiente de correlação
Areia total	0,99
Areia grossa	0,99
Areia fina	0,99
Argila	0,99
Silte	0,76
m	0,81
V	0,85
P	0,65
K	0,75
pH (H ₂ O)	0,77
pH (CaCl ₂)	0,55
CTC (T)	0,96
H+Al	0,96
Al	0,84
Mg	0,87
Ca	0,56
MO	0,93
P remanescente	0,98

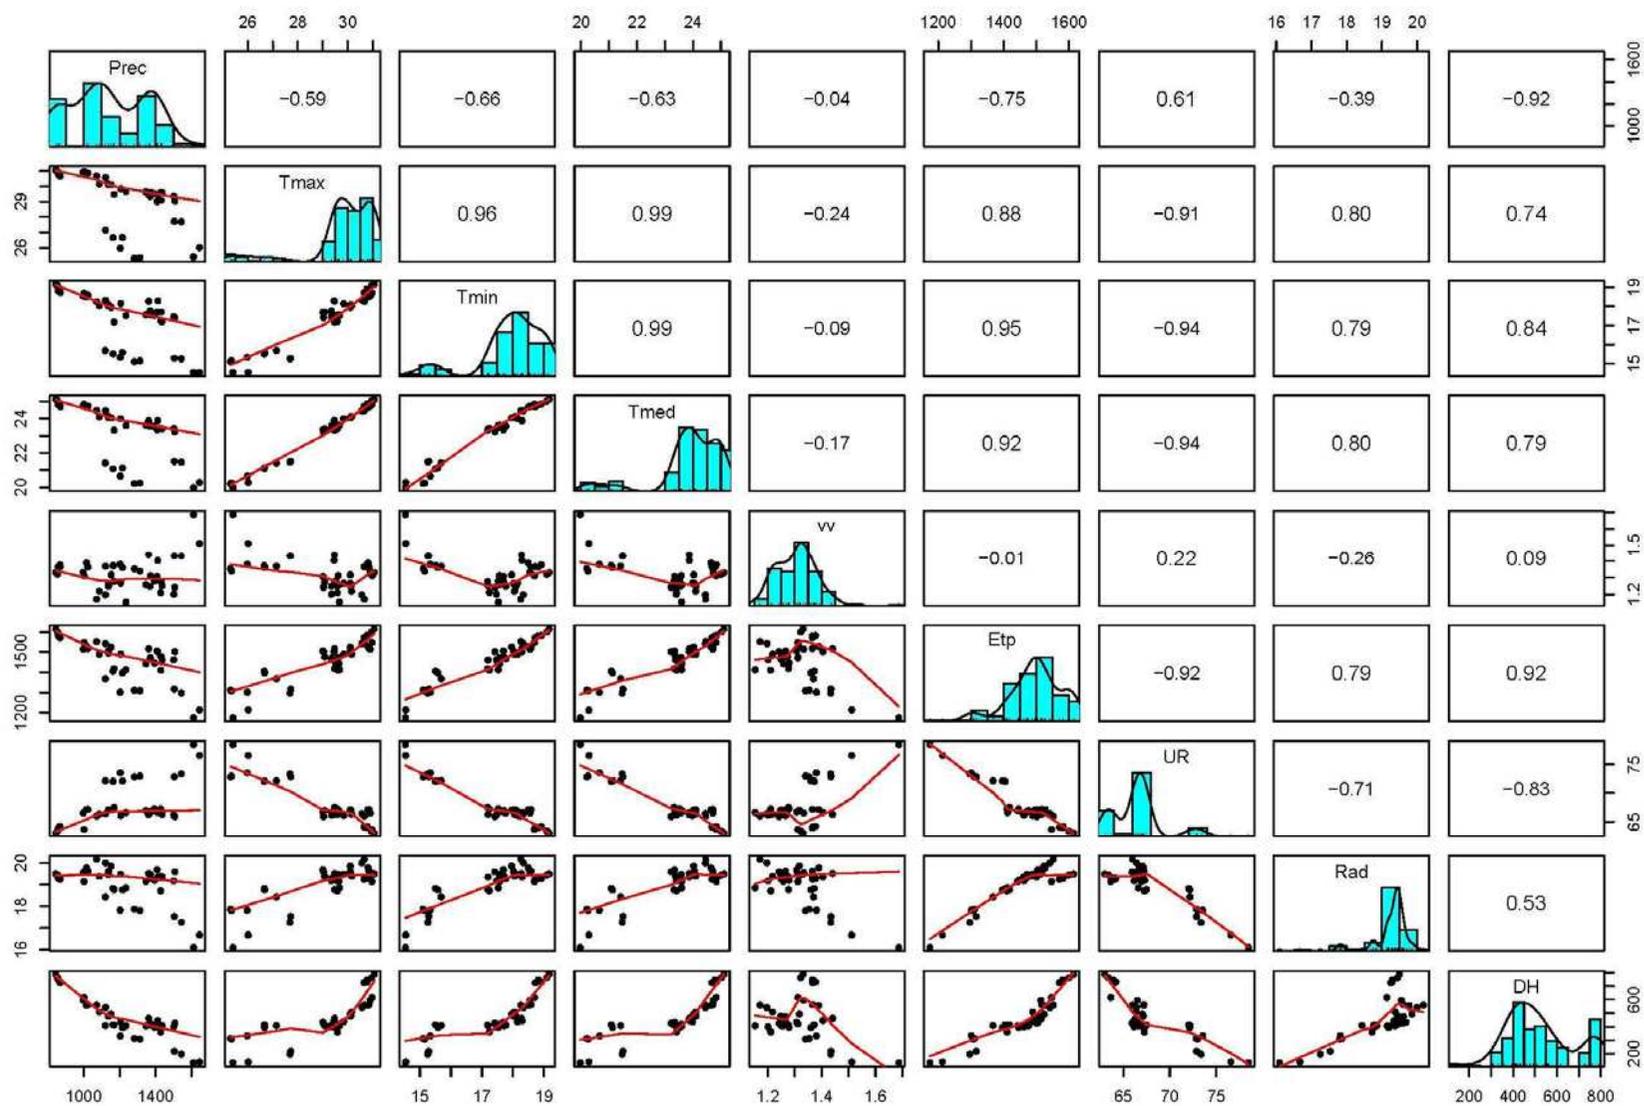


Figura 1 - Correlação de Pearson entre as variáveis climáticas (médias dos 8 anos anteriores ao IMA6)

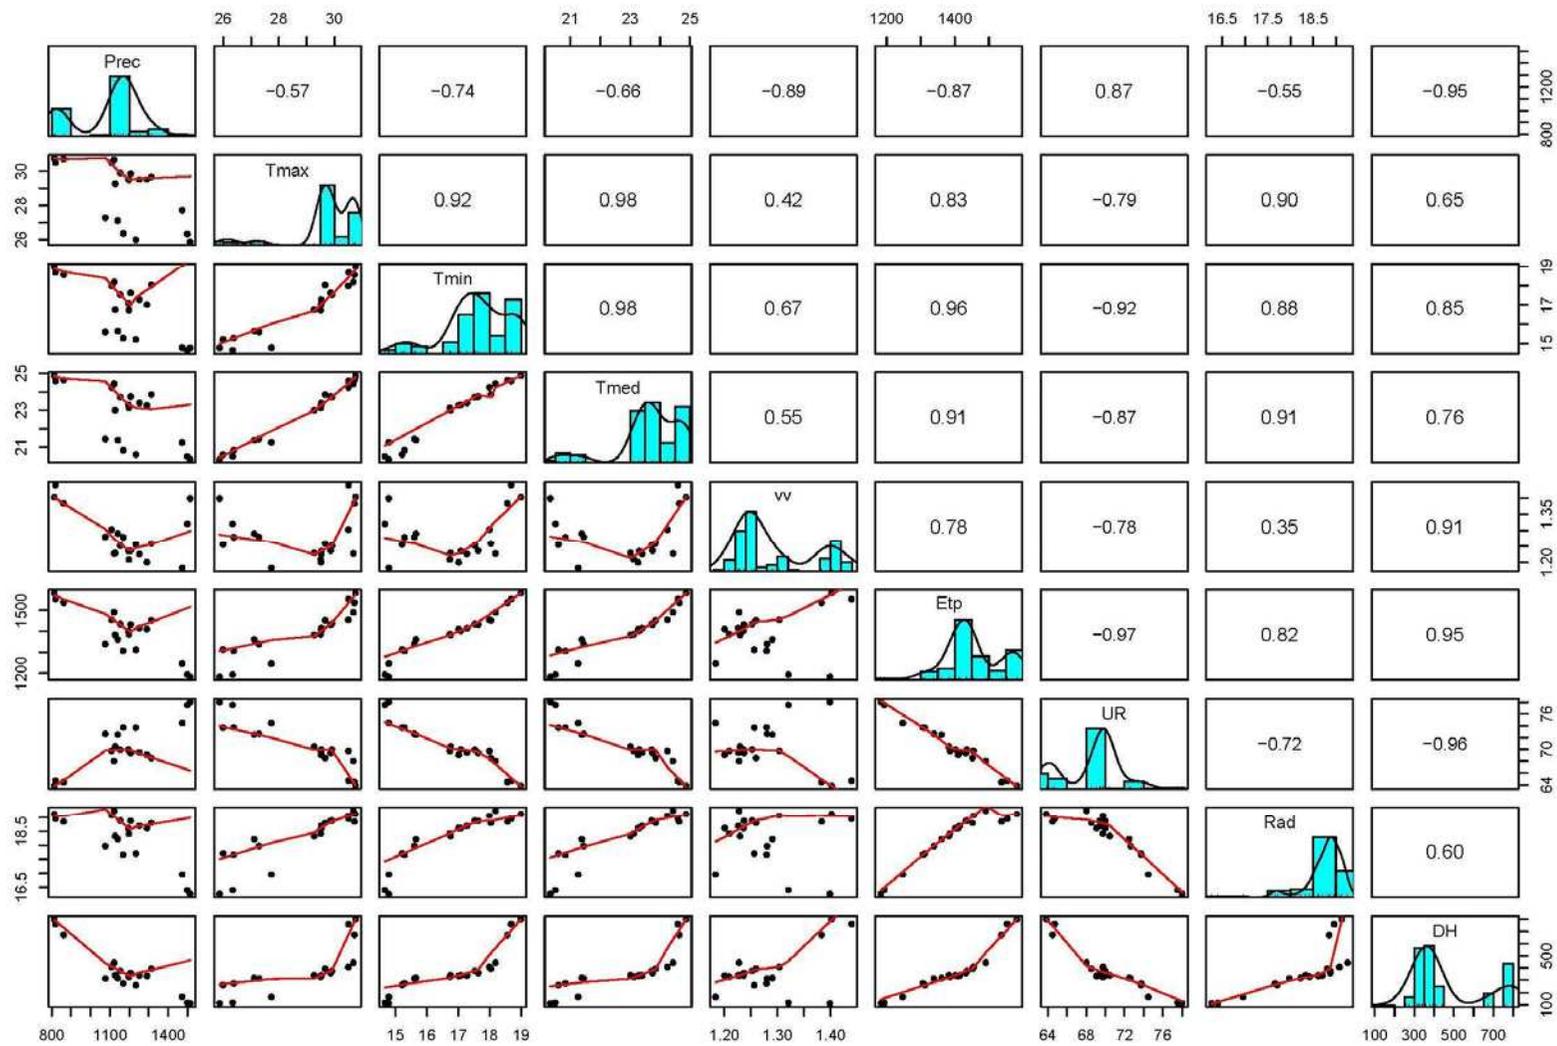


Figura 2 - Correlação de Pearson entre as variáveis climáticas (médias de 1980-2013)

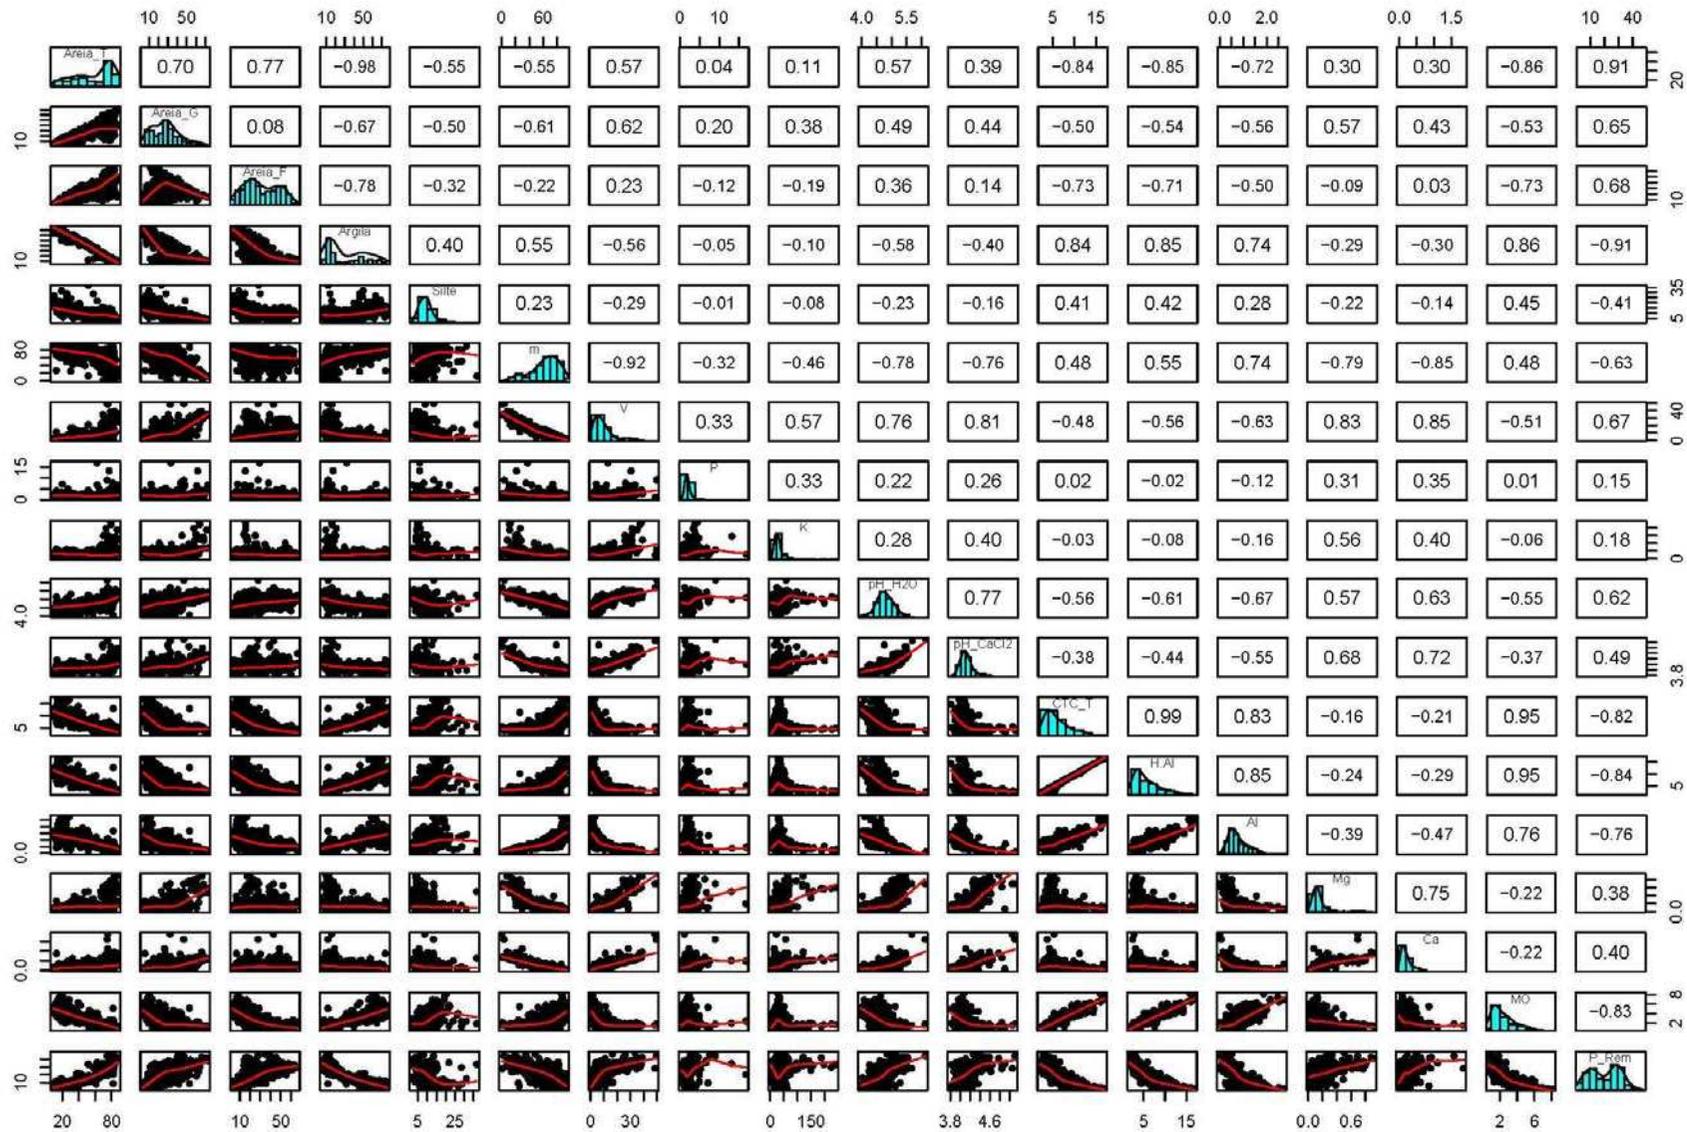


Figura 3 - Correlação de Pearson entre as variáveis edáficas (camada 0-20 cm de profundidade)

Tabela 3 - Redes Neurais Artificiais treinadas

ID	T	V	Variáveis predictoras	Ciclos	Algoritmo	Neurônios	Função	T		V	
	(%)	(%)						r	REQM	r	REQM
RN99	90	10	genótipo/espacamento/P/K/V/CTC/P1P2P3P4P5P6P7P8/Tmin_med(6)/adubações(todas)	2000	Rprop+	8	Log-Log	0.88	3.21	0.89	3.33
RN74	90	10	genótipo/espacamento/m/ARG/P/SOMAP8/Tmin_med(6)/adubações(todas)	3000	Rprop+	6	Log-Log	0.82	3.95	0.88	3.43
RN53	90	10	genótipo/espacamento/P/K/pH(H2O)/Ca/Mg/MO/P1P2P3P4P5P6P7P8/Tmin_med(6)/adubações(todas)	3000	Rprop+	8	Log-Log	0.90	2.97	0.85	3.44
RN66	90	10	genótipo/espacamento/P/K/V/CTC/P1P2P3P4P5P6P7P8/adubações(todas)	3000	Rprop+	8	Log-Log	0.90	2.96	0.86	3.61
RN95	90	10	genótipo/espacamento/P/K/pH(H2O)/Ca/Mg/MO/DH1DH2DH3DH4DH5DH6DH7DH8/adubações(todas)	2000	Rprop+	8	Log-Log	0.88	3.27	0.85	3.63
RN16	90	10	genótipo/espacamento/ARG/AF/AG/SIL/m/V/P/K/pH(H2O)/pH(CaCl2)/CTC/H+Al/Al/Mg/Ca/MO/Prem/DH1DH2DH3DH4DH5DH6DH7DH8/vv_media(6)/Adubações(todas)	3000	Rprop+	8	Log-Log	0.88	3.21	0.85	3.65
RN14	90	10	genótipo/espacamento/ARG/AF/AG/SIL/m/V/P/K/pH(H2O)/pH(CaCl2)/CTC/H+Al/Al/Mg/Ca/MO/Prem/P1P2P3P4P5P6P7P8/Tmin_med(6)/Tmax/Tmed/vv_med(6)/rad_med(6)/Etp_med(6)/UR_med(6)/DH1DH2DH3DH4DH5DH6DH7DH8/Adubações(todas)	3000	Rprop+	8	Log-Log	0.91	2.85	0.87	3.66
RN68	90	10	genótipo/espacamento/m/ARG/P/K/DH1DH2DH3DH4DH5DH6DH7DH8/adubações(todas)	3000	Rprop+	6	Log-Log	0.88	3.24	0.86	3.71
RN44	90	10	genótipo/espacamento/ARG/AF/AG/SIL/m/V/P/K/pH(H2O)/pH(CaCl2)/CTC/H+Al/Al/Mg/Ca/MO/Prem/Climáticas normais(todas)/Adubações(todas)	3000	Rprop+	8	Log-Log	0.81	4.04	0.86	3.80
RN29	90	10	genótipo/espacamento/ARG/P/K/pH(H2O)/Ca/Mg/SOMAP8/Tmax_med(6)/Adubações(todas)	3000	Rprop+	8	Log-Log	0.86	3.53	0.85	3.83
RN91	90	10	genótipo/espacamento/m/ARG/P/K/SOMADH8/adubações(todas)	3000	Rprop+	8	Log-Log	0.86	3.47	0.86	3.85
RN151	90	10	genótipo/espacamento/Análise foliar(todas)/Análise do solo (todas de 0-20 e 20-40 cm)/P1P2P3P4P5P6/DH1DH2DH3DH4DH5DH6/Tmin_med(6)/Tmax/Tmed/vv_med(6)/rad_med(6)/Etp_med(6)/UR_med(6)/todas adubações	3000	Rprop+	6	Log-Log	0.92	2.72	0.85	3.86
RN59	90	10	genótipo/espacamento/P/K/pH(H2O)/Ca/Mg/Prem/SOMADH8/adubações(todas)	3000	Rprop+	8	Log-Log	0.88	3.29	0.80	3.87
RN104	90	10	genótipo/espacamento/P/K/V/CTC/P1P2P3P4P5P6P7P8/Tmin_med(6)/adubações(todas)	3000	Rprop+	7	Log-Log	0.89	3.17	0.80	3.88
RN9	90	10	genótipo/espacamento/ARG/DH_nor	3000	Rprop+	8	Log-Log	0.76	4.58	0.79	3.88
RN250	90	10	genótipo/espacamento/P/K/V/CTC/P1P2P3P4P5P6P7P8/Tmin_med(6)/adubações(todas)	3000	Rprop+	8	Tan-Tan	0.93	2.54	0.84	3.90
RN12	90	10	genótipo/espacamento/ARG/SOMADH(8)/Adubações(todas)	3000	Rprop+	8	Log-Log	0.86	3.51	0.76	3.91
RN159	90	10	genótipo/espacamento/análise do solo (todas na camada 0-20 cm)/P1P2P3P4P5P6P7P8/DH1DH2DH3DH4DH5DH6DH7DH8/Tmin_med(6)/Tmax/Tmed/vv_med(6)/rad_med(6)/Etp_med(6)/UR_med(6)/todas adubações	3000	Back	6	Log-Log	0.91	2.91	0.75	3.95
RN198	90	10	genótipo/espacamento/ARG/P/K/pH(H2O)/Ca/Mg/SOMAP8/Tmax_med(6)/Adubações(todas)	3000	Rprop+	6	Log-Log	0.81	4.16	0.72	3.95
RN156	90	10	genótipo/espacamento/P/K/V/CTC/P1P2P3P4P5P6P7P8/Tmed_med(6)/adubações(todas)	3000	Rprop+	8	Log-Log	0.83	3.89	0.82	3.96
RN13	90	10	genótipo/espacamento/ARG/P/K/pH(H2O)/Ca/Mg/SOMADH(8)/vv_med(6)/Adubações(todas)	3000	Rprop+	8	Log-Log	0.89	3.11	0.80	3.96
RN50	90	10	genótipo/espacamento/ARG/AF/AG/SIL/m/V/P/K/pH(H2O)/pH(CaCl2)/CTC/H+Al/Al/Mg/Ca/MO/Prem/DH1DH2DH3DH4DH5DH6DH7DH8/Adubações(todas)	3000	Rprop+	8	Log-Log	0.88	3.27	0.81	3.97
RN101	90	10	genótipo/espacamento/m/ARG/p/k/DH1DH2DH3DH4DH5DH6DH7DH8/adubações(todas)	2000	Rprop+	6	Log-Log	0.87	3.38	0.85	3.98
RN340	90	10	genótipo/espacamento/P/K/V/CTC/P1P2P3P4P5P6P7P8/Tmin_med(6)/adubações(todas)	2000	Rprop+	8	Log-Log	0.83	3.89	0.78	3.98
RN290	90	10	genótipo/espacamento/m/ARG/P/K/DH1DH2DH3DH4DH5DH6DH7/adubações(todas)	3000	Rprop+	6	Log-Log	0.88	3.38	0.75	3.98
RN162	90	10	genótipo/espacamento/análise do solo (todas na camada 0-20 cm)/P1P2P3P4P5P6P7P8/DH1DH2DH3DH4DH5DH6DH7DH8/Tmin_med(6)/Tmax/Tmed/vv_med(6)/rad_med(6)/Etp_med(6)/UR_med(6)/todas adubações	3000	Quick	4	Log-Log	0.88	3.23	0.78	3.99

RN287	90	10	genótipo/espacamento/m/ARG/P/K/DH1DH2DH3DH4DH5DH6DH7	3000	Rprop+	6	Log-Log	0.84	3.74	0.75	3.99
RN106	90	10	genótipo/espacamento/P/K/V/CTC/P1P2P3P4P5P6P7P8/Tmin_med(6)/adubações(todas)	3000	Rprop+	16	Log-Log	0.93	2.44	0.88	4.00
RN252	90	10	genótipo/espacamento/P/K/V/CTC/P1P2P3P4P5P6P7P8/Tmin_med(6)/adubações(todas)	3000	Quick	8	Log-Log	0.90	3.10	0.84	4.01
RN177	90	10	genótipo/espacamento/ARG/AF/AG/SIL/m/V/P/K/pH(H2O)/pH(CaCl2)/CTC/H+Al/Al/Mg/Ca/MO/Prem/DH1DH2DH3DH4DH5DH6DH7DH8/Adubações(todas)	3000	Rprop+	8	Tan-Tan	0.94	2.38	0.81	4.02
RN27	90	10	genótipo/espacamento/ARG/P/K/pH(H2O)/Ca/Mg/P1P2P3P4P5P6P7P8/Tmin_med(6)/Adubações(todas)	3000	Rprop+	8	Log-Log	0.91	2.88	0.80	4.05
RN49	90	10	genótipo/espacamento/ARG/AF/AG/SIL/m/V/P/K/pH(H2O)/pH(CaCl2)/CTC/H+Al/Al/Mg/Ca/MO/Prem/P1P2P3P4P5P6PP8/Tmin_med(6)/Adubações(todas)	3000	Rprop+	7	Log-Log	0.92	2.70	0.76	4.08
RN135	90	10	genótipo/espacamento/P/K/pH(H2O)/Ca/Mg/MO/P1P2P3P4P5P6P7P8/Tmin_med(6)/	3000	Rprop+	6	Log-Log	0.87	3.44	0.75	4.10
RN247	90	10	genótipo/espacamento/P/K/V/CTC/P1P2P3P4P5P6P7P8/Tmin_med(6)/adubações(todas)	2000	Rprop+	8	Log-Log	0.89	3.14	0.82	4.12
RN133	90	10	genótipo/espacamento/P/K/pH(H2O)/Ca/Mg/MO/P1P2P3P4P5P6P7/Tmin_med(6)/adubações	3000	Rprop+	6	Log-Log	0.83	3.80	0.85	4.12
RN192	90	10	genótipo/ARG/AF/AG/SIL/m/V/P/K/pH(H2O)/pH(CaCl2)/CTC/H+Al/Al/Mg/Ca/MO/Prem/DH1DH2DH3DH4DH5DH6DH7DH8/vv_media(6)/Adubações(todas)	3000	Rprop+	8	Log-Log	0.92	2.69	0.83	4.13
RN65	90	10	genótipo/espacamento/P/K/V/ARG/P1P2P3P4P5P6P7P8/Tmin_med(6)/adubações(todas)	3000	Rprop+	8	Log-Log	0.88	3.30	0.81	4.14
RN37	90	10	genótipo/espacamento/V/P/K/H+Al/P1P2P3P4P5P6P7P8/Tmin_med(6)/Adubações(todas)	3000	Rprop+	8	Log-Log	0.91	2.85	0.76	4.14
RN128	90	10	genótipo/espacamento/P/K/pH(H2O)/Ca/Mg/MO/DH1DH2DH3DH4DH5DH6/Adubações(todas)	3000	Rprop+	8	Log-Log	0.91	2.85	0.80	4.15
RN122	90	10	genótipo/espacamento/areia total/P/K/Ca/Mg/DH1DH2DH3DH4DH5DH6DH7DH8/Adubações(todas)	3000	Rprop+	6	Log-Log	0.89	3.18	0.79	4.16
RN18	90	10	genótipo/espacamento/ARG/AF/AG/SIL/m/V/P/K/pH(H2O)/pH(CaCl2)/CTC/H+Al/Al/Mg/Ca/MO/Prem/SOMADH(8)/vv_media(6)/Adubações(todas)	3000	Rprop+	10	Log-Log	0.87	3.39	0.77	4.19
RN179	90	10	genótipo/espacamento/ARG/AF/AG/SIL/m/V/P/K/pH(H2O)/pH(CaCl2)/CTC/H+Al/Al/Mg/Ca/MO/Prem/DH1DH2DH3DH4DH5DH6DH7DH8/Adubações(todas)	3000	Quick	8	Log-Log	0.83	3.87	0.81	4.22
RN335	90	10	genótipo/espacamento/P/K/pH(H2O)/Ca/Mg/MO/DH1DH2DH3DH4DH5DH6DH7DH8/	3000	Rprop+	8	Log-Log	0.88	3.19	0.81	4.22
RN313	90	10	genótipo/espacamento/P/K/V/CTC/P1P2P3P4P5P6P7P8/Tmin_med(6)/	3000	Rprop+	8	Log-Log	0.86	3.56	0.80	4.22
RN157	80	20	genótipo/espacamento/análise do solo (todas na camada 0-20 cm)/P1P2P3P4P5P6P7P8/DH1DH2DH3DH4DH5DH6DH7DH8/Tmin_med(6)/Tmax/Tmed/vv_med(6)/rad_med(6)/Etp_med(6)/UR_med(6)/todas adubações	3000	Rprop+	6	Log-Log	0.87	3.48	0.79	4.22
RN171	80	20	genótipo/espacamento/ARG/AF/AG/SIL/m/V/P/K/pH(H2O)/pH(CaCl2)/CTC/H+Al/Al/Mg/Ca/MO/Prem/DH1DH2DH3DH4DH5DH6DH7DH8/Adubações(todas)	3000	Rprop+	8	Log-Log	0.89	3.29	0.72	4.23
RN76	90	10	genótipo/espacamento/P/K/V/CTC/SOMAP8/Tmin_med(6)/adubações(todas)	3000	Rprop+	8	Log-Log	0.86	3.50	0.84	4.24
RN11	90	10	genótipo/espacamento/ARG/SOMADH(8)	3000	Rprop+	8	Log-Log	0.74	4.70	0.81	4.24
RN96	90	10	genótipo/espacamento/P/K/V/CTC/DH1DH2DH3DH4DH5DH6DH7DH8/adubações(todas)	3000	Rprop+	8	Log-Log	0.91	2.92	0.78	4.24
RN240	90	10	genótipo/P/K/pH(H2O)/Ca/Mg/MO/P1P2P3P4P5P6P7P8/Tmin_med(6)_med/adubações(todas)	3000	Rprop+	8	Log-Log	0.79	4.25	0.77	4.25
RN270	90	10	genótipo/espacamento/m/ARG/P/K/DH1DH2DH3DH4DH5DH6DH7DH8/adubações(todas)	2000	Rprop+	6	Log-Log	0.87	3.42	0.76	4.25
RN248	90	10	genótipo/espacamento/P/K/V/CTC/P1P2P3P4P5P6P7P8/Tmin_med(6)/adubações(todas)	3000	Rprop+	6	Log-Log	0.86	3.60	0.81	4.25
RN341	90	10	genótipo/espacamento/P//m/CTC/SOMADH8/adubações(todas)	3000	Rprop+	8	Log-Log	0.76	4.55	0.79	4.26
RN118	90	10	genótipo/espacamento/m/ARG/P/K/DH1DH2DH3DH4DH5DH6DH7DH8/adubações(todas)	3000	Rprop+	8	log-log	0.87	3.39	0.75	4.27
RN200	90	10	genótipo/espacamento/ARG/P/K/pH(H2O)/Ca/Mg/SOMAP8/Tmax_med(6)/Adubações(todas)	3000	Rprop+	8	Tan-Tan	0.88	3.18	0.83	4.28
RN140	90	10	genótipo/espacamento/m/ARG/P/K/DH1DH2DH3DH4DH5DH6DH7/adubações(todas)	3000	Rprop+	6	Log-Log	0.88	3.33	0.79	4.28
RN2	90	10	genótipo/espacamento/ARG/P/K/pH(H2O)/Ca/Mg/P1P2P3P4P5P6P7P8/Tmin_med(6)/vv_med(6)/Adubações(todas)	3000	Rprop+	8	Log-Log	0.81	4.07	0.76	4.28
RN285	90	10	espacamento/m/ARG/P/K/DH1DH2DH3DH4DH5DH6DH7DH8/adubações(todas)	3000	Rprop+	6	Log-Log	0.85	3.75	0.71	4.28
RN223	90	10	genótipo/espacamento/P/K/pH(H2O)/Ca/Mg/MO/P1P2P3P4P5P6P7P8/Tmin_med(6)_med/adubações(todas)	2000	Rprop+	8	Log-Log	0.89	3.05	0.82	4.29
RN232	90	10	genótipo/espacamento/P/K/pH(H2O)/Ca/Mg/MO/P1P2P3P4P5P6P7P8/Tmin_med(6)_med/adubações(todas)	3000	Quick	8	Log-Log	0.91	2.88	0.80	4.30
RN28	90	10	genótipo/espacamento/ARG/P/K/pH(H2O)/Ca/Mg/P1P2P3P4P5P6P7P8/Tmin_med(6)/Adubações(todas)	3000	Rprop+	10	Log-Log	0.93	2.59	0.77	4.30

RN127	90	10	genótipo/espacamento/P/K/pH(H2O)/Ca/Mg/MO/SOMADH6/adubações(todas)	3000	Rprop+	6	Log-Log	0.86	3.45	0.82	4.31
RN275	90	10	genótipo/espacamento/m/ARG/P/K/DH1DH2DH3DH4DH5DH6DH7DH8/adubações(todas)	3000	Quick	6	Log-Log	0.89	3.15	0.76	4.33
RN129	90	10	genótipo/espacamento/P/K/pH(H2O)/Ca/Mg/MO/DH1DH2DH3DH4DH5DH6/adubações(todas)	2000	Rprop+	8	Log-Log	0.89	3.07	0.83	4.34
RN40	90	10	genótipo/espacamento/V/P/K/H+Al/P1P2P3P4P5P6P7P8/Tmin_med(6)/Adubações(todas)	3000	Rprop+	7	Log-Log	0.89	3.05	0.78	4.34
RN137	90	10	genótipo/espacamento/P/K/pH(H2O)/Ca/Mg/MO/P1P2P3P4P5P6P7P8/Tmin_med(6)/	2000	Rprop+	6	Log-Log	0.87	3.38	0.77	4.34
RN187	90	10	genótipo/espacamento/ARG/AF/AG/SIL/m/V/P/K/pH(H2O)/pH(CaCl2)/CTC/H+Al/Al/Mg/Ca/MO/Prem/DH1DH2DH3DH4DH5DH6DH7DH8/vv_media(6)/Adubações(todas)	3000	Rprop+	8	Tan-Tan	0.93	2.54	0.77	4.35
RN271	90	10	genótipo/espacamento/m/ARG/P/K/DH1DH2DH3DH4DH5DH6DH7DH8/adubações(todas)	3000	Rprop+	4	Log-Log	0.82	4.04	0.75	4.35
RN186	90	10	genótipo/espacamento/ARG/AF/AG/SIL/m/V/P/K/pH(H2O)/pH(CaCl2)/CTC/H+Al/Al/Mg/Ca/MO/Prem/DH1DH2DH3DH4DH5DH6DH7DH8/vv_media(6)/Adubações(todas)	3000	Rprop+	8	Log-Lin	0.75	4.65	0.69	4.35
RN58	90	10	genótipo/espacamento/P/K/pH(H2O)/Ca/Mg/Prem/DH1DH2DH3DH4DH5DH6DH7DH8/adubações(todas)	3000	Rprop+	8	Log-Log	0.87	3.36	0.82	4.36
RN61	90	10	genótipo/espacamento/m/ARG/P/K/P1P2P3P4P5P6P7P8/Tmin_med(6)/adubações(todas)	3000	Rprop+	8	Log-Log	0.90	3.06	0.75	4.37
RN69	90	10	genótipo/espacamento/P/K/V/CTC/DH1DH2DH3DH4DH5DH6DH7DH8/adubações(todas)	3000	Rprop+	8	Log-Log	0.89	3.18	0.82	4.38
RN93	90	10	genótipo/espacamento/m/ARG/p/k/DH1DH2DH3DH4DH5DH6DH7DH8/adubações(todas)	3000	Rprop+	8	Log-Log	0.86	3.53	0.80	4.38
RN100	90	10	genótipo/espacamento/m/ARG/P/K/DH1DH2DH3DH4DH5DH6DH7DH8/adubações(todas)	2000	Rprop+	8	Log-Log	0.89	3.08	0.80	4.38
RN220	90	10	genótipo/análise do solo (todas na camada 0-20 cm)/climáticas (todas as normais)/Adubações(todas)	3000	Rprop+	8	Log-Log	0.90	30.50	0.79	4.38
RN153	90	10	genótipo/espacamento/Análise foliar(todas)/Análise do solo (todas de 0-20 e 20-40 cm)/DH1DH2DH3DH4DH5DH6DH7DH8/Tmin_med(6)/Tmax/Tmed/vv_med(6)/rad_med(6)/Etp_med(6)/UR_med(6)/todas adubações	3000	Rprop+	6	Log-Log	0.92	2.64	0.74	4.38
RN175	90	10	genótipo/espacamento/ARG/AF/AG/SIL/m/V/P/K/pH(H2O)/pH(CaCl2)/CTC/H+Al/Al/Mg/Ca/MO/Prem/DH1DH2DH3DH4DH5DH6DH7DH8/adubações(todas)	3000	Rprop+	6	Log-Log	0.92	2.74	0.80	4.39
RN1	90	10	genótipo/espacamento/P/K/V/CTC/P1P2P3P4P5P6P7P8/Tmin_med(6)/Adubações(todas)	3000	Rprop+	6	Log-Log	0.88	3.38	0.76	4.39
RN88	90	10	genótipo/espacamento/P/K/V/CTC/P_nor/Tmin_nor/adubações(todas)	3000	Rprop+	6	Log-Log	0.81	4.10	0.76	4.39
RN155	90	10	genótipo/espacamento/Análise do solo (todas de 0-20 e 20-40 cm)/P1P2P3P4P5P6P7P8/DH1DH2DH3DH4DH5DH6DH7DH8/Tmin_med(6)/Tmax/Tmed/vv_med(6)/rad_med(6)/Etp_med(6)/UR_med(6)/todas adubações	3000	Rprop+	6	Log-Log	0.87	3.42	0.81	4.40
RN309	90	10	genótipo/m/ARG/P/K/SOMAP8/Tmin_med(6)/adubações(todas)	3000	Rprop+	6	Log-Log	0.79	4.25	0.78	4.40
RN236	90	10	genótipo/espacamento/P/K/pH(H2O)/Ca/Mg/MO/P1P2P3P4P5P6P7P8/Tmin_med(6)_med/adubações(todas)	3000	Rprop+	8	Log-Tan	0.80	4.17	0.78	4.41
RN256	90	10	genótipo/espacamento/P/K/V/CTC/P1P2P3P4P5P6P7P8/Tmin_med(6)/adubações(todas)	3000	Rprop+	8	Log-Tan	0.79	4.28	0.81	4.41
RN261	90	10	genótipo/espacamento/P/K/V/CTC/P1P2P3P4P5P6P7P8/tmed_med(6)/adubações(todas)	3000	Rprop+	8	Log-Log	0.90	2.90	0.80	4.42
RN318	90	10	genótipo/espacamento/P/K/pH(H2O)/Ca/Mg/MO/DH1DH2DH3DH4DH5DH6DH7DH8/adubações(todas)	3000	Rprop+	6	Log-Log	0.88	3.33	0.78	4.42
RN216	90	10	genótipo/espacamento/análise do solo (todas na camada 0-20 cm)/climáticas (todas as normais)/Adubações(todas)	3000	Rprop+	8	Tan-Lin	0.70	5.00	0.73	4.42
RN167	90	10	espacamento/análise do solo (todas na camada 0-20 cm)/P1P2P3P4P5P6P7P8/DH1DH2DH3DH4DH5DH6DH7DH8/Tmin_med(6)/Tmax/Tmed/vv_med(6)/rad_med(6)/Etp_med(6)/UR_med(6)/todas adubações	3000	Rprop+	6	Log-Log	0.88	3.27	0.80	4.43
RN152	90	10	genótipo/espacamento/Análise foliar(todas)/Análise do solo (todas de 0-20 e 20-40 cm)/P1P2P3P4P5P6P7P8/Tmin_med(6)/Tmax/Tmed/vv_med(6)/rad_med(6)/Etp_med(6)/UR_med(6)/todas adubações	3000	Rprop+	6	Log-Log	0.92	2.70	0.79	4.43
RN246	90	10	genótipo/espacamento/P/K/V/CTC/P1P2P3P4P5P6P7P8/Tmin_med(6)/adubações(todas)	5000	Rprop+	8	Log-Log	0.79	4.27	0.80	4.44
RN8	90	10	genótipo/espacamento/ARG/P/K/pH(H2O)/Ca/Mg/SOMAP8/Tmin_med(6)/vv_med(6)/Adubações(todas)	3000	Rprop+	8	Log-Log	0.85	3.69	0.79	4.44
RN43	90	10	genótipo/espacamento/ARG/P/K/pH(H2O)/Ca/Mg/P1P2P3P4P5P6/Tmin_med(6)/Adubações(todas)	3000	Rprop+	6	Log-Log	0.86	3.52	0.79	4.44
RN21	90	10	genótipo/espacamento/ARG/P/K/pHH2O/Ca/Mg/MÉDIADH(6)/Adubações(todas)	3000	Rprop+	8	Log-Log	0.87	3.46	0.81	4.45
RN312	90	10	genótipo/espacamento/SOMAP8/Tmin_med(6)/adubações(todas)	3000	Rprop+	6	Log-Log	0.79	4.27	0.80	4.45
RN193	90	10	ARG/AF/AG/SIL/m/V/P/K/pH(H2O)/pH(CaCl2)/CTC/H+Al/Al/Mg/Ca/MO/Prem/DH1DH2DH3DH4DH5DH6DH7DH8/vv_media(6)/Adubações(todas)	3000	Rprop+	8	Log-Log	0.88	3.33	0.76	4.45
RN97	90	10	genótipo/espacamento/P/K/V/CTC/DH1DH2DH3DH4DH5DH6DH7DH8/adubações(todas)	2000	Rprop+	8	Log-Log	0.89	3.18	0.68	4.46

RN57	90	10	genótipo/espacamento/P/K/pH(H2O)/Ca/Mg/Prem/SOMAP8/adubações(todas)	3000	Rprop+	8	Log-Log	0.89	3.07	0.80	4.47
RN185	90	10	genótipo/espacamento/ARG/AF/AG/SIL/m/V/P/K/pH(H2O)/pH(CaCl2)/CTC/H+Al/Al/Mg/Ca/MO/Prem/DH1DH2DH3DH4DH5DH6DH7DH8/vv_media(6)/Adubações(todas)	3000	Rprop+	6	Log-Log	0.91	2.94	0.73	4.47
RN254	90	10	genótipo/espacamento/P/K/V/CTC/P1P2P3P4P5P6P7P8/Tmin_med(6)/adubações(todas)	3000	Rprop+	10	Log-Log	0.91	2.87	0.80	4.47
RN64	90	10	genótipo/espacamento/P/K/V/CTC/P1P2P3P4P5P6P7P8/Tmin_med(6)/adubações(todas)	3000	Rprop+	6	Log-Log	0.88	3.28	0.77	4.48
RN230	90	10	genótipo/espacamento/P/K/pH(H2O)/Ca/Mg/MO/P1P2P3P4P5P6P7P8/Tmin_med(6)_med/adubações(todas)	3000	Rprop+	8	Tan-Tan	0.90	3.00	0.77	4.48
RN265	90	10	genótipo/espacamento/P/K/V/CTC/P1P2P3P4P5P6P7P8/Tmin_med(6)/	3000	Rprop+	8	Log-Log	0.88	3.27	0.75	4.48
RN26	90	10	genótipo/espacamento/ARG/P/K/pH(H2O)/Ca/Mg/P1P2P3P4P5P6P7P8/Tmax_med(6)/vv_med(6)/Adubações(todas)	3000	Rprop+	8	Log-Log	0.91	2.81	0.75	4.49
RN60	90	10	genótipo/espacamento/P/K/Ca/Mg/Prem/DH1DH2DH3DH4DH5DH6DH7DH8/adubações(todas)	3000	Rprop+	8	Log-Log	0.88	3.33	0.74	4.49
RN229	90	10	genótipo/espacamento/P/K/pH(H2O)/Ca/Mg/MO/P1P2P3P4P5P6P7P8/Tmin_med(6)_med/adubações(todas)	3000	Rprop+	8	Log-Lin	0.73	4.76	0.77	4.50
RN273	90	10	genótipo/espacamento/m/ARG/P/K/DH1DH2DH3DH4DH5DH6DH7DH8/adubações(todas)	3000	Rprop+	6	Tan-Tan	0.88	3.31	0.75	4.50
RN244	90	10	genótipo/espacamento/P1P2P3P4P5P6P7P8/Tmin_med(6)/adubações(todas)	3000	Rprop+	8	Log-Log	0.85	3.64	0.79	4.51
RN324	90	10	genótipo/espacamento/P/K/pH(H2O)/Ca/Mg/MO/DH1DH2DH3DH4DH5DH6DH7DH8/adubações(todas)	3000	Rprop+	10	Log-Log	0.90	3.00	0.77	4.51
RN131	90	10	genótipo/espacamento/P/K/pH(H2O)/Ca/Mg/MO/P1P2P3P4P5P6P7P8	3000	Rprop+	8	Log-Log	0.85	3.67	0.80	4.52
RN333	90	10	genótipo/P/K/pH(H2O)/Ca/Mg/MO/DH1DH2DH3DH4DH5DH6DH7DH8/adubações(todas)	3000	Rprop+	8	Log-Log	0.88	3.27	0.80	4.52
RN169	90	10	genótipo/análise do solo (todas na camada 0-20 cm)/P1P2P3P4P5P6P7P8/DH1DH2DH3DH4DH5DH6DH7DH8/Tmin_med(6)/Tmax/Tmed/vv_med(6)/rad_med(6)/Etp_med(6)/UR_med(6)/todas adubações	3000	Rprop+	4	Log-Log	0.88	3.27	0.79	4.52
RN38	90	10	genótipo/espacamento/P/K/V/CTC/P1P2P3P4P5P6P7P8/Tmin_med(6)/adubações(todas)	3000	Rprop+	8	Tan-Tan	0.92	2.75	0.77	4.52
RN202	90	10	genótipo/espacamento/ARG/P/K/pH(H2O)/Ca/Mg/SOMAP8/Tmax_med(6)/Adubações(todas)	3000	Quick	8	Log-Log	0.89	3.07	0.76	4.52
RN136	90	10	genótipo/espacamento/P/K/pH(H2O)/Ca/Mg/MO/P1P2P3P4P5P6P7P8/Tmin_med(6)/	3000	Rprop+	4	Log-Log	0.84	3.80	0.73	4.54
RN339	90	10	genótipo/espacamento/P/K/V/CTC/P1P2P3P4P5P6P7P8/Tmin_med(6)/adubações(todas)	5000	Rprop+	8	Log-Log	0.92	2.72	0.77	4.55
RN286	90	10	genótipo/m/ARG/P/K/DH1DH2DH3DH4DH5DH6DH7DH8/adubações(todas)	3000	Rprop+	6	Log-Log	0.86	3.56	0.76	4.55
RN3	90	10	genótipo/espacamento/ARG/P/K/pH(H2O)/Ca/Mg/DH1DH2DH3DH4DH5DH6DH7DH8/vv_med(6)/Adubações(todas)	3000	Rprop+	8	Log-Log	0.90	2.98	0.78	4.56
RN284	90	10	genótipo/espacamento/m/ARG/P/K/DH1DH2DH3DH4DH5DH6/adubações(todas)	3000	Rprop+	6	Log-Log	0.82	3.99	0.68	4.56
RN228	90	10	genótipo/espacamento/P/K/pH(H2O)/Ca/Mg/MO/P1P2P3P4P5P6P7P8/Tmin_med(6)_med/adubações(todas)	3000	Rprop+	6	Log-Log	0.88	3.25	0.75	4.57
RN75	90	10	genótipo/espacamento/P/K/V/CTC/P1P2P3P4P5P6P7P8/Tmin_med(6)/adubações(todas)	3000	Rprop+	8	Log-Tan	0.81	4.09	0.72	4.57
RN105	90	10	genótipo/espacamento/m/ARG/P/K/DH1DH2DH3DH4DH5DH6DH7DH8/adubações(todas)	3000	Rprop+	5	Log-Log	0.85	3.64	0.80	4.58
RN289	90	10	genótipo/espacamento/DH1DH2DH3DH4DH5DH6DH7DH8/adubações(todas)	3000	Rprop+	6	Log-Log	0.84	3.71	0.78	4.58
RN92	90	10	genótipo/espacamento/m/ARG/P/K/DH1DH2DH3DH4DH5DH6DH7DH8/adubações(todas)	3000	Rprop+	6	Log-Log	0.90	3.00	0.77	4.59
RN55	90	10	genótipo/espacamento/areia_total/P/K/pH(H2O)/Ca/Mg/SOMADH8/adubações(todas)	3000	Rprop+	8	Log-Log	0.88	4.28	0.81	4.60
RN221	90	10	análise do solo (todas na camada 0-20 cm)/climáticas (todas as normais)/Adubações(todas)	3000	Rprop+	8	Log-Log	0.84	3.80	0.69	4.60
RN331	90	10	genótipo/espacamento/P/K/pH(H2O)/Ca/Mg/MO/DH1DH2DH3DH4DH5DH6/adubações(todas)	3000	Rprop+	8	Log-Log	0.90	2.94	0.78	4.61
RN112	90	10	genótipo/espacamento/m/ARG/P/K/DH1DH2DH3DH4DH5DH6DH7DH8/adubações(todas)	3000	Rprop+	4	Tan-Tan	0.86	3.59	0.74	4.61
RN308	90	10	espacamento/m/ARG/P/K/SOMAP8/Tmin_med(6)/adubações(todas)	3000	Rprop+	6	Log-Log	0.77	4.50	0.69	4.62
RN10	90	10	genótipo/espacamento/ARG/SOMADH(6)	3000	Rprop+	8	Log-Log	0.77	4.39	0.73	4.64
RN188	90	10	genótipo/espacamento/ARG/AF/AG/SIL/m/V/P/K/pH(H2O)/pH(CaCl2)/CTC/H+Al/Al/Mg/Ca/MO/Prem/DH1DH2DH3DH4DH5DH6DH7DH8/vv_media(6)/Adubações(todas)	3000	Rprop+	8	Tan-Lin	0.74	4.72	0.63	4.64
RN249	90	10	genótipo/espacamento/P/K/V/CTC/P1P2P3P4P5P6P7P8/Tmin_med(6)/adubações(todas)	3000	Rprop+	8	Log-Lin	0.72	4.85	0.77	4.65
RN119	90	10	genótipo/espacamento/m/ARG/P/K/DH1DH2DH3DH4DH5DH6DH7DH8/adubações(todas)	3000	Rprop+	6	log-log	0.87	3.42	0.77	4.65
RN231	90	10	genótipo/espacamento/P/K/pH(H2O)/Ca/Mg/MO/P1P2P3P4P5P6P7P8/Tmin_med(6)_med/adubações(todas)	3000	Rprop+	8	Tan-Lin	0.73	4.73	0.76	4.65
RN243	90	10	genótipo/espacamento/P/K/pH(H2O)/Ca/Mg/MO/adubações(todas)	3000	Rprop+	8	Log-Log	0.85	3.66	0.75	4.65
RN322	90	10	genótipo/espacamento/P/K/pH(H2O)/Ca/Mg/MO/DH1DH2DH3DH4DH5DH6DH7DH8/adubações(todas)	3000	Quick	8	Log-Log	0.90	2.94	0.73	4.68

RN316	90	10	genótipo/espacamento/P/K/pH(H2O)/Ca/Mg/MO/DH1DH2DH3DH4DH5DH6DH7DH8/adubações(todas)	5000	Rprop+	8	Log-Log	0.85	3.64	0.72	4.68
RN219	90	10	espacamento/análise do solo (todas na camada 0-20 cm)/climáticas (todas as normais)/Adubação(todas)	3000	Rprop+	8	Log-Log	0.87	3.41	0.79	4.69
RN109	90	10	genótipo/espacamento/P/K/V/CTC/P1P2P3P4P5P6P7P8/Tmin_med(6)/adubações(todas)	3000	Rprop+	6	Tan-Tan	0.89	3.08	0.78	4.69
RN79	90	10	genótipo/espacamento/P/K/V/ARG/SOMADH8/adubações(todas)	3000	Rprop+	8	Log-Log	0.77	4.37	0.77	4.70
RN170	90	10	genótipo/espacamento/ARG/AF/AG/SIL/m/V/P/K/pH(H2O)/pH(CaCl2)/CTC/H+Al/Al/Mg/Ca/MO/Prem/DH1DH2DH3DH4DH5DH6DH7DH8/Adubações(todas)	3000	Rprop+	8	Log-Log	0.91	2.73	0.80	4.71
RN72	90	10	genótipo/espacamento/P/K/V/CTC/DH1DH2DH3DH4DH5DH6DH7DH8/adubações(todas)	3000	Rprop+	8	Log-Log	0.82	3.92	0.79	4.71
RN141	90	10	genótipo/espacamento/ARG/pH(H2O)/P/K/Ca/Mg/climáticas (todas as normais exceto Tmed)	3000	Rprop+	6	Log-Log	0.80	4.16	0.69	4.72
RN154	90	10	genótipo/espacamento/Análise foliar(todas)/Análise do solo (todas de 0-20 e 20-40 cm)/DH1DH2DH3DH4DH5DH6DH7DH8/Tmin_med(6)/Tmax/Tmed/vv_med(6)/rad_med(6)/Etp_med(6)/UR_med(6)/todas adubações	3000	Rprop+	4	Log-Log	0.88	3.24	0.78	4.73
RN145	80	20	genótipo/espacamento/Análise foliar(todas)/Análise do solo (todas de 0-20 e 20-40 cm)/P1P2P3P4P5P6P7P8/DH1DH2DH3DH4DH5DH6DH7DH8/Tmin_med(6)/Tmax/Tmed/vv_med(6)/rad_med(6)/Etp_med(6)/UR_med(6)/todas adubações	3000	Rprop+	6	Log-Log	0.93	2.47	0.72	4.73
RN189	90	10	genótipo/espacamento/ARG/AF/AG/SIL/m/V/P/K/pH(H2O)/pH(CaCl2)/CTC/H+Al/Al/Mg/Ca/MO/Prem/DH1DH2DH3DH4DH5DH6DH7DH8/vv_med(6)/adubações(todas)	3000	Quick	8	Log-Log	0.94	2.36	0.80	4.74
RN48	90	10	genótipo/espacamento/P/K/V/CTC/P1P2P3P4P5P6P7P8/Tmin_med(6)/adubações(todas)	3000	Quick	8	Log-Log	0.90	2.96	0.74	4.74
RN206	90	10	ARG/P/K/pH(H2O)/Ca/Mg/SOMAP8/Tmax_med(6)/Adubações(todas)	3000	Rprop+	8	Log-Log	0.81	4.06	0.74	4.74
RN251	90	10	genótipo/espacamento/P/K/V/CTC/P1P2P3P4P5P6P7P8/Tmin_med(6)/adubações(todas)	3000	Rprop+	8	Tan-Lin	0.72	4.86	0.76	4.74
RN269	90	10	genótipo/espacamento/m/ARG/P/K/DH1DH2DH3DH4DH5DH6DH7DH8/adubações(todas)	5000	Rprop+	6	Log-Log	0.89	3.12	0.73	4.75
RN73	90	10	genótipo/espacamento/m/ARG/P/K/SOMAP8/Tmin_med(6)/adubações(todas)	3000	Rprop+	8	Log-Log	0.87	3.39	0.71	4.75
RN160	90	10	genótipo/espacamento/análise do solo (todas na camada 0-20 cm)/P1P2P3P4P5P6P7P8/DH1DH2DH3DH4DH5DH6DH7DH8/Tmin_med(6)/Tmax/Tmed/vv_med(6)/rad_med(6)/Etp_med(6)/UR_med(6)/todas adubações	3000	Quick	6	Log-Log	0.91	2.84	0.77	4.76
RN317	90	10	genótipo/espacamento/P/K/pH(H2O)/Ca/Mg/MO/DH1DH2DH3DH4DH5DH6DH7DH8/adubações(todas)	2000	Rprop+	8	Log-Log	0.90	2.96	0.74	4.76
RN288	90	10	genótipo/espacamento/m/ARG/P/K/adubações(todas)	3000	Rprop+	6	Log-Log	0.80	4.23	0.69	4.76
RN253	90	10	genótipo/espacamento/P/K/V/CTC/P1P2P3P4P5P6P7P8/Tmin_med(6)/adubações(todas)	3000	Back	8	Log-Log	0.80	4.39	0.76	4.79
RN139	90	10	genótipo/espacamento/m/ARG/P/K/DH1DH2DH3DH4DH5DH6DH7DH8	3000	Rprop+	6	Log-Log	0.84	3.68	0.80	4.80
RN163	90	10	genótipo/espacamento/análise do solo (todas na camada 0-20 cm)/P1P2P3P4P5P6P7P8/DH1DH2DH3DH4DH5DH6DH7DH8/Tmin_med(6)/Tmax/Tmed/vv_med(6)/rad_med(6)/Etp_med(6)/UR_med(6)/todas adubações	3000	Rprop+	6	Log-Lin	0.77	4.48	0.81	4.81
RN19	90	10	genótipo/espacamento/ARG/P/K/pH(H2O)/Al/Mg/Ca/MO/SOMADH(8)/Adubações(todas)	3000	Rprop+	10	Log-Log	0.90	2.93	0.72	4.83
RN201	90	10	genótipo/espacamento/ARG/P/K/pH(H2O)/Ca/Mg/SOMAP8/Tmax_med(6)/Adubações(todas)	3000	Rprop+	8	Tan-Lin	0.63	5.39	0.73	4.84
RN47	90	10	genótipo/espacamento/P/K/V/CTC/P1P2P3P4P5P6P7P8/Tmin_med(6)/adubações(todas)	3000	Rprop+	8	Tan-Lin	0.74	4.71	0.69	4.84
RN7	90	10	genótipo/espacamento/ARG/P/K/pH(H2O)/Ca/Mg/P1P2P3P4P5P6P7P8/Tmin_med(6)/vv_med(6)/Adubações(todas)	3000	Rprop+	5	Log-Log	0.88	3.33	0.66	4.84
RN86	90	10	genótipo/espacamento/P/K/V/CTC/P_nor/Tmin_nor/adubações(todas)	3000	Rprop+	8	Log-Log	0.88	3.32	0.75	4.85
RN143	90	10	genótipo/espacamento/Análise foliar(todas)/Análise do solo (todas de 0-20 e 20-40 cm)/P1P2P3P4P5P6P7P8/DH1DH2DH3DH4DH5DH6DH7DH8/Tmin_med(6)/Tmax/Tmed/vv_med(6)/rad_med(6)/Etp_med(6)/UR_med(6)/todas adubações	3000	Rprop+	45	Log-Log	0.98	1.15	0.75	4.85
RN103	85	15	genótipo/espacamento/m/ARG/P/K/DH1DH2DH3DH4DH5DH6DH7DH8/adubações(todas)	3000	Rprop+	6	Log-Log	0.88	3.23	0.75	4.86
RN161	90	10	genótipo/espacamento/análise do solo (todas na camada 0-20 cm)/P1P2P3P4P5P6P7P8/DH1DH2DH3DH4DH5DH6DH7DH8/Tmin_med(6)/Tmax/Tmed/vv_med(6)/rad_med(6)/Etp_med(6)/UR_med(6)/todas adubações	3000	Back	6	Log-Log	0.81	4.24	0.63	4.86
RN54	90	10	genótipo/espacamento/p/k/pH(H2O)/ca/mg/mo/DH1DH2DH3DH4DH5DH6DH7DH8/adubações(todas)	3000	Rprop+	8	Log-Log	0.90	3.06	0.76	4.87

RN321	90	10	genótipo/espacamento/P/K/pH(H2O)/Ca/Mg/MO/DH1DH2DH3DH4DH5DH6DH7DH8/adubações(todas)	3000	Rprop+	8	Tan-Lin	0.70	4.97	0.72	4.87
RN213	90	10	genótipo/espacamento/análise do solo (todas na camada 0-20 cm)/climáticas (todas as normais)/Adubação(todas)	3000	Rprop+	6	Log-Log	0.80	4.24	0.71	4.87
RN117	90	10	genótipo/espacamento/m/ARG/P/K/DH1DH2DH3DH4DH5DH6DH7DH8/adubações(todas)	3000	Rprop+	14	Log-Lin	0.73	4.76	0.69	4.87
RN276	90	10	genótipo/espacamento/m/ARG/P/K/DH1DH2DH3DH4DH5DH6DH7DH8/adubações(todas)	3000	Back	6	Log-Log	0.79	4.40	0.66	4.87
RN33	90	10	genótipo/espacamento/ARG/P/K/pH(H2O)/Ca/Mg/P7/P8/Tmin_med(6)/Adubações todas	3000	Rprop+	8	Log-Log	0.81	4.09	0.70	4.88
RN51	90	10	genótipo/espacamento/areia_total/P/K/pH(H2O)/ca/mg/SOMAP8/Tmin_med(6)/adubações(todas)	3000	Rprop+	8	Log-Log	0.90	3.02	0.77	4.89
RN87	90	10	genótipo/espacamento/m/ARG/P/K/DH_nor/adubações(todas)	3000	Rprop+	8	Log-Log	0.87	3.35	0.76	4.89
RN111	90	10	genótipo/espacamento/m/ARG/P/K/DH1DH2DH3DH4DH5DH6DH7DH8/adubações(todas)	3000	Rprop+	6	Tan-Tan	0.90	2.99	0.76	4.89
RN125	90	10	genótipo/espacamento/ARG/Ca/Mg/Ph(H2O)/P/K/SOMADH8/adubações(total)	3000	Rprop+	8	Log-Log	0.90	3.05	0.78	4.92
RN107	90	10	genótipo/espacamento/m/ARG/p/k/DH1DH2DH3DH4DH5DH6DH7DH8/adubações(todas)	3000	Rprop+	16	Log-Log	0.93	2.50	0.69	4.92
RN343	90	10	genótipo/espacamento/P/K/V/CTC/DH1DH2DH3DH4DH5DH6DH7DH8/adubações(todas)	3000	Rprop+	8	Log-Log	0.89	3.19	0.68	4.92
RN302	90	10	genótipo/espacamento/m/ARG/P/K/SOMAP8/Tmin_med(6)/adubações(todas)	3000	Rprop+	6	Log-Tan	0.80	nc	0.67	4.92
RN242	90	10	genótipo/espacamento/P/K/pH(H2O)/Ca/Mg/MO/P1P2P3P4P5P6P7P8/Tmin_med(6)	3000	Rprop+	8	Log-Log	0.90	3.02	0.76	4.93
RN63	90	10	genótipo/espacamento/P/K/V/CTC/MÉDIAP8/Tmin_med(6)/adubações(todas)	3000	Rprop+	8	Log-Log	0.90	2.99	0.75	4.93
RN257	80	20	genótipo/espacamento/P/K/V/CTC/P1P2P3P4P5P6P7P8/Tmin_med(6)/adubações(todas)	3000	Rprop+	8	Log-Log	0.88	3.27	0.73	4.93
RN23	90	10	genótipo/espacamento/P/K/V/CTC/P1P2P3P4P5P6P7P8/Tmin_med(6)/adubações(todas)	3000	Rprop+	8	Log-Lin	0.74	4.74	0.66	4.93
RN234	90	10	genótipo/espacamento/P/K/pH(H2O)/Ca/Mg/MO/P1P2P3P4P5P6P7P8/Tmin_med(6)_med/adubações(todas)	3000	Rprop+	16	Log-Log	0.92	2.59	0.74	4.94
RN30	90	10	genótipo/espacamento/ARG/P/K/pH(H2O)/Ca/Mg/SOMAP8/Tmin_med(6)/Adubações(todas)	3000	Rprop+	8	Log-Log	0.88	3.25	0.78	4.95
RN77	90	10	genótipo/espacamento/m/ARG/P/K/SOMADH8/adubações(todas)	3000	Rprop+	6	Log-Log	0.84	3.76	0.75	4.95
RN90	90	10	genótipo/espacamento/MO/Al/CTC/SOMAP8/Tmin_med(6)/adubações(todas)	3000	Rprop+	8	Log-Log	0.85	3.61	0.75	4.95
RN110	90	10	genótipo/espacamento/P/K/V/CTC/P1P2P3P4P5P6P7P8/Tmin_med(6)/adubações(todas)	2000	Rprop+	5	Tan-Tan	0.88	3.31	0.72	4.95
RN191	90	10	espacamento/ARG/AF/AG/SIL/m/V/P/K/pH(H2O)/pH(CaCl2)/CTC/H+Al/Al/Mg/Ca/MO/Prem/ DH1DH2DH3DH4DH5DH6DH7DH8/vv_media(6)/Adubações(todas)	3000	Rprop+	8	Log-Log	0.88	3.23	0.66	4.95
RN205	90	10	genótipo/ARG/P/K/pH(H2O)/Ca/Mg/SOMAP8/Tmax_med(6)/Adubações(todas)	3000	Rprop+	8	Log-Log	0.82	3.90	0.77	4.96
RN310	90	10	genótipo/espacamento/m/ARG/P/K/SOMAP8/Tmin_med(6)/	3000	Rprop+	6	Log-Log	0.81	4.07	0.69	4.96
RN62	90	10	genótipo/espacamento/P/K/V/CTC/P1P2P3P4P5P6P7P8/Tmin_med(6)/adubações(todas)	3000	Back	8	Log-Log	0.79	4.45	0.68	4.96
RN178	90	10	genótipo/espacamento/ARG/AF/AG/SIL/m/V/P/K/pH(H2O)/pH(CaCl2)/CTC/H+Al/Al/Mg/Ca/MO/Prem/ DH1DH2DH3DH4DH5DH6DH7DH8/Adubações(todas)	3000	Rprop+	8	Tan-Lin	0.77	4.48	0.68	4.96
RN39	90	10	genótipo/espacamento/ARG/AF/AG/SIL/m/V/P/K/pH(H2O)/pH(CaCl2)/CTC/H+Al/Al/Mg/Ca/MO/Prem/Ca,P,pHCaCl2 (20-40)/ somaP8/Tmin_med(6)/Tmax_med(6)/vv_med(6)/rad_med(6)/ur_med(6)/somaDH8/Adubações(todas)	3000	Rprop+	8	Log-Log	0.93	2.57	0.71	4.97
RN67	90	10	genótipo/espacamento/P/K/V/CTC/P1P2P3P4P5P6P7P8/Tmin_med(6)/adubações(todas)	3000	Rprop+	10	Log-Log	0.89	3.20	0.71	4.97
RN94	80	20	genótipo/espacamento/areia total/P/K/Ca/Mg/DH1DH2DH3DH4DH5DH6DH7DH8/Adubações(todas)	3000	Rprop+	8	Log-Log	0.88	3.18	0.77	4.98
RN102	85	15	genótipo/espacamento/P/K/V/CTC/P1P2P3P4P5P6P7P8/Tmin_med(6)/adubações(todas)	3000	Rprop+	8	Log-Log	0.91	2.78	0.75	4.98
RN208	90	10	genótipo/espacamento/análise do solo (todas na camada 0-20 cm)/climáticas (todas as normais)/Adubação(todas)	2000	Rprop+	8	Log-Log	0.84	3.78	0.69	4.98
RN222	90	10	genótipo/P/K/V/CTC/P1P2P3P4P5P6P7P8/Tmin_med(6)/adubações(todas)	3000	Rprop+	8	Log-Log	0.88	3.23	0.69	4.98
RN328	70	30	genótipo/espacamento/P/K/pH(H2O)/Ca/Mg/MO/DH1DH2DH3DH4DH5DH6DH7DH8/adubações(todas)	3000	Rprop+	8	Log-Log	0.91	2.80	0.76	4.99
RN342	90	10	genótipo/espacamento/P/K/pH(H2O)/Ca/Mg/MO/P1P2P3P4P5P6P7P8/Tmin_med(6)/adubações(todas)	3000	Rprop+	8	Tan-Tan	0.91	2.78	0.71	4.99
RN35	90	10	genótipo/espacamento/ARG/P/K/pH(H2O)/Ca/Mg/P6/P7/P8/Tmin_med(6)/Adubações todas	3000	Rprop+	8	Log-Log	0.90	3.91	0.77	5.00
RN264	90	10	P/K/V/CTC/P1P2P3P4P5P6P7P8/Tmin_med(6)/adubações(todas)	3000	Rprop+	8	Log-Log	0.81	4.00	0.70	5.00
RN210	70	30	genótipo/espacamento/análise do solo (todas na camada 0-20 cm)/climáticas (todas as normais)/Adubação(todas)	3000	Rprop+	8	Log-Log	0.70	5.10	0.67	5.01
RN214	90	10	genótipo/espacamento/análise do solo (todas na camada 0-20 cm)/climáticas (todas as normais)/Adubação(todas)	3000	Rprop+	8	Log-Lin	0.72	4.97	0.53	5.01
RN25	90	10	genótipo/espacamento/ARG/P/K/pH(H2O)/Ca/Mg/SOMAP(6)/Tmin_med(6)/vv_med(6)/Adubações(todas)	3000	Rprop+	10	Log-Log	0.89	3.16	0.74	5.02

RN150	90	10	genótipo/espacamento/Análise foliar(todas)/Análise do solo (todas de 0-20 e 20-40 cm)/climáticas (todas as normais)/todas adubações	2000	Rprop+	5	Log-Log	0.88	2.29	0.74	5.02
RN314	90	10	genótipo/espacamento/P/K/v/ctc/adubações(todas)	3000	Rprop+	8	Log-Log	0.86	3.61	0.60	5.02
RN233	90	10	genótipo/espacamento/P/K/pH(H2O)/Ca/Mg/MO/P1P2P3P4P5P6P7P8/Tmin_med(6)_med/adubações(todas)	3000	Back	8	Log-Log	0.80	4.39	0.75	5.04
RN238	90	10	genótipo/espacamento/P/K/pH(H2O)/Ca/Mg/MO/pnormal/Tmin_nor/adubações(todas)	3000	Rprop+	8	Log-Log	0.88	3.29	0.75	5.04
RN282	60	40	genótipo/espacamento/m/ARG/P/K/DH1DH2DH3DH4DH5DH6DH7DH8/adubações(todas)	3000	Rprop+	6	Log-Log	0.83	3.91	0.71	5.04
RN41	90	10	genótipo/espacamento/ARG/P/K/pH(H2O)/Ca/Mg/Ca(40)/P(40)/pH(CaCl2)(40)/SOMAP8/Tmin_med(6)/Adubações todas	3000	Rprop+	8	Log-Log	0.89	3.10	0.70	5.04
RN172	70	30	genótipo/espacamento/ARG/AF/AG/SIL/m/V/P/K/pH(H2O)/pH(CaCl2)/CTC/H+Al/Al/Mg/Ca/MO/Prem/DH1DH2DH3DH4DH5DH6DH7DH8/Adubações(todas)	3000	Rprop+	8	Log-Log	0.94	2.41	0.71	5.05
RN319	90	10	genótipo/espacamento/P/K/pH(H2O)/Ca/Mg/MO/DH1DH2DH3DH4DH5DH6DH7DH8/adubações(todas)	3000	Rprop+	8	Log-Lin	0.76	4.54	0.70	5.05
RN338	90	10	genótipo/espacamento/P/K/V/CTC/P1P2P3P4P5P6/Tmin_med(6)/adubações(todas)	3000	Rprop+	8	Log-Log	0.91	2.87	0.70	5.05
RN113	90	10	genótipo/espacamento/m/ARG/P/K/DH1DH2DH3DH4DH5DH6DH7DH8/adubações(todas)	3000	Rprop+	6	Tan-Lin	0.74	4.76	0.59	5.05
RN164	90	10	genótipo/espacamento/análise do solo (todas na camada 0-20 cm)/P1P2P3P4P5P6P7P8/DH1DH2DH3DH4DH5DH6DH7DH8/Tmin_med(6)/Tmax/Tmed/vv_med(6)/rad_med(6)/Etp_med(6)/UR_med(6)/todas adubações	3000	Rprop+	6	Tan-tan	0.92	2.68	0.77	5.07
RN280	80	20	genótipo/espacamento/m/ARG/P/K/DH1DH2DH3DH4DH5DH6DH7DH8/adubações(todas)	3000	Rprop+	6	Log-Log	0.88	3.18	0.73	5.07
RN17	90	10	genótipo/espacamento/ARG/AF/AG/SIL/m/V/P/K/pH(H2O)/pH(CaCl2)/CTC/H+Al/Al/Mg/Ca/MO/Prem/SOMADH8/vv_med(6)/Adubações(todas)	3000	Rprop+	8	Log-Log	0.90	3.03	0.74	5.08
RN329	60	40	genótipo/espacamento/P/K/pH(H2O)/Ca/Mg/MO/DH1DH2DH3DH4DH5DH6DH7DH8/adubações(todas)	3000	Rprop+	8	Log-Log	0.90	3.08	0.71	5.08
RN168	90	10	genótipo/análise do solo (todas na camada 0-20 cm)/P1P2P3P4P5P6P7P8/DH1DH2DH3DH4DH5DH6DH7DH8/Tmin_med(6)/Tmax/Tmed/vv_med(6)/rad_med(6)/Etp_med(6)/UR_med(6)/todas adubações	3000	Rprop+	6	Log-Log	0.90	3.03	0.74	5.09
RN326	90	10	genótipo/espacamento/P/K/pH(H2O)/Ca/Mg/MO/DH1DH2DH3DH4DH5DH6DH7DH8/adubações(todas)	3000	Rprop+	8	Log-Tan	0.74	4.65	0.71	5.09
RN36	90	10	genótipo/espacamento/ARG/P/K/pH(H2O)/Ca/Mg/SOMAP8/Tmin_med(6)/Adubações(todas)	10000	Rprop+	8	Log-Log	0.89	3.20	0.72	5.10
RN166	90	10	genótipo/espacamento/análise do solo (todas na camada 0-20 cm)/P1P2P3P4P5P6P7P8/DH1DH2DH3DH4DH5DH6DH7DH8/Tmin_med(6)/Tmax/Tmed/vv_med(6)/rad_med(6)/Etp_med(6)/UR_med(6)/todas adubações	3000	Rprop+	6	Tan-Lin	0.77	4.43	0.71	5.10
RN146	70	30	genótipo/espacamento/Análise foliar(todas)/Análise do solo (todas de 0-20 e 20-40 cm)/P1P2P3P4P5P6P7P8/DH1DH2DH3DH4DH5DH6DH7DH8/Tmin_med(6)/Tmax/Tmed/vv_med(6)/rad_med(6)/Etp_med(6)/UR_med(6)/todas adubações	3000	Rprop+	6	Log-Log	0.85	3.55	0.72	5.11
RN121	80	20	genótipo/espacamento/P/K/V/CTC/P1P2P3P4P5P6P7P8/Tmin_med(6)/adubações(todas)	3000	Rprop+	8	Log-Log	0.89	3.21	0.71	5.12
RN158	90	10	genótipo/espacamento/análise do solo (todas na camada 0-20 cm)/P1P2P3P4P5P6P7P8/DH1DH2DH3DH4DH5DH6DH7DH8/Tmin_med(6)/Tmax/Tmed/vv_med(6)/rad_med(6)/Etp_med(6)/UR_med(6)/todas adubações	3000	Rprop+	12	Log-Log	0.96	1.93	0.72	5.14
RN258	70	30	genótipo/espacamento/P/K/V/CTC/P1P2P3P4P5P6P7P8/Tmin_med(6)/adubações(todas)	3000	Rprop+	8	Log-Log	0.87	3.35	0.72	5.14
RN323	90	10	genótipo/espacamento/P/K/pH(H2O)/Ca/Mg/MO/DH1DH2DH3DH4DH5DH6DH7DH8/adubações(todas)	3000	Back	8	Log-Log	0.76	4.62	0.66	5.15
RN277	90	10	genótipo/espacamento/m/ARG/P/K/DH1DH2DH3DH4DH5DH6DH7DH8/adubações(todas)	3000	Rprop+	8	Log-Log	0.79	4.50	0.67	5.16
RN132	90	10	genótipo/espacamento/P/K/pH(H2O)/Ca/Mg/MO/P1P2P3P4P5P6P7/adubações	3000	Rprop+	8	Log-Log	0.89	3.16	0.72	5.17
RN267	90	10	genótipo/espacamento/P1P2P3P4P5P6P7P8/Tmin_med(6)/adubações(todas)	3000	Rprop+	8	Log-Log	0.86	3.48	0.70	5.17
RN15	90	10	genótipo/espacamento/ARG/AF/AG/SIL/m/V/P/K/pH(H2O)/pH(CaCl2)/CTC/H+Al/Al/Mg/Ca/MO/Prem/P1P2P3P4P5P6P7P8/Tmin_med(6)/vv_med(6)/Adubações(todas)	3000	Rprop+	8	Log-Log	0.92	2.57	0.76	5.18
RN78	90	10	genótipo/espacamento/m/ARG/P/K/SOMADH8/adubações(todas)	3000	Rprop+	5	Log-Log	0.81	3.98	0.72	5.18
RN332	90	10	espacamento/P/K/pH(H2O)/Ca/Mg/MO/DH1DH2DH3DH4DH5DH6DH7DH8/adubações(todas)	3000	Rprop+	8	Log-Log	0.81	4.06	0.68	5.18
RN115	90	10	genótipo/espacamento/m/ARG/P/K/DH1DH2DH3DH4DH5DH6DH7DH8/adubações(todas)	3000	Rprop+	6	Log-Lin	0.71	4.94	0.65	5.18

RN274	90	10	genótipo/espacamento/m/ARG/P/K/DH1DH2DH3DH4DH5DH6DH7DH8/adubações(todas)	3000	Rprop+	6	Tan-Lin	0.68	5.19	0.58	5.18
RN281	70	30	genótipo/espacamento/m/ARG/P/K/DH1DH2DH3DH4DH5DH6DH7DH8/adubações(todas)	3000	Rprop+	6	Log-Log	0.86	3.41	0.72	5.19
RN304	70	30	genótipo/espacamento/m/ARG/P/K/SOMAP8/Tmin_med(6)/adubações(todas)	3000	Rprop+	6	Log-Log	0.85	nc	0.69	5.19
RN149	90	10	genótipo/espacamento/Análise foliar(todas)/Análise do solo (todas de 0-20 e 20-40 cm)/climáticas (todas as normais)/todas adubações	3000	Rprop+	6	Log-Log	0.90	3.02	0.68	5.19
RN194	80	20	genótipo/espacamento/ARG/P/K/pH(H2O)/Ca/Mg/SOMAP8/Tmax_med(6)/Adubações(todas)	3000	Rprop+	8	Log-Log	0.88	3.20	0.66	5.19
RN336	90	10	genótipo/espacamento/P/K/pH(H2O)/Ca/Mg/MO/adubações(todas)	3000	Rprop+	8	Log-Log	0.86	3.50	0.61	5.19
RN52	90	10	genótipo/espacamento/areia_total/P/K/Ca/Mg/SOMAP8/Tmin_med(6)/adubações(todas)	3000	Rprop+	7	Log-Log	0.86	3.47	0.71	5.20
RN204	90	10	espacamento/ARG/P/K/pH(H2O)/Ca/Mg/SOMAP8/Tmax_med(6)/Adubações(todas)	3000	Rprop+	8	Log-Log	0.79	4.23	0.66	5.20
RN56	90	10	genótipo/espacamento/P/K/pH(H2O)/Ca/Mg/Prem/P1P2P3P4P5P6P7P8/adubações(todas)	3000	Rprop+	8	Log-Log	0.88	3.20	0.77	5.22
RN296	90	10	genótipo/espacamento/m/ARG/P/K/SOMAP8/Tmin_med(6)/adubações(todas)	3000	Rprop+	6	Tan-Tan	0.85	3.66	0.64	5.22
RN147	60	40	genótipo/espacamento/Análise foliar(todas)/Análise do solo (todas de 0-20 e 20-40 cm)/P1P2P3P4P5P6P7P8/DH1DH2DH3DH4DH5DH6DH7DH8/Tmin_med(6)/Tmax/Tmed/vv_med(6)/rad_med(6)/Etp_med(6)/UR_med(6)/todas adubações	3000	Rprop+	6	Log-Log	0.72	4.59	0.72	5.23
RN224	80	20	genótipo/espacamento/P/K/pH(H2O)/Ca/Mg/MO/P1P2P3P4P5P6P7P8/Tmin_med(6)_med/adubações(todas)	3000	Rprop+	8	Log-Log	0.92	2.69	0.66	5.24
RN298	90	10	genótipo/espacamento/m/ARG/P/K/SOMAP8/Tmin_med(6)/adubações(todas)	3000	Quick	6	Log-Log	0.86	3.52	0.63	5.24
RN116	90	10	genótipo/espacamento/m/ARG/P/K/DH1DH2DH3DH4DH5DH6DH7DH8/adubações(todas)	3000	Rprop+	10	Log-Lin	0.74	4.59	0.74	5.25
RN89	90	10	genótipo/espacamento/m/ARG/P/K/DH_nor/adubações(todas)	3000	Rprop+	6	Log-Log	0.73	4.74	0.71	5.25
RN181	80	20	genótipo/espacamento/ARG/AF/AG/SIL/m/V/P/K/pH(H2O)/pH(CaCl2)/CTC/H+Al/Al/Mg/Ca/MO/Prem/DH1DH2DH3DH4DH5DH6DH7DH8/vv_media(6)/Adubações(todas)	3000	Rprop+	8	Log-Log	0.85	3.48	0.74	5.27
RN215	90	10	genótipo/espacamento/análise do solo (todas na camada 0-20 cm)/climáticas (todas as normais)/Adubações(todas)	3000	Rprop+	8	Tan-Tan	0.92	2.74	0.68	5.27
RN263	90	10	genótipo/P/K/V/CTC/P1P2P3P4P5P6P7P8/Tmin_med(6)/adubações(todas)	3000	Rprop+	8	Log-Log	0.87	3.49	0.63	5.27
RN32	90	10	genótipo/espacamento/ARG/P/K/pH(H2O)/Ca/Mg/SOMAP8/Tmin_med(6)/Adubações(todas)	3000	Rprop+	15	Log-Log	0.93	2.60	0.70	5.28
RN173	60	40	genótipo/espacamento/ARG/AF/AG/SIL/m/V/P/K/pH(H2O)/pH(CaCl2)/CTC/H+Al/Al/Mg/Ca/MO/Prem/DH1DH2DH3DH4DH5DH6DH7DH8/Adubações(todas)	3000	Rprop+	8	Log-Log	0.88	3.17	0.73	5.30
RN180	90	10	genótipo/espacamento/ARG/AF/AG/SIL/m/V/P/K/pH(H2O)/pH(CaCl2)/CTC/H+Al/Al/Mg/Ca/MO/Prem/DH1DH2DH3DH4DH5DH6DH7DH8/Adubações(todas)	3000	Back	8	Log-Log	0.82	4.04	0.71	5.31
RN138	90	10	genótipo/espacamento/P/K/pH(H2O)/Ca/Mg/MO/P1P2P3P4P5P6/Tmin_med(6)/adubações	3000	Rprop+	8	Log-Log	0.87	3.33	0.70	5.31
RN320	90	10	genótipo/espacamento/P/K/pH(H2O)/Ca/Mg/MO/DH1DH2DH3DH4DH5DH6DH7DH8/adubações(todas)	3000	Rprop+	8	Tan-Tan	0.90	2.93	0.65	5.31
RN300	90	10	genótipo/espacamento/m/ARG/P/K/SOMAP8/Tmin_med(6)/adubações(todas)	3000	Rprop+	8	Log-Log	0.78	4.34	0.61	5.32
RN272	90	10	genótipo/espacamento/m/ARG/P/K/DH1DH2DH3DH4DH5DH6DH7DH8/adubações(todas)	3000	Rprop+	6	Log-Lin	0.73	4.85	0.59	5.32
RN337	90	10	genótipo/espacamento/DH1DH2DH3DH4DH5DH6DH7DH8/adubações(todas)	3000	Rprop+	8	Log-Log	0.87	3.44	0.66	5.34
RN114	90	10	genótipo/espacamento/m/ARG/P/K/DH1DH2DH3DH4DH5DH6DH7DH8/adubações(todas)	3000	Rprop+	16	Tan-Lin	0.73	4.67	0.72	5.35
RN176	90	10	genótipo/espacamento/ARG/AF/AG/SIL/m/V/P/K/pH(H2O)/pH(CaCl2)/CTC/H+Al/Al/Mg/Ca/MO/Prem/DH1DH2DH3DH4DH5DH6DH7DH8/Adubações(todas)	3000	Rprop+	8	Log-Lin	0.73	4.64	0.71	5.35
RN293	90	10	genótipo/espacamento/m/ARG/P/K/SOMAP8/Tmin_med(6)/adubações(todas)	2000	Rprop+	6	Log-Log	0.83	3.84	0.61	5.35
RN283	50	50	genótipo/espacamento/m/ARG/P/K/DH1DH2DH3DH4DH5DH6DH7DH8/adubações(todas)	3000	Rprop+	6	Log-Log	0.81	3.84	0.68	5.36
RN184	50	50	genótipo/espacamento/ARG/AF/AG/SIL/m/V/P/K/pH(H2O)/pH(CaCl2)/CTC/H+Al/Al/Mg/Ca/MO/Prem/DH1DH2DH3DH4DH5DH6DH7DH8/vv_media(6)/Adubações(todas)	3000	Rprop+	8	Log-Log	0.76	4.40	0.67	5.36
RN307	90	10	genótipo/espacamento/m/ARG/P/K/SOMAP8/tmed_med(6)/adubações(todas)	3000	Rprop+	6	Log-Log	0.85	nc	0.64	5.36
RN45	90	10	genótipo/espacamento/ARG/AF/AG/SIL/m/V/P/K/pH(H2O)/pH(CaCl2)/CTC/H+Al/Al/Mg/Ca/MO/Prem/Climáticas normais (todas)/Adubações(todas)	3000	Rprop+	8	Log-Log	0.90	2.87	0.74	5.37
RN134	90	10	genótipo/espacamento/P/K/pH(H2O)/Ca/Mg/MO/P1P2P3P4P5P6P7P8/Tmin_med(6)/	3000	Rprop+	8	Log-Log	0.89	3.14	0.65	5.37

RN209	80	20	genótipo/espacamento/análise do solo (todas na camada 0-20 cm)/climáticas (todas as normais)/Adubação(todas)	3000	Rprop+	8	Log-Log	0.92	2.71	0.70	5.38
RN120	90	10	genótipo/espacamento/m/ARG/P/K/DH1DH2DH3DH4DH5DH6DH7DH8/adubações(todas)	3000	Rprop+	4	log-log	0.84	3.76	0.69	5.38
RN174	50	50	genótipo/espacamento/ARG/AF/AG/SIL/m/V/P/K/pH(H2O)/pH(CaCl2)/CTC/H+Al/Al/Mg/Ca/MO/Prem/DH1DH2DH3DH4DH5DH6DH7DH8/Adubações(todas)	3000	Rprop+	8	Log-Log	0.85	3.64	0.67	5.41
RN294	90	10	genótipo/espacamento/m/ARG/P/K/SOMAP8/Tmin_med(6)/adubações(todas)	3000	Rprop+	4	Log-Log	0.80	4.17	0.57	5.41
RN34	90	10	genótipo/espacamento/ARG/P/K/pH(H2O)/Ca/Mg/P7/P8/Tmin_nor/Tmax_normal/Adubações todas	3000	Rprop+	8	Log-Log	0.85	3.64	0.69	5.42
RN239	90	10	espacamento/P/K/pH(H2O)/Ca/Mg/MO/P1P2P3P4P5P6P7P8/Tmin_med(6)_med/adubações(todas)	3000	Rprop+	8	Log-Log	0.86	3.59	0.60	5.44
RN259	60	40	genótipo/espacamento/P/K/V/CTC/P1P2P3P4P5P6P7P8/Tmin_med(6)/adubações(todas)	3000	Rprop+	8	Log-Log	0.90	3.08	0.66	5.47
RN148	50	50	genótipo/espacamento/Análise foliar(todas)/Análise do solo (todas de 0-20 e 20-40 cm)/P1P2P3P4P5P6P7P8/DH1DH2DH3DH4DH5DH6DH7DH8/Tmin_med(6)/Tmax/Tmed/vv_med(6)/rad_med(6)/Etp_med(6)/UR_med(6)/todas adubações	3000	Rprop+	6	Log-Log	0.70	4.96	0.62	5.47
RN70	90	10	genótipo/espacamento/P/K/V/ARG/DH1DH2DH3DH4DH5DH6DH7DH8/adubações(todas)	3000	Rprop+	8	Log-Log	0.90	2.97	0.71	5.48
RN315	90	10	genótipo/espacamento/P1P2P3P4P5P6P7P8/Tmin_med(6)/adubações(todas)	3000	Rprop+	8	Log-Log	0.85	3.60	0.67	5.48
RN303	80	20	genótipo/espacamento/m/ARG/P/K/SOMAP8/Tmin_med(6)/adubações(todas)	3000	Rprop+	6	Log-Log	0.86	nc	0.66	5.48
RN225	70	30	genótipo/espacamento/P/K/pH(H2O)/Ca/Mg/MO/P1P2P3P4P5P6P7P8/Tmin_med(6)_med/adubações(todas)	3000	Rprop+	8	Log-Log	0.93	2.60	0.68	5.49
RN295	90	10	genótipo/espacamento/m/ARG/P/K/SOMAP8/Tmin_med(6)/adubações(todas)	3000	Rprop+	6	Log-Lin	0.66	5.29	0.55	5.49
RN237	90	10	genótipo/espacamento/P/K/pH(H2O)/Ca/Mg/MO/P1P2P3P4P5P6P7P8/tmed_med(6)/adubações(todas)	3000	Rprop+	8	Log-Log	0.89	3.17	0.60	5.51
RN262	90	10	espacamento/P/K/V/CTC/P1P2P3P4P5P6P7P8/Tmin_med(6)/adubações(todas)	3000	Rprop+	8	Log-Log	0.73	4.62	0.71	5.52
RN142	90	10	genótipo/espacamento/Análise foliar(todas)/Análise do solo (todas de 0-20 e 20-40 cm)/P1P2P3P4P5P6P7P8/DH1DH2DH3DH4DH5DH6DH7DH8/Tmin_med(6)/Tmax/Tmed/vv_med(6)/rad_med(6)/Etp_med(6)/UR_med(6)/todas adubações	3000	Rprop+	8	Log-Log	0.96	1.86	0.70	5.52
RN4	90	10	genótipo/espacamento/ARG/P/K/pH(H2O)/Ca/Mg/DH1DH2DH3DH4DH5DH6/vv_med(6)/Adubações(todas)	3000	Rprop+	8	Log-Log	0.88	3.20	0.71	5.53
RN327	80	20	genótipo/espacamento/P/K/pH(H2O)/Ca/Mg/MO/DH1DH2DH3DH4DH5DH6DH7DH8/adubações(todas)	3000	Rprop+	8	Log-Log	0.92	2.64	0.67	5.53
RN22	90	10	genótipo/espacamento/ARG/P/K/pHH2O/Ca/Mg/SOMADH(6)/Adubações(todas)	3000	Rprop+	8	Log-Log	0.90	3.03	0.70	5.55
RN165	90	10	espacamento/P/K/V/CTC/P1P2P3P4P5P6P7P8/Tmin_med(6)/adubações(todas)	3000	Rprop+	8	Log-Log	0.85	3.70	0.67	5.55
RN190	90	10	genótipo/espacamento/ARG/AF/AG/SIL/m/V/P/K/pH(H2O)/pH(CaCl2)/CTC/H+Al/Al/Mg/Ca/MO/Prem/DH1DH2DH3DH4DH5DH6DH7DH8/vv_med(6)/Adubações(todas)	3000	Back	8	Log-Log	0.82	4.13	0.64	5.55
RN83	90	10	genótipo/espacamento/m/ARG/P/K/SOMAP8/Tmin_med(6)/adubações(todas)	3000	Rprop+	6	Tan-lin	0.64	5.32	0.63	5.55
RN46	90	10	genótipo/espacamento/ARG/P/K/pH(H2O)/Ca/Mg/P1P2P3P4P5P6P7P8/Tmin_med(6)/Adubações(todas menos N)	3000	Rprop+	8	Log-Log	0.90	2.89	0.70	5.56
RN311	90	10	genótipo/espacamento/m/ARG/P/K/adubações(todas)	3000	Rprop+	6	Log-Log	0.83	3.82	0.70	5.57
RN98	90	10	genótipo/espacamento/P/K/V/CTC/MÉDIADH8/adubações(todas)	3000	Rprop+	8	Log-Log	0.87	3.40	0.69	5.57
RN207	90	10	genótipo/espacamento/ARG/P/K/pH(H2O)/Ca/Mg/SOMAP8/Tmax_med(6)	3000	Rprop+	8	Log-Log	0.84	3.70	0.70	5.59
RN241	90	10	P/K/pH(H2O)/Ca/Mg/MO/P1P2P3P4P5P6P7P8/Tmin_med(6)_med/adubações(todas)	3000	Rprop+	8	Log-Log	0.84	3.76	0.67	5.60
RN183	60	40	genótipo/espacamento/ARG/AF/AG/SIL/m/V/P/K/pH(H2O)/pH(CaCl2)/CTC/H+Al/Al/Mg/Ca/MO/Prem/DH1DH2DH3DH4DH5DH6DH7DH8/vv_med(6)/Adubações(todas)	3000	Rprop+	8	Log-Log	0.96	2.00	0.64	5.60
RN81	80	20	genótipo/espacamento/m/ARG/P/K/SOMAP8/Tmin_med(6)/adubações(todas)	3000	Rprop+	4	Log-Log	0.77	4.37	0.67	5.61
RN330	50	50	genótipo/espacamento/P/K/pH(H2O)/Ca/Mg/MO/DH1DH2DH3DH4DH5DH6DH7DH8/adubações(todas)	3000	Rprop+	8	Log-Log	0.81	3.99	0.65	5.61
RN218	90	10	genótipo/espacamento/análise do solo (todas na camada 0-20 cm)/climáticas (todas as normais)/Adubação(todas)	3000	Back	8	Log-Log	0.78	4.57	0.69	5.63
RN144	50	50	genótipo/espacamento/p/k/v/ctc/p1p2p3p4p5p6p7p8/Tmin_med(6)/adubações(todas)	3000	Rprop+	8	Log-Log	0.92	2.69	0.64	5.63
RN292	90	10	genótipo/espacamento/m/ARG/P/K/SOMAP8/Tmin_med(6)/adubações(todas)	5000	Rprop+	6	Log-Log	0.87	3.40	0.59	5.63
RN278	90	10	genótipo/espacamento/m/ARG/P/K/DH1DH2DH3DH4DH5DH6DH7DH8/adubações(todas)	3000	Rprop+	6	Tan-Log	0.11	7.15	0.13	5.63
RN126	70	30	genótipo/espacamento/p/k/v/ctc/p1p2p3p4p5p6p7p8/Tmin_med(6)/adubações(todas)	3000	Rprop+	8	Log-Log	0.91	2.72	0.65	5.66
RN217	90	10	genótipo/espacamento/análise do solo (todas na camada 0-20 cm)/climáticas (todas as normais)/Adubação(todas)	3000	Quick	8	Log-Log	0.93	2.57	0.66	5.68

RN20	90	10	genótipo/espacamento/ARG/P/K/pH2O/Ca/Mg/MÉDIADH(8)/Adubações(todas)	3000	Rprop+	8	Log-Log	0.90	3.02	0.68	5.70
RN84	90	10	genótipo/espacamento/m/ARG/P/K/SOMAP8/Tmin_med(6)/adubações(todas)	3000	Rprop+	15	Tan-lin	0.67	5.15	0.63	5.70
RN108	90	10	genótipo/espacamento/P/K/V/CTC/P1P2P3P4P5P6P7P8/Tmin_med(6)/adubações(todas)	3000	Rprop+	8	Tan-Tan	0.91	2.85	0.71	5.72
RN297	90	10	genótipo/espacamento/m/ARG/P/K/SOMAP8/Tmin_med(6)/adubações(todas)	3000	Rprop+	6	Tan-Lin	0.64	5.39	0.50	5.73
RN130	60	40	genótipo/espacamento/P/K/V/CTC/P1P2P3P4P5P6P7P8/Tmin_med(6)/adubações(todas)	3000	Rprop+	8	Log-Log	0.92	2.66	0.66	5.76
RN203	90	10	genótipo/espacamento/ARG/P/K/pH(H2O)/Ca/Mg/SOMAP8/Tmax_med(6)/Adubações(todas)	3000	Back	8	Log-Log	0.88	3.20	0.66	5.80
RN279	90	10	genótipo/espacamento/m/ARG/P/K/DH1DH2DH3DH4DH5DH6DH7DH8/adubações(todas)	3000	Rprop+	6	Log-Tan	0.83	3.84	0.70	5.81
RN260	50	50	genótipo/espacamento/P/K/V/CTC/P1P2P3P4P5P6P7P8/Tmin_med(6)/adubações(todas)	3000	Rprop+	8	Log-Log	0.93	2.40	0.66	5.81
RN227	50	50	genótipo/espacamento/P/K/pH(H2O)/Ca/Mg/MO/P1P2P3P4P5P6P7P8/Tmin_med(6)_med/adubações(todas)	3000	Rprop+	8	Log-Log	0.94	2.37	0.66	5.82
RN24	90	10	genótipo/espacamento/ARG/P/K/pH(H2O)/Ca/Mg/SOMAP(6)/Tmin_med(6)/vv_med(6)/Adubações(todas)	3000	Rprop+	8	Log-Log	0.89	3.18	0.64	5.83
RN80	80	20	genótipo/espacamento/m/ARG/P/K/SOMAP8/Tmin_med(6)/adubações(todas)	3000	Rprop+	6	Log-Log	0.83	3.76	0.64	5.83
RN305	60	40	genótipo/espacamento/m/ARG/P/K/SOMAP8/Tmin_med(6)/adubações(todas)	3000	Rprop+	6	Log-Log	0.87	nc	0.64	5.83
RN195	70	30	genótipo/espacamento/ARG/P/K/pH(H2O)/Ca/Mg/SOMAP8/Tmax_med(6)/Adubações(todas)	3000	Rprop+	8	Log-Log	0.89	3.15	0.64	5.85
RN197	50	50	genótipo/espacamento/ARG/P/K/pH(H2O)/Ca/Mg/SOMAP8/Tmax_med(6)/Adubações(todas)	3000	Rprop+	8	Log-Log	0.92	2.68	0.62	5.87
RN123	90	10	genótipo/espacamento/areia total/P/K/Ca/Mg/SOMADH8/Adubações(todas)	2000	Rprop+	6	Log-Log	0.83	3.81	0.68	5.93
RN245	90	10	genótipo/espacamento/	3000	Rprop+	8	Log-Log	0.51	6.10	0.41	5.95
RN182	70	30	genótipo/espacamento/ARG/AF/AG/SIL/m/V/P/K/pH(H2O)/pH(CaCl2)/CTC/H+Al/Al/Mg/Ca/MO/Prem/ DH1DH2DH3DH4DH5DH6DH7DH8/vv_med(6)/Adubações(todas)	3000	Rprop+	8	Log-Log	0.92	2.60	0.63	6.00
RN124	90	10	genótipo/espacamento/P/K/V/CTC/SOMADH6/adubações(todas)	3000	Rprop+	8	Log-Log	0.87	3.32	0.66	6.02
RN334	90	10	genótipo/espacamento/P/K/pH(H2O)/Ca/Mg/MO/DH1DH2DH3DH4DH5DH6DH7/adubações(todas)	3000	Rprop+	8	Log-Log	0.91	2.82	0.57	6.03
RN199	90	10	genótipo/espacamento/ARG/P/K/pH(H2O)/Ca/Mg/SOMAP8/Tmax_med(6)/Adubações(todas)	3000	Rprop+	8	Log-Lin	0.65	5.26	0.66	6.05
RN291	90	10	genótipo/espacamento/P/K/v/ctc/p1p2p3p4p5p6p7/Tmin_med(6)/adubações(todas)	3000	Rprop+	8	Log-Log	0.91	2.88	0.67	6.06
RN299	90	10	genótipo/espacamento/m/ARG/P/K/SOMAP8/Tmin_med(6)/adubações(todas)	3000	Back	6	Log-Log	0.72	5.01	0.47	6.09
RN42	90	10	genótipo/espacamento/ARG/P/K/pH(H2O)/Ca/Mg/P1P2P3P4P5P6/Tmin_med(6)/vv_med(6)/Adubações(todas)	3000	Rprop+	8	Log-Log	0.91	2.77	0.70	6.11
RN211	60	40	genótipo/espacamento/análise do solo (todas na camada 0-20 cm)/climáticas (todas as normais)/Adubações(todas)	3000	Rprop+	8	Log-Log	0.94	2.39	0.62	6.13
RN226	60	40	genótipo/espacamento/P/K/pH(H2O)/Ca/Mg/MO/P1P2P3P4P5P6P7P8/Tmin_med(6)_med/adubações(todas)	3000	Rprop+	8	Log-Log	0.95	2.10	0.63	6.15
RN306	50	50	genótipo/espacamento/m/ARG/P/K/SOMAP8/Tmin_med(6)/adubações(todas)	3000	Rprop+	6	Log-Log	0.88	nc	0.63	6.16
RN266	90	10	genótipo/espacamento/P/K/V/CTC/adubações(todas)	3000	Rprop+	8	Log-Log	0.86	3.46	0.66	6.18
RN196	60	40	genótipo/espacamento/ARG/P/K/pH(H2O)/Ca/Mg/SOMAP8/Tmax_med(6)/Adubações(todas)	3000	Rprop+	8	Log-Log	0.91	2.77	0.60	6.27
RN212	50	50	genótipo/espacamento/análise do solo (todas na camada 0-20 cm)/climáticas (todas as normais)/Adubações(todas)	3000	Rprop+	8	Log-Log	0.97	1.72	0.58	6.72
RN255	90	10	genótipo/espacamento/P/K/V/CTC/P1P2P3P4P5P6P7P8/Tmin_med(6)/adubações(todas)	3000	Rprop+	8	Tan-Log	0.28	6.73	0.47	6.73
RN235	90	10	genótipo/espacamento/P/K/pH(H2O)/Ca/Mg/MO/P1P2P3P4P5P6P7P8/Tmin_med(6)_med/adubações(todas)	3000	Rprop+	8	Tan-Log	0.24	6.79	0.44	6.86
RN325	90	10	genótipo/espacamento/P/K/pH(H2O)/Ca/Mg/MO/DH1DH2DH3DH4DH5DH6DH7DH8/adubações(todas)	3000	Rprop+	8	Tan-Log	0.10	6.99	0.20	6.95
RN268	90	10	genótipo/espacamento/	3000	Rprop+	8	Log-Log	0.53	5.79	0.24	8.49
RN5	90	10	genótipo/espacamento/ARG/P/K/pH(H2O)/Ca/Mg/DH1DH2DH3DH4DH5DH6DH7DH8/Adubações(todas)	3000	Rprop+	8	Log-Log	nc	nc	nc	nc
RN6	90	10	genótipo/espacamento/ARG/P/K/pH(H2O)/Ca/Mg/DH_nor/vv_nor/Adubações(todas)	3000	Rprop+	8	Log-Log	nc	nc	nc	nc
RN31	90	10	genótipo/espacamento/ARG/P/K/pH(H2O)/Ca/Mg/SOMAP6/Tmin_med(6)/Adubações(todas)	3000	Rprop+	8	Log-Log	nc	nc	nc	nc
RN71	90	10	genótipo/espacamento/P/K/V/CTC/P1P2P3P4P5P6P7P8/Tmin_med(6)/adubações(todas)	3000	Rprop+	8	Tan-Log	nc	nc	nc	nc
RN82	90	10	genótipo/espacamento/m/ARG/P/K/SOMAP8/Tmin_med(6)/adubações(todas)	3000	Back	6	Log-Log	nc	nc	nc	nc
RN85	90	10	genótipo/espacamento/areia total/P/K/Ca/Mg/P1P2P3P4P5P6P7P8/Tmin_med(6)/Adubações(todas)	3000	Rprop+	8	Log-Log	nc	nc	nc	nc
RN301	90	10	genótipo/espacamento/m/ARG/P/K/SOMAP8/Tmin_med(6)/adubações(todas)	3000	Rprop+	6	Tan-Log	nc	nc	nc	nc

	I1	I2	I3	I4	I5	I6	I7	I8	I9	I10	I11	I12	I13	Output
H1	4.6932	1.0038	-10.6469	1.1914	3.3583	-1.5235	-0.7744	-1.1916	-2.2134	-53.5143	-14.7589	-1.2914	2.0267	-13.2534
H2	2.1145	-5.0743	-10.1131	3.7484	-1.8948	0.9912	2.6813	6.9303	2.7454	-0.6922	0.6359	2.0428	1.2132	1.7961
H3	-0.8041	-0.5115	-3.9092	-0.9016	-0.0619	-0.6061	-0.3215	-1.0322	2.5390	0.2756	1.8514	0.0576	-0.3339	-7.0434

(1º)

	I1	I2	I3	I4	I5	I6	I7	I8	I9	I10	I11	I12	I13	Output
H1	4.6932	1.0038	10.6469	1.1914	3.3583	1.5235	0.7744	1.1916	2.2134	53.5143	14.7589	1.2914	2.0267	13.2534
H2	2.1145	5.0743	10.1131	3.7484	1.8948	0.9912	2.6813	6.9303	2.7454	0.6922	0.6359	2.0428	1.2132	1.7961
H3	0.8041	0.5115	3.9092	0.9016	0.0619	0.6061	0.3215	1.0322	2.5390	0.2756	1.8514	0.0576	0.3339	7.0434

(2º)

	I1	I2	I3	I4	I5	I6	I7	I8	I9	I10	I11	I12	I13	Soma
H1	P11=62.2014	P12=13.3035	P13=141.1079	P14=15.7895	P15=44.5091	P16=20.1911	P17=10.2636	P18=15.7932	P19=29.3353	P110=709.2489	P111=195.6067	P112=17.1149	P113=26.861	1301.3262
H2	P21=3.7978	P22=9.1141	P23=18.1644	P24=6.7326	P25=3.4033	P26=1.7804	P27=4.8160	P28=12.4476	P29=4.9311	P210=1.2434	P211=1.1421	P212=3.6692	P213=2.1790	73.4208
H3	P31=5.6636	P32=3.6025	P33=27.5336	P34=6.3504	P35=0.4362	P36=4.2691	P37=2.2647	P38=7.2703	P39=17.8827	P310=1.9409	P311=13.0403	P312=0.4060	P313=2.3516	93.0119

(3º)

(4º)

	I1	I2	I3	I4	I5	I6	I7	I8	I9	I10	I11	I12	I13	Soma
H1	Q11=0.0478	Q12=0.0102	Q13=0.1084	Q14=0.0121	Q15=0.0342	Q16=0.0155	Q17=0.0079	Q18=0.0121	Q19=0.0225	Q110=0.545	Q111=0.1503	Q112=0.0132	Q113=0.0206	
H2	Q21=0.0517	Q22=0.1241	Q23=0.2474	Q24=0.0917	Q25=0.0464	Q26=0.0242	Q27=0.0656	Q28=0.1695	Q29=0.0672	Q210=0.0169	Q211=0.0156	Q212=0.0500	Q213=0.0297	
H3	Q31=0.0609	Q32=0.0387	Q33=0.296	Q34=0.0683	Q35=0.0047	Q36=0.0459	Q37=0.0243	Q38=0.0782	Q39=0.1923	Q310=0.0209	Q311=0.1402	Q312=0.0044	Q313=0.0253	
Soma	S1=0.1604	S2=0.1731	S3=0.6519	S4=0.1721	S5=0.0852	S6=0.0857	S7=0.0978	S8=0.2598	S9=0.282	S10=0.5828	S11=0.3061	S12=0.0675	S13=0.0756	3

(5º)

(6º)

	I1	I2	I3	I4	I5	I6	I7	I8	I9	I10	I11	I12	I13	Soma
	0.0535	0.0577	0.2173	0.0574	0.0284	0.0286	0.0326	0.0866	0.0940	0.1943	0.1020	0.0225	0.0252	1

(7º)

I1 a I13 = 13 neurônios na camada de entrada (13 variáveis predictoras)

H1 a H3 = 3 neurônios na camada oculta

Output = resposta da rede neuronal artificial

(1º) Organizar os pesos das conexões entre os neurônios das camadas de entrada, oculta e saída; (2º) Utilizar os valores absolutos dos pesos; (3º) Multiplicar cada peso da conexão camada oculta-saída para o respectivo neurônio da camada oculta. Exemplo: $H1-I1 \times H1-Output = 4.6932 \times 13.2534 = 62.2014 = P11$; (4º) Fazer a soma dos produtos para cada neurônio da camada oculta; (5º) Dividir cada produto (P) pela soma do respectivo neurônio da camada oculta. Exemplo: $Q11 = 62.2014/1301.3262 = 0.0478$; (6º) Somar os Q's para cada variável da camada de entrada. Exemplo: $S1 = 0.0478+0.0517+0.0609 = 0.1604$; (7º) Somar os S's e obter a relação para cada variável de entrada, que será a importância relativa de cada um, o somatório das importâncias deve ser igual a 1. Exemplo: Importância relativa da I1 = $0.1604/3 = 0.0535$

Figura 4 – Passo a passo do cálculo da importância relativa das variáveis predictoras por meio do algoritmo de Garson, conforme apresentado por Olden e Jackson (2002).

	I1	I2	I3	I4	I5	I6	I7	I8	I9	I10	I11	I12	I13	Output
H1	4.6932	1.0038	-10.6469	1.1914	3.3583	-1.5235	-0.7744	-1.1916	-2.2134	-53.5143	-14.7589	-1.2914	2.0267	-13.2534
H2	2.1145	-5.0743	-10.1131	3.7484	-1.8948	0.9912	2.6813	6.9303	2.7454	-0.6922	0.6359	2.0428	1.2132	1.7961
H3	-0.8041	-0.5115	-3.9092	-0.9016	-0.0619	-0.6061	-0.3215	-1.0322	2.5390	0.2756	1.8514	0.0576	-0.3339	-7.0434

(1º)

	I1	I2	I3	I4	I5	I6	I7	I8	I9	I10	I11	I12	I13
H1	P11=-62.2014	P12=-13.3035	P13=141.1079	P14=-15.7895	P15=-44.5091	P16=20.1911	P17=10.2636	P18=15.7932	P19=29.3353	P110=709.2489	P111=195.6067	P112=17.1149	P113=-26.861
H2	P21=3.7978	P22=-9.1141	P23=-18.1644	P24=6.7326	P25=-3.4033	P26=1.7804	P27=4.816	P28=12.4476	P29=4.9311	P210=-1.2434	P211=1.1421	P212=3.6692	P213=2.179
H3	P31=5.6636	P32=3.6025	P33=27.5336	P34=6.3504	P35=0.4362	P36=4.2691	P37=2.2647	P38=7.2703	P39=-17.8827	P310=-1.9409	P311=-13.0403	P312=-0.406	P313=2.3516
Soma	-52.7400	-18.8151	150.4772	-2.7065	-47.4762	26.2406	17.3443	35.5110	16.3838	706.0647	183.7085	20.3781	-22.3304

(2º)

(3º)

I1 a I13 = 13 neurônios na camada de entrada (13 variáveis preditoras).

H1 a H3 = 3 neurônios na camada oculta.

Output = resposta da rede neuronal artificial.

(1º) Organizar os pesos das conexões entre os neurônios das camadas de entrada, oculta e saída; (2º) Multiplicar cada peso (valores brutos) da conexão camada oculta-saída para o respectivo neurônio da camada oculta. Exemplo: $H1-I1 \times H1-Output = 4.6932 \times -13.2535 = -62.2014 = P11$; (3º) Fazer a soma dos produtos para cada neurônio da camada entrada, que será equivalente a importância de cada variável preditora.

Figura 5 – Passo a passo do cálculo da importância das variáveis preditoras por meio do algoritmo de Olden, conforme apresentado por Olden e Jackson (2002).