

**RICARDO RODRIGUES DE OLIVEIRA NETO**

**INVERSÃO DE REDES NEURAS ARTIFICIAIS NA MODELAGEM DA  
PRODUTIVIDADE DE EUCALIPTO**

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

Orientador: Helio Garcia Leite

Coorientadores: José Marinaldo Gleriani  
Júlio Cesar Lima Neves

**VIÇOSA - MINAS GERAIS  
2021**

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

T

O48i  
2021  
Oliveira Neto, Ricardo Rodrigues de, 1986-  
Inversão de redes neurais artificiais na modelagem da  
produtividade de eucalipto / Ricardo Rodrigues de Oliveira Neto.  
– Viçosa, MG, 2021.

1 tese eletrônica (142 f.): il. (algumas color.).

Orientador: Helio Garcia Leite.

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

Inclui bibliografia.

DOI: <https://doi.org/10.47328/ufvbbt.2022.027>

Modo de acesso: World Wide Web.

1. Florestas - Manejo. 2. Redes neurais (Computação).  
3. Produtividade. 4. Recozimento simulado (Matemática).  
I. Leite, Helio Garcia, 1960-. II. Universidade Federal de Viçosa.  
Departamento de Engenharia Florestal. Programa de  
Pós-Graduação em Ciência Florestal. III. Título.

CDO adapt. CDD 634.961

Bibliotecário(a) responsável: Renata de Fátima Alves CRB6/2578

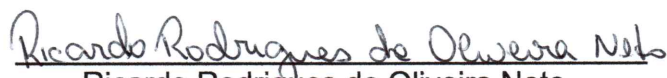
**RICARDO RODRIGUES DE OLIVEIRA NETO**

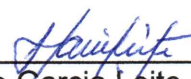
**INVERSÃO DE REDES NEURAIS ARTIFICIAIS NA MODELAGEM DA  
PRODUTIVIDADE DE EUCALIPTO**

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: 11 de novembro de 2021.

Assentimento:

  
\_\_\_\_\_  
Ricardo Rodrigues de Oliveira Neto  
Autor

  
\_\_\_\_\_  
Helio Garcia Leite  
Orientador

“A experiência mais bela e profunda que um homem pode ter é o sentido do mistério. Ele é o princípio fundamental da religião, bem como de todo esforço sério em termos de arte e ciência. Parece-me que aquele que nunca teve essa experiência, se não está morto, pelo menos está cego.”

Albert Einstein, Meu Credo, 1932.

## **AGRADECIMENTOS**

A meus pais, pelo suporte e apoio incondicional. A minha avó, Lourdes, pelos ensinamentos de vida e perseverança.

Aos amigos que conquistei durante minha estadia por onde passei, em especial Letícia, Simone, Fausto, Ronaldo, Kelsey, Marli, Kat e Léo.

Ao professor Hélio Garcia, pelo exemplo não só de profissional e professor, mas de pessoa e amigo, disposto a conversar para ajudar.

Ao professor Marinaldo pela oportunidade.

Ao professor Bogdan pelo acolhimento na Oregon State University.

Ao Departamento de Engenharia Florestal da Universidade Federal de Viçosa.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pela concessão da bolsa de estudos.

## **BIOGRAFIA**

Ricardo Rodrigues de Oliveira Neto é natural de Ubá, Minas Gerais. Filho de Maria Helena de Oliveira e Mário Sérgio Furtado, nascido em 20 de junho de 1986.

Em 2002 iniciou os estudos no Colégio de Aplicação da Universidade Federal de Viçosa (COLUNI) em Viçosa.

Iniciou o curso de engenharia florestal na mesma universidade em 2005, onde se graduou em janeiro de 2010.

Após a graduação trabalhou na área de Inventário, Planejamento e Pesquisa no Maranhão, Pará, Mato Grosso e São Paulo, com plantios de eucalipto e teca.

Em julho de 2014, iniciou o Programa de Mestrado em Ciências Florestal na Universidade Federal de Viçosa, submetendo-se a defesa da dissertação em 21 de julho de 2010.

Em agosto de 2017, iniciou o Programa de Doutorado em Ciências Florestal na Universidade Federal de Viçosa. Em novembro de 2019, como Pesquisador Visitante, foi para Oregon State University, nos Estados Unidos, onde realizou parte dos processamentos dos dados. Submeteu a defesa da tese em 11 de novembro de 2021.

## RESUMO

OLIVEIRA NETO, Ricardo Rodrigues de, D.Sc., Universidade Federal de Viçosa, novembro de 2021. **Inversão de redes neurais artificiais na modelagem da produtividade de eucalipto**. Orientador: Helio Garcia Leite. Coorientadores: José Marinaldo Gleriani e Júlio Cesar Lima Neves.

Para um bom gerenciamento dos plantios florestais, é imprescindível analisar todos os fatores que interferem no seu crescimento e produção, já que toda tomada de decisão é feita a partir da estimativa da produção futura utilizando-se informações históricas e correntes. Vários fatores se correlacionam e influenciam o crescimento da floresta, sendo divididos em climáticos, edáficos, fisiográficos e bióticos e diversas técnicas vem sendo utilizadas para modelar essa correlação, entre elas Redes Neurais Artificiais (RNA), na qual os fatores ecofisiológicos e silviculturais se relacionam com a produtividade esperada. A inversão de uma RNA é feita quando queremos as diversas possibilidades de valores das variáveis de entrada com um output fixo. A utilização de Simulated Annealing (SA) auxilia a inversão da rede na obtenção do grupo de respostas oriundas da inversão (*one-to-many*) visto que são produzidas mais de uma resposta para uma produtividade desejada, sendo também uma ferramenta eficiente na identificação dos limitantes da produtividade de plantios de eucalipto no Brasil. O presente trabalho realizou a inversão de uma RNA utilizando SA com dados edafoclimáticos e silviculturais de plantios de eucalipto no estado de Minas Gerais, com idade variando de dois a seis anos<sup>37</sup>, correlacionando com a sua produtividade aos 6 anos, a idade de corte. O Simulated Annealing consegue realizar a inversão da RNA com eficiência, encontrando mais de uma solução local para o problema. Comparando os resultados obtidos com estudos correlatos, verifica-se a importância de variáveis categóricas como material genético e espaçamento como também a relação dessas variáveis com os níveis de adubação ótima para uma maior produtividade levando em consideração as condições climáticas e edáficas da região.

**Palavras-chave:** Redes Neurais Artificiais. Simulated Annealing. Inversão de Rede. Produtividade Florestal.

## ABSTRACT

OLIVEIRA NETO, Ricardo Rodrigues de, D.Sc., Universidade Federal de Viçosa, November, 2021. **Inversion of artificial neural networks in eucalyptus productivity modeling**. Advisor: Helio Garcia Leite. Co-advisors: José Marinaldo Gleriani and Júlio Cesar Lima Neves.

For an optimized forest plantation management, it is essential to analyze all the factors that interfere in their growth and production, since all decision-making is made from the estimate of future production using historical and current information. Several factors correlate and influence the growth of the forest, which are divided into climatic, edaphic, physiographic and biotic and several techniques have been used to model this correlation, including Artificial Neural Networks (ANN), in which ecophysiological and silvicultural factors are relate to expected productivity. The inversion of an ANN is done when we want the different possible values of the input variables with a fixed output. The use of Simulated Annealing (SA) helps to obtain a group of responses from the inversion (one-to-many) since more than one response is obtained for a desired productivity and is an efficient tool to identificate the constraints of the productivity of eucalyptus plantations in Brazil. The present work carried out the inversion of an ANN using SA with edaphoclimatic and silvicultural data of eucalyptus plantations in MG from 3 to 7 years of age, correlating the harvest age with its productivity at 6 years of age. Simulated Annealing is able to perform the ANN inversion efficiently, finding more than one local solution to the problem. Comparing the results obtained with related studies, the importance of categorical variables such as genetic material and spacing is verified, as well as the relationship of these variables with the levels of optimal fertilization for greater productivity, taking into account the climatic and edaphic conditions of the region.

**Keywords:** Artificial Neural Networks. Simulated Annealing. Network Inversion. Forest Productivity.



## LISTA DE FIGURAS

Figura 1 - Diagrama da interação dos fatores do meio (BILINGS, 1964) .....	19
Figura 2 - Padrão de vegetação em relação a altitude .....	34
Figura 3 - Study area with the location of the plantation. The texture of the map is the geomorphology according to IBGE (2014). .....	76
Figura 4 - Multilayer perceptron with two hidden layers and an output layer. (adapted from Haykin, 2009) .....	82
Figura 5 - Hierarchical Cluster Analysis of the ANNs performances .....	94
Figura 6 - Performance of the pruned and unpruned ANNs, one of which supplied the top results in term of bias, RME and correlation coefficient. ....	95
Figura 7 - Observed vs Predicted values and Residuals of ANNs trained with SCG with four neurons in the hidden layer (red – no pruning, black –pruned).....	96
Figura 8 - Localização dos plantios de estudo. As cores do mapa fornecem informação de geomorfologia de acordo com o IBGE (2014). .....	120
Figura 9 - Pseudocódigo Simulated Annealling (Hosseinabadi et al., 2017) .....	126
Figura 10 - Dispersão entre nutrientes e produtividade ao ano 6 (IMA 6) .....	128
Figura 11 - Dispersão entre os materiais genéticos e produtividade ano 6 (IMA 6). .....	129
Figura 12 - Dispersão entre espaçamento e produtividade no ano 6 (IMA 6).....	130
Figura 13 - Heatmap entre material genético, espaçamento e produtividade no ano 6. ....	130
Figura 14 - Heatmap correlacionando macro nutrientes NPK, material genético e produtividade no ano 6.....	131
Figura 15 - Heatmap correlacionando macronutrientes NPK, espaçamento e produtividade no ano 6.....	132

## LISTA DE TABELAS

Tabela 1 - Grupos de fatores, suas subdivisões e os aspectos do meio que influenciam o crescimento e desenvolvimento da planta (fonte: BILINGS, 1964).....	20
Tabela 2 - Fatores ambientais que afetam a produtividade florestal. (fonte: Hughes and Boyd (1973)).....	47
Tabela 3 - Continuous variables, subject to standardization.....	77
Tabela 4 - Parameters for pruning algorithm.....	88
Table 5 - Principal Components supplying >90% of all variation, their eigenvalues and relative contribution [%].....	89
Table 6 - Statistics for top 20 ANNs according to bias.....	91
Tabela 7 - Ranking of the top 20 ANNs according to correlation, bias, MAE, RMSE, and time to produce the solution. (BPM = Backpropagation Momentum; BPW = Backpropagation Weight Decay; BPC = Backpropagation Chunk; SBP = Standard Backpropagation; RPR = Resilient Propagation; SCG- Scaled Conjugate Gradient; and for pruning method: MP Magnitude Based Pruning, OBD Optimal Brain Damage, SKE Skeletonization; NCU -Non-contributing Units. ....	93
Tabela 8 - Growth and yield models.....	97
Tabela 9 - Variáveis contínuas.....	121
Tabela 10 - Componentes principais fornecendo > 90% de toda a variação, seus autovalores e contribuição relativa [%].....	124
Tabela 11 - Saídas encontradas pela Simulated Annealing. ....	127

## SUMÁRIO

INTRODUÇÃO GERAL .....	12
REFERÊNCIAS .....	14
CAPÍTULO 1: FATORES CLIMÁTICOS, EDÁFICOS, FISIOGRÁFICOS E BIÓTICOS QUE INFLUENCIAM A PRODUTIVIDADE FLORESTAL. UMA REVISÃO. ....	18
1 INTRODUÇÃO .....	18
1.1 Ventos .....	23
1.2 Água .....	25
1.3 Temperatura e clima .....	27
1.4 Radiação .....	29
1.5 Composição Atmosférica .....	30
1.6 Fogo .....	32
1.7 Topografia e relevo .....	33
1.8 Solo e fertilidade .....	35
1.9 Genótipo .....	37
1.10 Doenças .....	39
1.11 Pragas .....	40
1.12 Outras plantas .....	42
1.13 Microrganismos do solo .....	43
1.14 Fauna .....	44
1.15 Homem .....	45
1.16 Manejo .....	46
REFERÊNCIAS .....	52
CAPÍTULO 2: ESTIMATION OF EUCALYPTUS PRODUCTIVITY USING EFFICIENT ARTIFICIAL NEURAL NETWORK .....	67
ABSTRACT .....	68
RESUMO .....	70
1 INTRODUCTION .....	72
2 METHODS .....	76
2.1 Study area and data .....	76
2.2 Principal Component Analysis .....	79
2.3 Artificial Neural Network and pruning .....	81
2.3.1 Structure of the ANN and training algorithms .....	81
2.3.2 Structure of the ann and training algorithms .....	86

2.4	The ANN assessment .....	88
3	RESULTS .....	89
4	DISCUSSIONS .....	99
5	CONCLUSION .....	101
	REFERENCE .....	102
	CAPÍTULO 3: INVERSÃO DE REDES NEURAIS ARTIFICIAIS PARA DIMENSIONAR FATORES DETERMINANTES DA PRODUTIVIDADE DE POVOAMENTOS DE EUCALIPTO .....	112
	RESUMO .....	113
	ABSTRACT .....	114
1	INTRODUÇÃO .....	115
2	MATERIAIS E MÉTODOS .....	120
	2.1 Dados .....	120
	2.2 Análise de Componentes Principais - PCA .....	123
	2.3 Redes Neurais Artificiais .....	124
	2.4 Simulated Annealing .....	125
3	RESULTADOS E DISCUSSÃO .....	126
	3.2 Genótipo X Ima 6 .....	129
	3.3 Espaçamento X Ima 6 .....	129
	3.4 Espaçamento X Genótipo X Ima 6 .....	130
	3.5 Npk X Genótipo X Ima 6 .....	131
	3.6 Npk X Espaçamento X Ima 6 .....	131
4	DISCUSSÃO .....	132
5	CONCLUSÕES .....	134
	REFERÊNCIAS .....	135

## INTRODUÇÃO GERAL

Para um gerenciamento de plantios florestais otimizado é necessário compreender os processos de crescimento e de produção, uma vez que as decisões a serem tomadas serão baseadas na predição da produção futura a partir de informações correntes (Cosenza, 2015). Para tal, são utilizados modelos estatísticos para fazer essas previsões utilizando informações atuais dos plantios florestais. Essas previsões são utilizadas no processo de planejamento, sendo a base do manejo florestal, com a prognose da produção, prescrição de tratamentos silviculturais e a classificação de terras, com este último sendo considerado um dos principais (Campos e Leite, 2013).

Os fatores que afetam o crescimento das plantas podem ser classificados em: climáticos, edáficos, fisiográficos e bióticos. A interação entre esses fatores e seu efeito no processo de crescimento da árvore é complexa e de difícil entendimento (Campos, 1970). Diversas são as metodologias para determinação da capacidade produtiva das terras, sendo as mais comuns as curvas de índices de local, que utilizando os modelos de Chapman-Richard, Logístico, Gompertz e o de Schumacher, relacionam altura dominante com a idade (Campos e Leite, 2013). Outras mais complexas, envolvem variáveis edáficas e climáticas para determinar o crescimento das árvores (Campos, 1970). Quanto maior o número de fatores e suas interações, maior a necessidade de ferramentas que consigam lidar com grandes quantidades de variáveis, gerando modelos mais robustos.

Nesse caso uma alternativa de modelagem que pode ser eficiente é o emprego de ferramentas de Inteligência Computacional (IC), como as redes neurais artificiais (RNA). O treinamento de uma RNA envolve a determinação dos pesos das conexões, com base nos dados de treinamento. São muitas as aplicações das RNA na área florestal. Elas podem ser utilizadas em estudos sobre reconhecimento de padrões e interpretação de imagens (Rai et al., 2020; Lu et al., 2017), mineração de dados (Jiao e Li, 2021; Sahu et al., 2020), análises financeiras (Zuxing e Dian, 2020), monitoramento de incêndios florestais (Al-Kahlout et al., 2020), modelagem de crescimento em diferentes níveis, estimacão da altura (Dantas et al., 2020), volume e afilamento do fuste de árvores (Leite et al., 2020; Socha et al., 2020; de Azevedo et al., 2020), estudos de mortalidade (Syvain, 2019; da Rocha et al. 2018), estimacão de estoques de carbono em povoamentos equiâneos e inequiâneos (Dantas et al., 2021;

Acheampong e Boateng, 2019; Dolácio et al., 2019) e predição da capacidade produtiva (Dolácio et al., 2020; Araújo et al., 2019; Cosenza et al., 2017).

A investigação dos fatores determinantes da produtividade dos plantios de eucalipto é tema recorrente em diversos estudos, para a alocação eficiente dos recursos visando sua maior produtividade. Recentemente, devido as mudanças climáticas, seleção precoce de clones e expansão das áreas de plantios sem o conhecimento prévio da região, vem se notando a estabilização dos ganhos de produtividade de florestas (Ibá, 2019; Investiagro, 2016). Portanto, é necessário identificar os fatores mais influentes e, dentre eles, definir aqueles que podem ser modificados e que tipo de modificação é necessária para se obter a melhor produtividade. Tal identificação não é uma tarefa simples e requer uma modelagem matemática abrangente, eficiente e apropriada, além de uma ampla base de dados históricos. Esses dados devem compreender o cadastro das operações florestais, os históricos de produção e informações edáficas, climáticas e fisiográficas de diferentes regiões. A inversão de uma RNA permite verificar a importância das variáveis de entrada sobre a variável de saída (Davis et al., 1993). Portanto, esta abordagem pode ser eficiente na identificação dos limitantes da produtividade de plantios de eucalipto no Brasil, além de permitir a definição de níveis de cada fator para que seja atingida uma produtividade potencial desejada.

Esse trabalho foi dividido em 3 capítulos:

- O primeiro capítulo contém uma revisão e análise de diversas variáveis que influenciam na produtividade de plantios florestais;
- O segundo capítulo testa diversas configurações de uma Rede Neural Artificial que relaciona as variáveis edafoclimáticas e silviculturais com a produtividade na idade de corte. Ainda, analisa diversas metodologias que ajudam na redução do espaço das variáveis de entrada, o que favorece o número menor de amostras;
- O terceiro capítulo utiliza da melhor configuração da RNA do capítulo anterior e realiza a inversão utilizando o Simulated Annealing. Nele os valores climáticos e edáficos, e a produtividade na idade de corte estão fixos, sendo geradas diversas respostas das variáveis silviculturais para a obtenção da produtividade desejada.

## REFERÊNCIAS

ACHEAMPONG, A. O., & BOATENG, E. B.. **Modelling carbon emission intensity: Application of artificial neural network.** Journal of Cleaner Production, 225, 833-856, 2019.

AL-KAHLOUT, M. M., GHALY, A. M. A., MUDAWAH, D. Z., & ABU-NASER, S. S.. **Neural Network Approach to Predict Forest Fires using Meteorological Data.** International Journal of Academic Engineering Research (IJAER), 4(9), 2020.

ARAÚJO, C. A., SOUZA, P. D. D., ASSIS, A. L. D., CABACINHA, C. D., LEITE, H. G., SOARES, C. P. B., ... & CASTRO, R. V. O. **Artificial neural networks, quantile regression, and linear regression for site index prediction in the presence of outliers.** Pesquisa Agropecuária Brasileira, 54, 2019.

BINOTI, M. L. M. DA S.; LEITE, H. G.; et al. **Prognose Em Nível De Povoamento De Clones De Eucalipto Empregando Redes Neurais Artificiais.** CERNE, v. 21, n. 1, p. 97–105, mar. 2015.

BINOTI, D. H. B.; BINOTI, M. L. M. DA S.; et al. **Modelagem da distribuição de diâmetros utilizando autômatos celulares e redes neurais artificiais.** Cerne, v. 19, p. 677–685, 2013.

CAMPOS, J. C. C.; LEITE, H. G. **Mensuração florestal: perguntas e respostas.** [s.l.] UFV, 2013.

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

CASTRO, R. V. O.; SOARES, C. P. B.; et al. **Crescimento e produção de plantios comerciais de eucalipto estimados por duas categorias de modelos.** Pesquisa Agropecuária Brasileira, v. 48, p. 287–295, 2013.

COSENZA, D. N.; LEITE, H. G.; et al. **Classificação da capacidade produtiva de sítios florestais utilizando máquina de vetor de suporte e rede neural artificial.** Scientia Forestalis, v. 43, n. 108, p. 955–963, 2015.

COSENZA, D. N., SOARES, A. A. V., DE ALCÂNTARA, A. E. M., DA SILVA, A. A. L., RODE, R., SOARES, V. P., & LEITE, H. G.. **Classificação de sítio para povoamentos de eucalipto utilizando redes neurais artificiais baseada em variáveis ambientais e de manejo.** Cerne, 23(3), 310-320, 2017.

DANTAS, D., TERRA, M. D. C. N. S., SCHORR, L. P. B., & CALEGARIO, N. **Machine learning for carbon stock prediction in a tropical forest in Southeastern Brazil.** Bosque, 42(1), 131-140, 2021.

DANTAS, D., RODRIGUES PINTO, L. O., DE CASTRO NUNES SANTOS TERRA, M., CALEGARIO, N., DE OLIVEIRA, R., & LELES, M.. **Reduction of sampling intensity in forest inventories to estimate the total height of eucalyptus trees.** Bosque (Valdivia), 41(3), 353-364, 2020.

DA ROCHA, S. J. S. S., TORRES, C. M. M. E., JACOVINE, L. A. G., LEITE, H. G., GELCER, E. M., NEVES, K. M., ... & ZANUNCIO, J. C.. **Artificial neural networks: Modeling tree survival and mortality in the Atlantic Forest biome in Brazil.** Science of the total environment, 645, 655-661, 2018.

DAVIS, D. T.; CHEN, Z.; et al. **Retrieval of snow parameters by iterative inversion of a neural network.** IEEE Transactions on Geoscience and Remote Sensing, v. 31, n. 4, p. 842–852, 1993.

DE AZEVEDO, G. B., TOMIAZZI, H. V., AZEVEDO, G. T. D. O. S., TEODORO, L. P. R., TEODORO, P. E., DE SOUZA, M. T. P., ... & GUERRA, S. P. S.. **Multi-volume modeling of Eucalyptus trees using regression and artificial neural networks.** Plos one, 15(9), e0238703, 2020.

DIAMANTOPOULOU, M. J.; MILIOS, E. **Modelling total volume of dominant pine trees in reforestations via multivariate analysis and artificial neural network models.** Biosystems Engineering, v. 105, n. 3, p. 306–315, 1 mar. 2010.

DOLÁCIO, C. J. F., OLIVEIRA, R. S., NAKAJIMA, N. Y., JÚNIOR, I. D. S. T., DA ROCHA, J. E. C., EBLING, Â. A., & GAMA, M. A. P.. **Integration of principal component analysis and artificial neural network to modeling productive capacity of eucalypt stands from biophysical attributes.** Forest Ecology and Management, 460, 117862, 2020.

DOLÁCIO, C. J. F., OLIVEIRA, R. S., NAKAJIMA, N. Y., DA SILVA, D. A., EBLING, Â. A., & DA ROCHA, J. E. C.. **Modeling of stored carbon in the trunk of Eucalyptus trees with linear models and artificial neural network.** Advances in Forestry Science, 6(2), 665-671, 2019.

FERRAZ, A. S.; SOARES, V. P.; et al. **Estimativa do estoque de biomassa em um fragmento florestal usando imagens orbitais.** Floresta e Ambiente, v. 21, p. 286–296, 2014.

GORDON, C. **Artificial neural network modeling of forest tree growth.** arXiv preprint physics/9906012, 1999.

GORGENS, E. B.; LEITE, H. G.; et al. **Estimação do volume de árvores utilizando redes neurais artificiais.** Revista Árvore, v. 33, p. 1141–1147, 2009.

GUAN, B. T.; GERTNER, G. **Modeling red pine tree survival with an artificial neural network.** Forest Science, v. 37, n. 5, p. 1429–1440, 1991.

IBÁ. **Relatório 2019.** Disponível em: <<https://iba.org/datafiles/publicacoes/relatorios/iba-relatorioanual2019.pdf>>. Acesso em 31 de outubro de 2021.

INVESTIAGRO. **Setor Florestal batalha para elevar produtividade mas clima atrapalha.** Disponível em: <<http://www.investagro.com.br/setor-de-florestas-batalha-para-elevar-produtividade-mas-clima-atrapalha>>. Acesso em 17 de setembro de 2016.



JIAO, G., & LI, W.. **Neural Network Data Mining Clustering Optimization Algorithm**. IETE Journal of Research, 1-11.2021.

LEITE, R. V., AMARAL, C. H. D., PIRES, R. D. P., SILVA, C. A., SOARES, C. P. B., MACEDO, R. P., ... & LEITE, H. G.. **Estimating stem volume in eucalyptus plantations using airborne LiDAR: A comparison of area-and individual tree-based approaches**. Remote Sensing, 12(9), 1513, 2020.

LU, L., ZHENG, Y., CARNEIRO, G., & YANG, L.. **Deep learning and convolutional neural networks for medical image computing**. Advances in computer vision and pattern recognition, 10, 978-3. 2017.

RAI, A. K., MANDAL, N., SINGH, A., & SINGH, K. K.. **Landsat 8 OLI Satellite Image Classification using Convolutional Neural Network**. Procedia Computer Science, 167, 987-993, 2020.

SAHU, A., HARSHVARDHAN, G. M., & GOURISARIA, M. K.. **A Dual Approach for Credit Card Fraud Detection using Neural Network and Data Mining Techniques**. In 2020 IEEE 17th India Council International Conference (INDICON) (pp. 1-7). IEEE, 2020.

SOCHA, J., NETZEL, P., & CYWICKA, D.. **Stem taper approximation by artificial neural network and a regression set models**. Forests, 11(1), 79, 2020.

SYLVAIN, J. D., DROLET, G., & BROWN, N.. **Mapping dead forest cover using a deep convolutional neural network and digital aerial photography**. ISPRS Journal of Photogrammetry and Remote Sensing, 156, 14-26, 2019.

ZUXING, C., & DIAN, W.. **A prediction model of forest preliminary precision fertilization based on improved GRA-PSO-BP neural network**. Mathematical Problems in Engineering, 2020.



## CAPÍTULO 1: FATORES CLIMÁTICOS, EDÁFICOS, FISIOGRÁFICOS E BIÓTICOS QUE INFLUENCIAM A PRODUTIVIDADE FLORESTAL. UMA REVISÃO.

### 1 INTRODUÇÃO

O meio ambiente de uma planta pode ser definido como a soma de todas as forças externas e substâncias que afetam seu crescimento, estrutura e reprodução. Devido à complexidade desse meio, a interação com a planta e entre os fatores devem ser analisados conjuntamente (Billings, 1952). Mesmo ao analisar individualmente o efeito de um fator no crescimento da planta é necessário lembrar que o meio é uma unidade dinâmica, que reage aos estímulos como um todo (Cooper, 1926). A complexidade das relações entre a análise de difícil visualização, além da dificuldade de obtenção dessas variáveis e dessas relações serem matematicamente complexa (Cain, 1944) (Figura 1). Outro princípio do meio que deve ser analisado é quais são os fatores limitantes, ou seja, quais fatores limitam o crescimento da planta quando estão abaixo ou acima do necessário para aquela espécie (Billings, 1952). Esses fatores variam no tempo e espaço e permitem ou limitam o crescimento das plantas dependendo dos valores dos fatores críticos em determinados períodos de tempo (Billings, 1952). Na Tabela 1 estão os principais grupos de fatores, suas subdivisões e os aspectos que influenciam o crescimento e o desenvolvimento da planta.

O crescimento de um povoamento florestal é resultante das interações dos fatores edáficos, climáticos e geográficos, além dos efeitos de manejo sobre, a área de plantio (Barros et al., 1990).

Neste capítulo estão os principais fatores que agem e influenciam, de modo direto ou indireto, no crescimento de um povoamento florestal com suas interrelações, assim como alguns tipos de manejo ou intervenção nesses fatores objetivando maximizar a produtividade do plantio florestal.

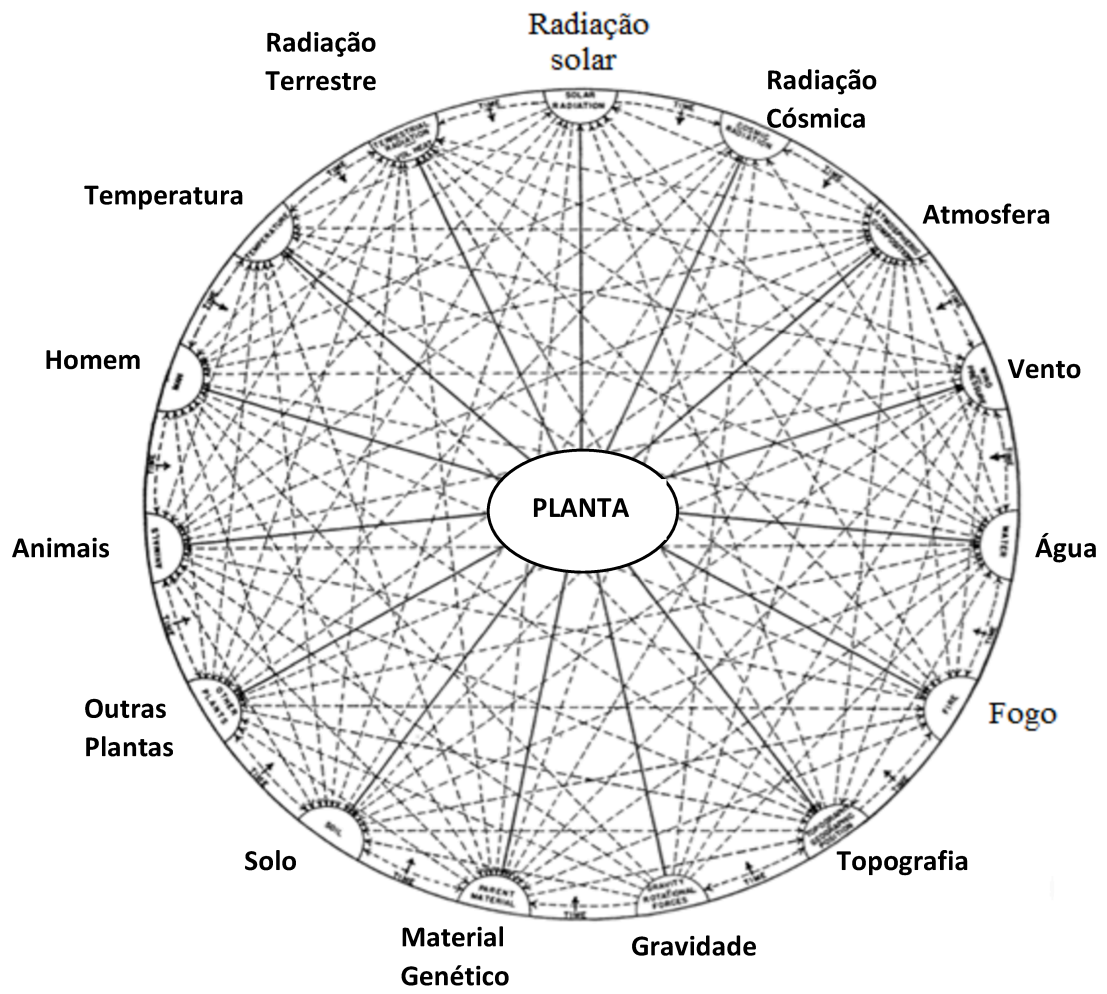


Figura 1 - Diagrama da interação dos fatores do meio (BILINGS, 1964)

Tabela 1 - Grupos de fatores, suas subdivisões e os aspectos do meio que influenciam o crescimento e desenvolvimento da planta (fonte: BILINGS, 1964).

Grupo	Fator	Subdivisão	Aspectos	Grupo	Fator	Subdivisão	Aspectos
Climático	Gases atmosféricos	Pressão	Altitude	Geográficos	Vulcanismo	Efeitos Termais	Temperatura
			Pressão Local			Efeitos Mecânicos	Cinzas
			Ciclones				Lava
		Frequência	Gases				
		Ventos	Força		Erosão e Deposição	Água	Afetam a planta ou mudam outros fatores
			Direção			Neve	
			Agentes Abrasivos			Gelo	
	Ventos						
Edáficos	Material primário	Materiais Ácidos	Minerais		Topografia	Direção de Inclinação	Afetam a planta ou mudam outros fatores
			Estrutura			Ângulo de inclinação	
		Materiais Básicos	Desgaste	Elevação			
	Solo	Prop. Físicas	Perfil	Píricos		Fogo	
			Estrutura		Intensidade		
			Textura		Microclima		
	Mistura do solo						

Grupo	Fator	Subdivisão	Aspectos	Grupo	Fator	Subdivisão	Aspectos					
		Prop. Químicas	Ar			Edáficos	Destruição de matéria Orgânica					
			Argila				Mudança estr. Solo					
			Prop. Básica troca				Erosão					
			pH			Bióticos	Composição Comunidade					
			ânions				Pop. Animal					
			Matéria Orgânica				Luz					
		Prop. Biótica	Flora			<b>Biótico</b>	Outras Plantas	Competição	Água			
			Fauna						Nutrientes			
			Humus						Efeitos Tóxicos			
									Humus			
Geográficos	Gravidade	Efeitos Internos	Efeitos Hormonais	<b>Biótico</b>	Animais			Dependência	Efeitos Físicos			
			Translocação						Efeitos Químicos			
		Efeitos Externos	Dispersão						Cobertura			
			Deslizamentos						Alimentação			
	Efeitos Rotacionais	Força Coriolis	Age sobre outros fatores					Homem			Efeitos Destrutivos	Efeitos no Solo
			Posição Geográfica								Latitude	Age sobre outros fatores
	Longitude											

<b>Grupo</b>	<b>Fator</b>	<b>Subdivisão</b>	<b>Aspectos</b>	<b>Grupo</b>	<b>Fator</b>	<b>Subdivisão</b>	<b>Aspectos</b>
		Distância costeira					Pode modificar quase todos os fatores, pelo menos localmente.

## 1.1 Ventos

O vento é um dos fatores que afetam diretamente o crescimento da árvore e, conseqüentemente, do povoamento. Os efeitos, geralmente visíveis, como a quebra de galhos, envergamento e quebra do fuste, estão muito relacionados ao genótipo e a aceleração do crescimento nas idades iniciais, além do tipo de vento.

Regiões com incidência frequente de ventos fortes tendem a ter espécies com a relação de diâmetro maior que altura, bifurcações no tronco e raízes mais profundas. Características intrínsecas (tamanho da árvore, características da sua copa e sistema radicular) e extrínsecas (grau de exposição ao vento, condições ambientais locais etc) são determinantes para resistência ou susceptibilidade das árvores à ação dos ventos (Nielsen, 2005), tendo influência na taxa de crescimento, forma da árvore, taxa de transpiração e resistência mecânica dos troncos (Telewski, 2006).

Em baixa intensidade, os ventos podem carregar moléculas de vapor d'água para as folhas, favorecendo as trocas gasosas e sua refrigeração (Zeiger, 2004), promovendo assim aumento na produção (Ataíde et al., 2015). Em maiores intensidades, promove aumento na transpiração prejudicando o crescimento das plantas (Dixon e Grace, 1984), além de modificar as características da madeira quanto a resistência, desfolhamento e produzir quebra ou arranque das árvores. Quando as árvores são tombadas, quebradas ou arrancadas ocorre a perda de dominância apical, com conseqüente perda na produção (Rosado, 2006), enquanto as árvores inclinadas podem retornar ao seu aspecto normal, desde que cesse o evento climático prejudicial. Além disso tais danos elevam os custos de colheita e reduzem o preço da madeira devido sua qualidade.

Em florestas juvenis e povoamentos com crescimento rápido, o impacto e os danos econômicos provocados pelos ventos é particularmente mais severo, uma vez que, a madeira nesta fase é quase totalmente constituída por alburno, o que pode ocorrer a inclinação das mudas (Talkkari et al., 2000). Além disso, os mesmos autores relatam que, os ventos podem causar maiores danos em locais adjacentes às áreas onde houve corte raso ou desbaste das árvores vizinhas, considerando-se que as árvores restantes ainda não estão aclimatadas aos ventos da região (Talkkari et al., 2000).

Conforme Ataíde (2015), ventos horizontais sobre a parte exposta da árvore, gera uma combinação de torques por torção e flexão na base desta, e, caso esse torque seja



maior que a resistência do sistema de enraizamento da árvore ou o seu sistema radicular se apresenta pouco desenvolvido, ocorre o arrancamento da mesma.

Fatores que favorecem a interação com o vento:

- **Solo:** profundidade, drenagem e estrutura se relacionam quanto a ancoragem do sistema radicular. Os ventos também causam aumento da evaporação da umidade do solo, que pode favorecer a queda de árvores.
- **Topografia:** colinas e lugares com estreitamento do vale possuem maior exposição a ventos fortes.
- **Características da árvore:** Sistema radicular não adaptado a região de plantio (solos saturado resultam em sistemas radicular pouco estruturado), relação raiz/parte aérea (quanto menor, mais susceptível ao vento), altura, diâmetro e forma do tronco, tamanho e forma da copa (maiores densidades de copa tendem a ser mais vulneráveis aos ventos), relação altura/diâmetro (quanto menor mais estável), plasticidade (capacidade de adaptar ao ambiente) e elasticidade (quantidade de força necessária para provocar danos a estrutura da árvore) da espécie, material genético (inclinações de tronco elevadas, ocos, baixa resistência a patógenos e danos na casca).
- **Povoamento:** Densidade e distribuição das árvores, desramas e desbastes, mecanização das operações.

Efeitos sobre a floresta:

- Diminuição da transpiração, com fechamento dos estômatos, fazendo com que haja diminuição da fotossíntese.
- Aumento da evaporação.
- Redução do status hídrico das plantas (Satoo, 1962).
- Redução do fluxo de seiva,
- Produção de lenho de reação (Sousa, 2004) (formação de anéis assimétricos devido ao aumento da atividade cambial para estabilizar o tronco).

## 1.2 Água

A água participa de todos os processos fisiológicos e bioquímicos na planta, além de participar na nutrição mineral das plantas, pois os nutrientes são absorvidos pelas raízes em solução aquosa. A disponibilidade de água também é um dos maiores fatores que afetam a produtividade da floresta, influenciando a fotossíntese, a disponibilidade de nutrientes do solo para a planta e outros fatores (Gholz et al., 1990).

Existe uma grande relação entre a distribuição dos maiores biomas e a precipitação e temperatura, que influenciam a evapotranspiração e a quantidade de água disponível para as plantas (Zobel et al., 1976). O nível de precipitação de uma região determina o tipo de vegetação: em locais com alta precipitação, as plantas devem ser adaptadas ao clima úmido e solo encharcado por água (Kumar, 2018).

O balanço hidrológico é o movimento das águas dentro do ambiente. Esta contabilidade representa a quantidade de chuva de uma determinada região, que representa a disponibilidade hídrica, subtraída das águas que sofrem infiltração nos solos e/ou evapotranspiração, do escoamento e da interceptação de água pelo dossel. Com exceção da precipitação, os demais processos são bastante influenciados pela densidade de plantas, pelo tipo de solo, pelo comportamento fisiológico da planta e pela estrutura e arquitetura do dossel (Almeida e Soares, 2003).

O conjunto de perdas evaporativas de uma dada área vegetada recebe o nome de evapotranspiração e engloba três componentes: a evaporação direta (da água do solo, de superfícies líquidas, do orvalho depositado nas folhas, etc.), a transpiração e a interceptação. A evapotranspiração é enormemente controlada por condições meteorológicas, isto é, sua taxa pode ser calculada a partir de dados de energia solar, velocidade do vento, temperatura do ar, umidade atmosférica e outros dados climáticos (Lima, 2008).

A interceptação das chuvas tem efeito significativo sob o recebimento e redistribuição das chuvas. Pela interceptação, a floresta causa uma diminuição no total de chuva que atinge a superfície do solo, sendo que essa redução pode chegar a 25% da precipitação anual (Linsley et al., 1949). Durante o período chuvoso, ela pode fazer parte juntamente com a transpiração e evapotranspiração na perda de água do ecossistema (Rutter, 1968). Quando a copa das árvores de uma floresta está molhada,

verifica-se que a evaporação ocorre em taxas maiores do que a taxa normal de transpiração, representando uma perda significativa do total de água (Singh and Szeicz, 1979).

A evaporação é o processo de conversão de água no estado líquido em vapor, no qual depende de vários fatores ambientais como temperatura da água e do ar e ventos. A evaporação direta é reduzida drasticamente pela floresta, pois auxilia na redução de temperatura do microclima local e com isso aumento da infiltração da água no solo. No entanto há um aumento do processo de transpiração.

A transpiração é essencialmente um processo de evaporação, mas há um controle biológico da transpiração, ou seja, o controle que a própria planta exerce sobre a transpiração, através da dinâmica de seus estômatos. A transpiração é influenciada por diversos fatores: clima, solo, idade da floresta, disponibilidade de água no solo, e a própria espécie florestal (Balbinot et al., 2008).

Conforme Rutter (1968), apenas uma fração da água absorvida contribui para a produção de matéria seca. Como exemplo, de 1000 mm anual e um incremento médio anual de 20 t/ha, apenas cerca de 1,2 mm deste consumo fica fixado quimicamente nesta produção. No entanto ela é o mecanismo que reduz a perda de nutrientes no solo (Gates, 1980).

A água afeta a fotossíntese em duas formas: pelo solo, que determina a energia que é gasta para o transporte da água, e pela atmosfera. Ambos afetam a condutância dos estômatos e mesófilo. E no mesófilo que ocorrem os principais processos fisiológicos dos vegetais, aporte dos minerais trazidos do solo pelo xilema e convertidos em moléculas orgânicas, onde ocorrem as trocas gasosas entre as células e a atmosfera e de onde parte a água destinada à transpiração efetuada pelos estômatos. Estudos mostram que déficit de água podem fazer com que o processo de fotossíntese nas plantas seja interrompido e com isso o ganho de carbono reduzido, diminuindo a produtividade (Balbinot et al., 2008; Baldocchi, Verma e Anderson, 1987).

A água também tem efeito no crescimento de folhas, no qual em períodos de déficit, tem a produção reduzida e aumento da queda de folhas, reduzindo a área fotossintética e taxa de fotossíntese por unidade de área foliar (Santos e Carlesso, 1998).

Esse parece ser um mecanismo para conservação de água. Whitehead e Beadle (2004) elucidam melhor todos os processos fisiológicos que são influenciados pela água.

A medida que inicia o estresse hídrico, aspectos da anatomia, morfologia, fisiologia e bioquímica são afetados (Santos e Carlesso, 1998). Culturas florestais tendem a manifestar alta sensibilidade à competição por água, luz e nutrientes, principalmente com espécies de rápido crescimento, como gramíneas (Da Silva et al., 1997).

Ryan (2010) demonstrou que maiores disponibilidades de água aumentaram a produtividade em quase 18 % e elevaram em 11 % a eficiência fotossintética de florestas de eucalipto em quatro regiões do Brasil. Já o trabalho de Stape (2010), verificou um aumento de 30% na produtividade da floresta quando esta foi irrigada nos primeiros anos após o plantio. Martinkosky et al. (2015) verificaram correlação positiva entre precipitação e produtividade de diversas espécies arbóreas de clima tropical.

Um excesso de água pode ser prejudicial para o crescimento devido à falta de aeração das raízes, o que afeta seu crescimento e funcionamento, e, por conseguinte, a absorção de minerais (Wilsie, 1962).

### 1.3 Temperatura e clima

A fonte primária da temperatura é a radiação solar, sendo um dos fatores decisivos para o crescimento da planta (Campos, 1970), influenciando quase todas as atividades da planta, além da disponibilidade de luz e água. Ela pode variar dependendo da altitude, latitude, estação do ano e período do dia. A temperatura influencia fisiologicamente as plantas, afetando o crescimento, podendo ser tanto diretamente, afetando a fotossíntese e respiração, quanto indiretamente, alterando o funcionamento dos estômatos. A temperatura também pode afetar a produção de flores, frutos, sementes e folhas (Kozlowski e Pallardy, 1997).

A influência da temperatura e precipitação sobre a distribuição e o crescimento das florestas é demonstrada pela alta correlação existente entre esses aspectos e as classificações climáticas, como as feitas por Merriam, Köppen e Thornthwaite (Spurr e Barnes, 1973). A temperatura é o fator que determina a eficácia da precipitação. Kumar (2018) diz que chuvas fracas em climas quentes e secos não afetam o teor de umidade

do solo, pois a água não desce até as raízes e evapora rapidamente da superfície do solo e que chuvas fortes de curta duração também podem ter pouco efeito na umidade do solo.

Baixas temperaturas afetam diretamente as plantas limitando a energia para processos bioquímicos, diminuindo a permeabilidade das membranas e aumentando a viscosidade do protoplasma, enquanto altas temperaturas podem desnaturar ou tornar inativas enzimas e reduzir as reservas de carboidratos devido ao aumento da respiração (Aber et al., 2001). Indiretamente, a mineralização, decomposição e função das raízes decrescem à medida que o solo fica seco ou saturado de água (relação direta com a temperatura e umidade) (Riley e Vitousek, 1995).

A elevação da temperatura dentro de um limite ótimo pode aumentar a taxa fotossintética das folhas, por acelerar a atividade das enzimas neste processo. Nesse limite ótimo há o favorecimento de uma absorção mais rápida pelas raízes das soluções nutritivas do solo (Dias, 2009). No entanto, sob temperaturas mais elevadas, pode ocorrer a inibição dessas enzimas (Dias, 2009), fechamento dos estômatos, aumento da respiração, redução na evaporação (Costa e Foley, 2000), redução da assimilação de carbono devido ao decréscimo na relação  $O_2/CO_2$  (Hall e Keys, 1983), intensificação dos efeitos foto inibitórios da luz (Kitao et al., 2000) e desnaturação de proteínas. Alves (2004) afirma que temperaturas acima de  $32^\circ C$  influencia negativamente na fotossíntese.

Já diminuição da temperatura tem forte relação com a respiração (Clark et al., 2003), pois com a abertura dos estômatos há maior entrada de  $CO_2$ . No entanto, a velocidade dos processos enzimáticos é diretamente influenciada pela temperatura. Baixas mais drásticas, como as geadas podem causar perda de até 100% das espécies susceptíveis, congelando os líquidos presente nos espaços intercelulares e extravasamento do citoplasma. Higa et al. (1997) observaram que danos indiretos são mais frequentes, podendo restringir a produtividade da planta e torna-la mais susceptível a infecção por patógenos.

## 1.4 Radiação

A radiação solar é considerada a fonte primária dos processos fotossintéticos, mas também influenciam no fototropismo e na temperatura, com seus efeitos agindo através da intensidade, qualidade e duração (Campos, 1970). Juntamente com o CO<sub>2</sub> são produzidos carboidratos e produtos vegetais, estes últimos somente quando há uma maior proporção de fotossíntese em relação a respiração, o que promove o crescimento da planta (Wilsie, 1962). À medida que a planta cresce, há uma demanda maior de radiação para seus processos.

A radiação é sujeita a flutuações na intensidade, variando de acordo com a altitude, latitude, estação do ano e condições climáticas (Kumar, 2018). As plantas também são tolerantes a diversos níveis de intensidade, sendo capazes de sobreviver em baixa intensidade ou requerendo grandes intensidades para crescer e sobreviver, sendo importantes para a sucessão de uma floresta nativa. Intensidade excessiva provoca aumento da transpiração e com isso a diminuição de água no interior do mesófilo (Wilsie, 1962).

Em relação a duração, fotoperíodos curtos podem promover a queda e até interrupção do crescimento de algumas espécies. Downs (1962) realizou um experimento em que demonstrava que espécies do gênero *Larix* e *Pinus* cessam seu crescimento com foto-períodos menores que 14 horas. Outros trabalhos relatam que certas espécies de *Pinus* podem crescer continuamente se receberem luz durante as 24 horas do dia (Amaral Machado et al., 2010).

Uma floresta absorve de 60 a 90% da radiação solar incidente, dependendo essencialmente da densidade e do desenvolvimento foliar (Hernandes, 2004). Para uma floresta densa e bem desenvolvida, a absorção varia de 75 a 90%; para um povoamento de densidade baixa e copa mal desenvolvida a absorção é de aproximadamente 60% (Bartelink, 1998). Essa quantidade de radiação absorvida promove um dos grandes efeitos da floresta sob o clima. Isto se reflete, por exemplo, na redução de até 6°C na temperatura do ar dentro da floresta no verão (Bartelink, 1998).

Esta radiação absorvida é dissipada de acordo com a equação do balanço de energia. Parte é convertida em calor sensível, que aquece a copa, e aquece o ar. A maior parte, todavia, é consumida no processo de evaporação. Como já afirmado, uma fração

diminuta é utilizada na fotossíntese (De Paula Lima, 1996).

### 1.5 Composição Atmosférica

Os principais gases que compõem a atmosfera são vapor d'água, oxigênio, dióxido de carbono e nitrogênio. Esses gases geralmente não variam consideravelmente entre os ambientes, no entanto, podem haver partículas de poeira, fumaça, microrganismos, e gases poluentes e resultantes da decomposição de material orgânico (Guimarães, 2017).

A umidade é um fator importante que afeta a vegetação, pois modifica a estrutura, a forma e a transpiração das plantas. Em temperaturas mais altas, a umidade relativa é baixa e a água rapidamente evapora, aumentando, a taxa de transpiração. A umidade é máxima próximo ao equador e declina próximo dos polos e é diretamente afetada pela temperatura e latitude (Kumar, 2018).

O oxigênio é produzido durante o dia pelas plantas verdes e usado na respiração de todos os organismos na produção de energia. Na respiração há a liberação de  $\text{CO}_2$  que é usado pelas plantas na fotossíntese. Há também o ozônio na atmosfera, responsável por filtrar os raios ultravioletas do sol, nocivos aos seres vivos, no entanto, altas concentrações podem ser danosas as plantas (Kozłowski e Pallardy, 1997).

O dióxido de carbono representa apenas 0,03% da atmosfera, sendo o principal componente para a realização da fotossíntese nas plantas. A respiração e queima de matéria orgânica são as fontes de  $\text{CO}_2$  (Nobre e Nobre, 2002).

Nitrogênio representa a maior porcentagem da atmosfera, representando quase 79% e sendo responsável pela síntese de aminoácidos essenciais para os seres vivos. No entanto, o nitrogênio atmosférico é inerte, sendo necessário sua transformação para se tornar disponível para as plantas através de atividades microbianas, fixação eletroquímica, fixação industrial e fixação biológica de nitrogênio (Kumar, 2018).

Experimentos mostram uma elevação no crescimento das plantas sob aumento de  $\text{CO}_2$  disponível, devido ao aumento da fotossíntese e redução da fotorrespiração (Long et al., 1996) pelo menos em um curto período (Kozłowski e Pallardy, 1997). Em longos períodos, esse crescimento reduz devido as limitações de nutrientes e água e inibição devido ao acúmulo de produtos fotossintéticos (Bazzaz, 1990; Curtis e Wang, 1998).

Johnson et al. (1998) observou variações de 0% a 1000% no crescimento da planta devido a nitrogênio disponível no solo com o aumento de CO<sub>2</sub> disponível. Já Curtis e Wang (1998) avaliou que o CO<sub>2</sub> contribuiu com 31% a mais de ganho no crescimento em condições ótimas de nutrição. A eficiência do uso da água é maior devido ao aumento de sequestro de carbono do ar em relação a perda da água da planta. Em relação a luminosidade disponível, trabalhos sugerem que em baixas condições de luz favorecem as respostas a concentração de CO<sub>2</sub> (Curtis e Wang, 1998). Outras alterações incluem baixas concentrações de N e altas concentrações de metabólitos provenientes da fotossíntese, que podem influenciar a resistência da planta a pragas e ataques de herbívoros (Williams et al., 1998).

Aumento do CO<sub>2</sub> na atmosfera age indiretamente em dois fatores importantes para as plantas: a deposição de nitrogênio e concentração de ozônio na atmosfera. A formação de ozônio na superfície da Terra está ligada com a quantidade de óxido de N (Aber et al., 2001). A deposição de Nitrogênio tem aumentado devido ao aumento de temperatura e atividades humanas e sua disponibilidade está diretamente relacionada com a produtividade das florestas. No entanto, os efeitos negativos estão na acidificação do solo (retenção de íons de nitrato no solo), desbalanceamento nas relações N:Mg, e Ca:Al nas folhas e redução na fotossíntese (Aber et al., 1995). Já o ozônio resultante da combustão de combustíveis fósseis está presente em regiões de alta industrialização e densamente populado, é altamente reativo e a sua formação requer a presença do óxido de nitrogênio, hidrocarbonetos e radiação solar (Aber et al., 2001). Por ser altamente oxidante, ele pode causar danos as membranas celulares, fazendo com que a planta gaste energia a reparando e reduzindo a fotossíntese (Tjoelker et al., 1998).

Gases da poluição como SO<sub>2</sub>, NO<sub>2</sub> e NH<sub>3</sub> são convertidos em partículas de sulfato, amônia e gases como HNO<sub>3</sub> e afetam as plantas causando danos nas cutículas, acumulam nos cloroplastos e a regulação de pH e a fotossíntese (Zhao et al., 2021). No solo, a longo prazo, causam acidificação do meio, fazendo com que a disponibilidade de nutrientes seja menor (Zhao et al., 2021).

As teorias apontam que as atividades humanas, em especial as emissões dos chamados gases de efeito estufa (GEE) em quantidades maiores do que a natureza pode assimilar, como a principal causa das mudanças no clima (Baesso et al., 2010). Estudos



têm demonstrado que mudanças na concentração de dióxido de carbono atmosférico e no clima influenciarão a produção, o consumo e o comércio internacional de produtos de madeira por meio de efeitos no crescimento das árvores (Perez-Garcia et al., 2002).

## 1.6 Fogo

Os incêndios podem provocar danos econômicos e ecológicos nos ecossistemas florestais, como a perda de rendimento em povoamentos de produção ou alterações no solo e nas comunidades vegetais. A rapidez de recuperação dos ecossistemas depende da severidade do fogo, das condições meteorológicas verificadas após o fogo, das características da vegetação, do solo, da topografia e da gestão subsequente (Silva et al., 2007).

Silva (2007) no seu trabalho, verificou que a mortalidade é influenciada pela rotação e estágio de desenvolvimento do povoamento. Nele foi recolhido dados após o incêndio que ocorreu em 2003 em um plantio em Portugal e observou-se que a mortalidade das árvores foi total nos povoamentos jovens e crescente com idades mais . Povoamentos jovens ainda possuem grande quantidade de material combustível no solo de exploração anterior e de roçadas, além da copa das árvores estarem próximas desse material combustível (Silva et al., 2007). À medida que a árvore se desenvolve, a altura da copa a protege da ação direta das chamas, além de promover uma descontinuidade vertical do combustível, pois incêndios de copa são raros em povoamentos adultos, sendo observados apenas em encostas de fortes declives (Heringer e Jacques, 2001). O aumento da espessura da casca também favorece a sobrevivência da população (Heringer e Jacques, 2001).

Além da queda direta da produtividade da floresta, com a estagnação do crescimento ou até mesmo retirada do volume de árvores mortas pelo fogo, os incêndios florestais promovem alterações no solo, aumentando a erosão e o escoamento superficial das águas, afetando o balanço hidrológico do meio (McIver, 2000).

Quando as árvores dos povoamentos estão com dimensões comerciais, geralmente são feitas sua exploração no pós fogo, pois a madeira morta ainda possui

interesse comercial. No entanto quando a área afetada pelo fogo é superior a demanda da madeira, nem todas as áreas são exploradas (Silva et al., 2007).

No caso de plantio de Pinus, Shakesby et al. (1996) sugere que a exploração não seja efetuada antes de 12 semanas, pois a queda das acículas após o incêndio promove uma cobertura no solo capaz de proteger contra erosão. Já nos plantios de eucalipto, Valejo e Alloza (2006) sugerem que sejam feitas logo após o fogo, pois ajuda na recuperação e reabilitação do povoamento, devido a capacidade de brotação da espécie. Em ambos são sugeridos o corte raso para evitar um povoamento irregular e a difícil exploração.

Thomas et al. (2000) analisou a perda de nutrientes em povoamentos atingidos pelo fogo e verificou que houve elevada perda de nutrientes por dissolução na água de escoamento superficial e por absorção nos sedimentos arrastados.

Em todos os casos, a aplicação de técnicas silviculturais como subsolagem e disposição dos resíduos pós colheita reduziram as taxas de erosão do solo (Shakesby et al., 1993; Shakesby et al., 1994; Shakesby et al., 1996) e perda de nutrientes (Thomas et al., 2000).

## 1.7 Topografia e relevo

A topografia afeta principalmente variações espaciais de clima e água no solo, sendo relacionada com a produtividade dos ecossistemas (Chen et al., 2007). Muitas vezes é evidente o efeito do relevo sob o clima: os cumes são quase sempre com temperaturas mais baixas, a pressão atmosférica é menor, a velocidade dos ventos umidade relativa e intensidade luminosa maiores que as regiões mais baixas (Chen et al., 2007). As partes mais baixas também possuem solos mais férteis do que as encostas, devido ao processo erosivo sofrido pelos solos que ocorrem nesta região (Campos, 1970). Essas mudanças nas condições climáticas também provocam mudanças no padrão de vegetação. A partir da base das colinas, o padrão de vegetação muda de tropical para temperado, taiga, tundra e polar (na região totalmente coberta de neve) (Kumar, 2018) (FIGURA 02).




Figura 2 - Padrão de vegetação em relação a altitude  
 (Fonte: <http://www.biologydiscussion.com/plants/growth-of-plants/ecological-factors-that-affect-the-growth-of-plants-with-diagrams/15288>)

A inclinação do relevo também traz variações na quantidade de água, radiação e características do solo (Pissara et al. 2004). A inclinação da encosta determina a rapidez com que a água flui para fora da superfície, o grau de umidade da superfície do solo, a quantidade de matéria orgânica no solo, a intensidade com que os raios solares podem aquecer a superfície do solo e a densidade e altura até a qual a vegetação pode ocorrer (Kumar, 2018). A direção da inclinação determina a precipitação do local. As cadeias montanhosas orientam o vento em direções definidas, captam a umidade do vento em certos lados e condensam vapores aquosos na forma de nuvens e chuvas na região superior, assim, em certos lados rica vegetação é encontrada, enquanto o outro lado da montanha com menor altura, tem apenas vegetação xerofítica (Kumar, 2018).

Em baixas altitudes, onde a vegetação é mais diversa, Little (2007) verificou que a competição nos plantios florestais por outras espécies invasoras acontece mais cedo do que em altitudes mais altas. Também foi observado que nessas regiões, o preparo do solo por queima não teve influência.

## 1.8 Solo e fertilidade

O solo é um dos principais fatores que influencia no crescimento das plantas (Rigatto et al., 2005), o qual está relacionado com a disponibilidade de nutrientes (fertilidade e aeração do solo) e água, além de ancoragem para a planta (Da Silva, 2021). O solo pode influenciar a germinação das sementes, tamanho e vigor das plantas e do sistema radicular, formação de madeira, a susceptibilidade de patógenos, formação de frutos e flores (Kumar, 2018). Esse é um dos fatores que podem ser melhorados e modificados a fim de se obter um melhor crescimento e produtividade através do preparo do solo e adubações subsequentes (Kumar, 2018). No entanto, é importante salientar que o emprego de fertilizantes sem outras técnicas de implantação e manejo florestal pode não fornecer os resultados esperados (Gonçalves et al., 2000).

A textura do solo é a propriedade que influencia a capacidade de suprimento de água e nutrientes para a planta (Gonçalves et al., 1990). Para Ralston (1964) o crescimento das árvores se eleva com o aumento do teor de silte e argila, devido a um maior suprimento de água e nutrientes, até um ponto em que o acréscimo de partículas finas compromete a aeração do solo. Conseqüentemente, admite-se que o potencial de crescimento das florestas apresenta uma resposta curvilínea relativamente ao acréscimo dos teores de silte e argila em áreas com solos bem drenados, mas com amplas variações texturais (Gonçalves et al., 1990). Teores de argila no solo são utilizados para classificar sítios em plantios de Pinus no Paraná (de Carvalho et al., 1999). Partículas mais grossas (areia) favorecem a penetração da água, no entanto não possuem capacidade de retenção e armazenamento de umidade do solo (Aguiar, 2008).

A profundidade efetiva do solo também influencia no suprimento de água e no livre crescimento do sistema radicular (Lepsch et al., 2015). Geralmente, o potencial de crescimento da floresta apresenta uma relação direta com a profundidade efetiva do solo, notoriamente nas áreas em que os solos apresentam balanços hídricos com elevadas deficiências hídricas (Gonçalves et al., 1990).

O preparo do solo objetiva disponibilizar quantidades suficientes de água e nutrientes para a planta, visando o rápido crescimento do sistema radicular e também eliminando plantas indesejáveis que competem com as mudas (Gatto et al., 2003). Há indicações de trabalhos que sugerem uso de técnicas menos intensivas (Gonçalves et

al., 2000), passando pelos processos tradicionais com a queima dos resíduos da rotação anterior (Lazari, 2001), até preparos intensivos em áreas onde a mecanização se torna difícil devido a rotações anteriores. Gatto (2003) observou que as maiores produtividades foram obtidas em regiões onde houve um preparo mais intensivo das áreas, tendo um decréscimo à medida que era menos intenso. No entanto os solos com preparo mínimo eram os que tinham melhores características químicas e de matéria orgânica, havendo menor exportação de nutrientes do solo.

Quanto as propriedades químicas, há evidências de interação entre água e nutrientes e o crescimento das plantas. Santana (2008) cita que foram estudadas com *Pinus radiata* (Raison et al., 1992), com *E. globulus* (Pereira et al., 1994) e respostas positivas à adição de diferentes nutrientes e, ou, às suas interações com a água têm sido relatadas para plantios de eucalipto no Brasil (Barros et al., 2008; Stape et al., 2004). No seu trabalho, ele verificou que a produção de biomassa pela floresta estava positivamente relacionada com a disponibilidade de água e conteúdo de nutrientes do solo. E há uma menor resposta à aplicação de fertilizantes após os 4,5 anos, além de que a maior parte dos nutrientes estão na casca, sendo recomendado a colheita apenas do lenho para evitar a exportação de nutrientes (Barros et al., 2008).

Gonçalves (1990) observou que as propriedades do solo: pH, teor de matéria orgânica, teor de fósforo disponível, nitrogênio total, teor de potássio, cálcio e magnésio trocável, em ordem decrescente de frequência, são as propriedades químicas do solo que mostram as melhores correlações com o crescimento da maioria das espécies.

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 ( de Freitas, 2017). A economicidade da aplicação de fertilizantes é determinada pela relação benefício/custo, com a análise de diversos parâmetros que definem o aumento da produtividade (altura, dap, homogeneidade, conicidade do fuste, qualidade da madeira) ( Freitas, 2017).

## 1.9 Genótipo

As principais características do melhoramento genético das espécies florestais estão associadas ao aumento da produtividade (volume de madeira, celulose e biorredutor por área e tempo), adaptação ao ambiente, principalmente ambientes estressantes e a melhoria da qualidade da madeira para seus diferentes usos (de Assis et al., 1996). A maneira mais fácil e prática de obter ganhos em relação a uma característica é praticar a seleção diretamente sobre esta, mas ao praticar essa seleção, podem ocorrer modificações em outras, cujas a magnitude dessa variação depende da associação entre elas (Paula et al., 2002). No entanto na maioria das vezes o melhoramento visa a melhoria de múltiplas características (Paula et al., 2002).

No melhoramento para celulose, Tolfo et al. (2005) observou estimativas de herdabilidades, no sentido amplo, de 67% para volume de celulose, 84% para teor de lignina e 56% para densidade básica da madeira. Estas estimativas de herdabilidade indicam predominância dos efeitos genéticos (aditivos e dominantes) no controle das principais características de qualidade da madeira (Tolfo et al., 2005).

Para a fabricação de biorredutores, características como alta densidade da madeira e a resistência mecânica e granulometria são desejadas (Galvan, 2018). Assis (1996) cita que a utilização de espécies de eucalipto para a fabricação de biorredutores teve seu início baseada em espécies de alta densidade, como *C. citriodora*, no entanto essa espécie possui baixa produtividade. Atualmente são pesquisadas melhoria de materiais genéticos com maior densidade e produtividade elevada como *E. camaldulensis*, *E. tereticornis*, *E. brassiana*, *E. resinifera*, *E. pellita* e *E. paniculata* e também pelo Gênero *Corymbia* (de Assis et al., 2015).

Na utilização de madeira para fins de produção de energia, o critério utilizado é a densidade da madeira, teor de lignina e volume. De modo geral as espécies e híbridos utilizados para biorredutores são os mesmos para produção de energia ( de Assis et al., 1996).

No melhoramento visando serraria, devido às restrições na utilização de florestas nativas, o Eucalipto tem sido uma opção para o abastecimento, pois possuem atributos de elevada capacidade produtiva, adaptabilidade e requisitos tecnológicos (de Assis et al., 1996). No entanto a maioria dos plantios visam essa utilização como secundários,

utilizando povoamentos em idades mais avançadas. Problemas como madeira juvenil, colapso, nós, empenamento e resinas são os principais alvos no melhoramento genético para essa finalidade ( de Assis et al., 1996).

Em relação ao uso de melhoramento visando adaptação aos fatores abióticos, o foco principal são genótipos resistentes a déficit hídrico, geadas, ventos e variações de temperatura (de Assis et al., 2015).

Os fatores bióticos, como pragas e doenças, que causam danos econômicos as plantações, também podem ser combatidos utilizando melhoramento genético das espécies a serem plantadas (de Assis et al., 2015). As principais doenças de folhas, que afetam plantios de eucalipto no Brasil, são a ferrugem (*Puccinia psidii*), a mancha foliar e a desfolha por *Cylindrocladium pteridis* e a bacteriose (*Xanthomonas axonopodis*) (Fonseca, 2010). Dentre as fontes de resistência à ferrugem do eucalipto (*Puccinia psidii*) estão as espécies *Corymbia citriodora*, *C. torelliana*, *E. camaldulensis*, *E. microcorys*, *E. pellita*, *E. pilularis*, *E. propinqua*, *E. resinifera*, *E. robusta*, *E. saligna*, *E. tereticornis* e *E. urophylla* (Alfenas et al., 2004). As espécies *E. pellita*, *E. robusta* e *E. resinifera* têm apresentado altos níveis de resistência à *Cylindrocladium* na Região Norte do Brasil. Em relação a doenças do tronco, o cancro (*chysoporthe cubensis*) e murcha de *ceratocystis* (*ceratocystis fimbriata*), sendo as espécies mais resistente ao cancro, são *Corymbia citriodora*, *C. torelliana*, *E. cloeziana*, *E. pilularis*, *E. paniculata*, *E. pellita*, *E. urophylla*, *E. robusta*, *E.resinifera* e *E. microcorys* (Alfenas et al., 2004).

Ressalta-se que, para se ter maior eficiência na produção de árvores com maior potencial de resistência às enfermidades, tanto de folhas quanto de tronco, é necessário desenvolver programas de seleção de genitores resistentes, de forma a realizar a introgressão de genes de resistência nas populações de melhoramento (de Assis et al., 2015).

É importante salientar que os testes de melhoramento são realizados em diferentes ambientes antes da recomendação final pois ainda há a interação genótipo e ambiente do qual não se tem informações prévias da magnitude dessa interação (Sudarić et al., 2006).

## 1.10 Doenças

Os plantios florestais podem ser afetados por diversos patógenos, desde a fase de semente e viveiro até os plantios adultos, sendo agravado por condições favoráveis que permitem a maior reprodução e disseminação dos patógenos e em todo grau de ataque há geração de danos negativos na produtividade (Dos Santos et al., 2001).

As doenças em viveiro causam a morte na fase de germinação e de plântulas, reduzindo o número de mudas, sendo que os fungos e as bactérias são responsáveis pela maioria das enfermidades (Dos Santos et al., 2001). Alta umidade relativa do ar e substrato, elevada temperatura, substratos e água utilizada para a irrigação contaminados são as principais condições favoráveis para as doenças (Dos Santos et al., 2001). Como estratégias de controle estão o uso de proágulo livre de patógenos, substratos com boa drenagem, adubação equilibrada, utilização de sistema de irrigação adequado, aplicação de fungicidas e fumigantes, solarização e uso de controle biológico (Dos Santos et al., 2001). Tombamento de mudas (*Cylindrocladium candelabrum* Viégas, *Fusarium* sp., *Phytophthora* sp., *Pythium* sp. e *Rhizoctonia solani* Kuhn.), mofo cinzento (*Botrytis cinerea* Pers.), Oídio (*Oidium* sp.) e podridão de raiz (*Phytophthora* sp., *Pythium* sp. e *Fusarium* sp.) são alguns exemplos de doenças que acometem viveiros (Dos Santos et al., 2001).

As doenças em plantios adultos ocorrem quando as mudas já estão estabelecidas em campo. Podem ser divididas em doenças de tronco e hastes e doenças de folhas (Dos Santos et al., 2001).

Nas doenças de tronco como cancro do eucalipto (*Cryphonectria cubensis* (Bruner) Hodges (anam. *Endothiella* sp.)), e Valsa ceratosperma ocorrem quando as plantas em campo estão sob algum fator de estresse: temperaturas acima de 28°C, elevado índice de umidade relativa do ar e longos períodos de molhamento foliar (Dos Santos et al., 2001). Já nas doenças de folhagem as principais estão as manchas de *Cylindrocladium* (*Cylindrocladium candelabrum* Viégas), Oídio (*Oidium* sp.), *Coniella* (*Coniella* sp.), Micosferela (*Mycosphaerella* sp.) e *Phaeoseptoria* (*Phaeoseptoria* sp.) (Dos Santos et al., 2001). Os fatores que favorecem essas doenças são o contato entre plantas doentes e sadias, pelo vento ou respingos de chuva e irrigação (Dos Santos et al., 2001).



Há ainda as doenças, classificadas como complexos etiológicos, que são causados por um ou mais fatores abióticos seguidos pela ação dos patógenos (Dos Santos et al., 2001). A seca de ponteiros (deficiência de boro, deficiência hídrica e patógenos como *Botryosphaeria ribis* (*B. dothidea*), *B. rhodina* (Cooke) von Arx, *Dothiorella* sp. ou *Fusicoccum aesculi* (anamorfo de *B. ribis*) e *Botryodiplodia theobromae* Pat. (anamorfo de *B. rhodina*)), a seca de saia (baixa relação de ferro e manganês, pH inferior a 4, temperaturas baixas e chuvas intensas) e podridão do cerne (infecção por himenomicetos) são alguns dos exemplos (Dos Santos et al., 2001).

Para o controle dessas doenças, a principal medida é a utilização de populações resistentes e aumento da qualidade dos sítios (adubação, calagem, etc) (Dos Santos et al., 2001).

### 1.11 Pragas

Dentre as variáveis mais deletérias para os plantios florestais, as pragas estão entre as mais importantes, podendo atacar desde a fase do viveiro até o ciclo final da espécie florestal (Dos Santos et al., 2001). Pragas de viveiro, formigas, lagartas e besouros desfolhadores são os principais (Dos Santos et al., 2001). Ocorrem em viveiros clonais, insetos sugadores, desfolhadores e danificadores de raízes, como exemplo: pulgão - *Toxoptera aurantii*; cochonilha - *Eriococcus* sp.; mosca-branca - *Dialeurodicus tessellatus*; mosca-do-viveiro - *Bradysia coprophila*, *Scythropochroa* sp. E *Sciara* spp.; ácaros - *Olygonychus yothersi*, *Olygonychus ilicis*, *Olygonychus punicae*, *Tetranychus urticae* e *Rhombacus eucalypti*. Já na produção de mudas por via sexuada, são as lagartas (*Agrotis ipisilon* Hufnagel), grilos (*Gryllus assimilis* Fabricius) e paquinhas (*Gryllotalpa hexadactyla*) (Dos Santos et al., 2001).

As principais espécies de formiga que atacam plantios florestais são as saúvas (*Atta* spp.) e as quenquéns (*Acromyrmex* spp.) (Reis, 2011). Elas podem causar desfolha total e até a morte dos plantios tanto jovens quanto já adultos, sendo que os maiores prejuízos ocorrem até 2 anos após a implantação. Reis (2011) verificou que desfolhas acima de 50% causaram perdas em altura e diâmetro de até 20% em plantios

de Pinus e Eucalipto. O combate as formigas são feitas com produtos químicos em forma de iscas granuladas, manejo adequado e monitoramento (de Carvalho et al., 1999).

Em plantios de Pinus, a vespa da madeira é a que mais provoca danos (Penteado, 2002). Durante a postura, a fêmea introduz na árvore um fungo simbiote tóxico a planta, causando a morte das acículas (Penteado, 2002). Após a eclosão, as larvas constroem galerias dentro da madeira em busca do fungo, retirando os nutrientes necessários para seu desenvolvimento (Penteado, 2002). A planta morre e sua madeira não é economicamente viável (Penteado, 2002). Seu combate consiste no manejo integrado de praga e práticas silviculturais corretas (Penteado, 2002). Pulgões da espécie *Cinara pinivora* e *Cinara atlântica* que atacam as brotações, os ramos, o caule e as raízes do Pinus (Dos Santos et al., 2001). O controle desta praga no Brasil é realizado por meio de Programa de Manejo Integrado, com controle biológico pelo parasitoide, *Xenostigmus bifasciatus*.

Nos plantios de eucalipto destacam-se os pequenos insetos, tais como: pulgões, percevejos, psilídeos e microvespas (Santos et al., 2008). São insetos que se dispersam com facilidade, possuem ciclo de vida curto e muitas vezes passam despercebidos, em função de seu pequeno tamanho (Santos et al., 2008). Por isso, em muitos casos são detectados apenas quando o dano econômico já está avançado (Santos et al., 2008).

O percevejo bronzeado (*Thaumastocoris peregrinus*) posta seus ovos agrupados nas irregularidades das folhas, causando o prateamento das folhas e com o tempo, para tons de marrom e vermelho, e grandes infestações podem causar a morte da árvore (Barbosa et al., 2012). Seu controle pode ser feito com controle biológico com uso do parasitoide *Cleruoides noackae* (Dos Santos et al., 2001). A vespa da galha são encontradas em *Eucalyptus camaldulensis* e clones derivados (Puretz et al., 2015). As larvas são encontradas nas galhas e os adultos nas brotações novas (Puretz et al., 2015). Nas árvores adultas causa super brotação, perdendo o crescimento, secamento do ponteiro, podendo causar até a morte da (Puretz et al., 2015). Não há até hoje nenhuma medida para o controle, sendo as plantas atacadas descartadas e queimadas (Puretz et al., 2015).

Dentre as lagartas, as da ordem Lepidoptera são as que causam mais danos nas plantas devido a sua fase larval se alimentar de folhas. Alguns exemplos *Eacles imperialis*

*magnifica* (Lepidoptera: Saturniidae), *Automeris* spp. (Lepidoptera: Hemileucidae), *Glena* spp. (Lepidoptera: Geometridae), *Eupseudosoma aberrans* (Lepidoptera: Arctiidae), *Sabulodes caberata caberata* (Lepidoptera: Geometridae) e *Sarcina violascens* (Lepidoptera: Lymantriidae) (Silva, 2008). O controle dessa praga não tem sido muito efetivo, sendo utilizado manejo integrado com a bactéria *Bacillus thuringiensis* (Silva, 2008).

A principal espécie de besouros desfolhadores que apresenta importância para o setor florestal brasileiro é *Costalimaita ferrugínea* (Xavier et al., 2019). Estes besouros atacam folhas novas, roem ponteiros e galhos tenros de eucaliptos jovens, sendo o controle dessa praga inclui o uso de plantas resistentes e tratos culturais adequados (Xavier et al., 2019).

Os insetos broqueadores (*Platypus sulcatus*, *Phoracantha semipunctata*, *Achryson surinamum* e *Mallodon spinibarbis*) também causam danos em plantios florestais, sendo que o controle consiste em eliminar as partes afetadas para evitar reinfestações (Dos Santos et al., 2001).

### 1.12 Outras plantas

As relações de uma planta com outras da mesma comunidade afetam as atividades da planta (morfologia, reprodução, etc) além de competição por luz, água e nutrientes (Andrade et al., 2001). Elas podem coexistir no mesmo espaço ou ainda interferir na sobrevivência de outras espécies (Andrade et al., 2001). Toledo et al. (2003), citado por De Freitas (2017), 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.

Os cipós são plantas lenhosas enraizadas no solo, mas sobem com o apoio de outras árvores e chegam quase ao topo das plantas de dossel. Eles são autotróficos e são encontrados em quase todas as florestas. Podem competir por luz com as árvores, diminuindo a produtividade da mesma (Engel et al., 1998).

As plantas parasitas não são autotróficas, obtendo seus nutrientes da planta hospedeira e, geralmente não possuem contato com o solo, possuindo raízes especiais, chamadas haustórios para se alimentar das plantas hospedeiras (Kumar, 2018). Os parasitas podem ser parasitas totais, obtendo sua necessidade total de alimento, água e minerais da planta hospedeira, ou parasitas parciais que extraem água e minerais do hospedeiro (Kumar, 2018).

### 1.13 Microrganismos do solo

Os decompositores exercem a ação sobre a matéria orgânica morta presente no solo e sua conversão em formas simples que podem ser usadas pelas plantas superiores como nutrientes, resultando em um aumento da fertilidade do solo e, portanto, tem um efeito significativo sobre o crescimento das plantas naquele solo (Kumar, 2018).

As bactérias fixadoras de nitrogênio transformam o nitrogênio inerte da atmosfera em formas que podem ser utilizadas nas plantas, como nitratos, amônia e componentes orgânicos (Barbosa et al., 2012). Alguns invertebrados, como as minhocas, auxiliam na aeração do solo, favorecendo o crescimento do sistema radicular das plantas (Kumar, 2018).

Fungos micorrizicos arbusculares (FMA) associam se as raízes das plantas, e propiciam estas maiores capacidades de competição em solos de baixa fertilidade, através dos efeitos de simbiose planta-fungo-solo, favorecendo o desenvolvimento (Siqueira et al., 1995). Geralmente são encontradas nos solos ou inoculadas durante a formação da muda para que haja o desenvolvimento adequado no campo (Janos, 1996). Pouyú-rojas (2000) inoculou FMA em sete espécies florestais e observou que todas as espécies tiveram aumento significativo no crescimento comparado com as que não foram inoculadas.

## 1.14 Fauna

A composição faunística possui uma importante relação com a flora, principalmente nos mecanismos de polinização e dispersão de sementes (de Almeida, 1996). As interações harmônicas da comunidade faunística e as estruturas biofísicas dos reflorestamentos, ao lado de suas alternativas de manejo, contribuem para a evolução, sustentabilidade e sobrevivência da floresta, juntamente com os fatores do meio físico (de Almeida, 1996).

A população florística, oferece a fauna alimentos e abrigos, fundamental para sua sobrevivência (de Almeida, 1996). Por isso, em talhões homogêneos, distantes de reservas naturais e sem sub-bosque, apresentam populações animais muito reduzidas, devido à alta demanda energética para procura de alimentos (de Almeida, 1996).

As relações entre planta, polinizador e dispersor influencia a distribuição espacial, a riqueza e abundancia de espécies das comunidades (Bawa, 1990). Esses processos afetam diretamente o sucesso reprodutivo das plantas, favorecendo a diversidade genética, através do fluxo de genes (Nason et al., 1997). A FAO (Food and Agriculture Organization) (2006) estima que 33% da alimentação humana depende em algum de plantas cultivadas polinizadas muitas vezes pelas abelhas (Klein et al., 2007).

As alterações ambientais podem causar ações indiretas nas florestas, afetando os polinizadores e/ou dispersores (Yamamoto et al., 2007). Populações de abelhas estão ameaçadas em várias regiões do mundo devido ao desmatamento de grandes áreas florestais (Imperatriz-Fonseca e Nunes-Silva, 2010).

As principais estratégias de polinização decorrem do ambiente em que as plantas se encontram (dossel, sub-bosque, floresta fechada, clareiras, bordas), da forma da planta, da predação, da competição e do clima (Drezner et al., 2001).

Dispersão zoocóricas com frutos ou sementes pesadas e numerosas predominariam nos estratos mais baixos da floresta, nos quais a vida animal seria mais intensa (Roth, 2012). Furtos carnosos, como de algumas espécies de Myrtaceae são consumidas por aves, roedores, répteis e mamíferos, favorecendo a dispersão de sementes (Gressler et al., 2006).

A maior diversidade de animais terrestres é composta pelos insetos, sendo de fundamental importância para o estudo de biodiversidade e função dos ecossistemas

(Basset et al., 2007), além de serem utilizados como indicadores ambientais (Freitas et al., 2003).

### 1.15 Homem

Nos arranjos naturais, fauna, flora e meio físico apresentam constante e perfeita interações e interdependências (de Almeida, 1996). No entanto, quando o homem interfere de forma significativa na natureza para atingir seus objetivos específicos, cria-se um ambiente modificado nos mais variados níveis (de Almeida, 1996). O ambiente pode estar de tal forma alterado pelas ações antrópicas, que as interações da flora com a fauna ficam prejudicadas e comprometidas, afetando de forma significativa as comunidades bióticas e conseqüentemente os meios físicos e socioeconômico (de Almeida, 1996). As alterações do homem no meio ambiente têm um papel determinante na estrutura e composição das comunidades (Gerhardt e Foster, 2002). Em áreas com histórico de atividade antrópica, o uso da terra sofre forte impacto sob os padrões de vegetação e relações do ecossistema (Peterken, 1993).

As florestas primárias possuem maior diversidade de fauna e flora, enquanto as florestas secundárias possuem uma baixa diversidade, especialmente a ausência de espécies com baixa taxa de dispersão ou sensíveis a distúrbios no meio (Peterken e Game, 1984). A introdução de plantas e animais exóticos em outras partes do globo representa outro problema para as espécies nativas, e a competição pela existência entre eles se torna mais intensa. Alguma introdução de novos animais pelos homens produz um efeito significativo sobre a vegetação existente (Kumar, 2018).

O desmatamento, a sobre-exploração, espécies invasoras e mudanças climáticas são as principais ações antrópicas relacionadas a perda de biodiversidade das florestas (Fischer e Lindenmayer, 2007).

Retirar a vegetação natural faz com que ocorra um desequilíbrio no teor de carbono orgânico do solo pela intensificação da mineralização da matéria orgânica, que inicialmente libera alguns nutrientes que favorecem o crescimento florestal (Barreto et al., 2006). No entanto, quando o processo de adição de matéria orgânica é inferior ao de

decomposição, o sistema se degrada, diminuindo sua fertilidade e infiltração de água, aumentando a densidade e processo de erosão. Técnicas de manejo utilizadas no cultivo nem sempre se preocupa com a sustentabilidade do sistema (Melo Filho et al., 2007).

Modificações de vegetação por destruição parcial intermitente pelo fogo é outro efeito indireto devido às atividades do homem (Mota, 2008). Quando a vegetação é queimada, quase todo o ambiente é alterado. Quando o fogo é extremamente severo, a vegetação é quase destruída e a parte superior dos húmus também é queimada (Redin et al., 2011) e isso reduz a fertilidade do solo. Os compostos de cálcio, potássio e fósforo são convertidos em formas solúveis, que facilmente se afastam do solo, tornando-o deficiente nesses minerais (Redin et al., 2011). Os compostos de nitrogênio são convertidos em suas formas gasosas e, portanto, desaparecem (Redin et al., 2011). Incêndios de baixa intensidade podem resultar em aumento da fertilidade do solo. Quando a temperatura está abaixo de 100° C, mas bem acima do normal, as bases são liberadas, aumentando assim o pH dos solos ácidos. Essa temperatura também promove o crescimento e a atividade das bactérias fixadoras de nitrogênio presentes no solo (Nascimento et al., 2018).

A criação de populações homogêneas tem provocado alterações sensíveis nas comunidades bióticas, causando reduções populacionais, mudanças nas razões dos sexos e isolamentos de metapopulações, além do aumento na incidência de pragas florestais (de Almeida, 1996). A supressão total de uma população (hidroelétrica, projetos florestais ou agrícolas, expansão das cidades), tem sido responsável pelo desaparecimento de populações inteiras de fauna e flora (de Almeida, 1996).

### 1.16 Manejo

A produção de uma floresta depende das fatores climáticos, edáficos, fisiográficos e bióticos, sendo que o manejo adequado pode influenciar quantitativamente e qualitativamente a produção (Binkley et al., 2010). Em todas as etapas da floresta (implementação, desenvolvimento e colheita), esses fatores devem ser levados em consideração para que sejam escolhidos corretamente os tratamentos silviculturais

adequados para aquela população, a fim de se ter a maior viabilidade econômica do plantio (Binkley et al., 2010).

Em um meio, essas variáveis podem ser divididas em 3 grupos de acordo com a possibilidade de serem modificados (Tabela 2). O manejo de uma floresta, juntamente com a escolha dos tratamentos silviculturais a serem aplicados, agem sob as variáveis que podem ser modificadas como escolha do genótipo, preparo do solo, espaçamento do plantio, fertilização, controle de matocompetição e pragas, seleção de sistemas de colheita e outros (de Toledo et al., 2003; Stape et al., 2004; Rocha et al., 2015). Algumas dessas variáveis e suas relações com a florestas foram discutidas acima.

*Tabela 2 - Fatores ambientais que afetam a produtividade florestal. (fonte: Hughes and Boyd (1973)).*

<b>Normalmente Fixos</b>	<b>Geralmente Mutáveis</b>	<b>Costumeiramente Mutáveis</b>
1.Clima	1.Densidade da Vegetação	1.Densidade da vegetação
Precipitação		
Umidade		
Radiação		2.Espécie
	2.Espécie	
2.Topografia		3.Idade
3.Solo	3.Solo	
Profundidade	Umidade	
Textura	Nutrientes	
Matéria Orgânica	Temperatura	
	Microrganismo	
4.Distribuição de raízes	Densidade da micro e macrofauna	

A escolha do genótipo para plantio, conforme já discutido, visa a escolha de características, como produtividade, resistência a ambientes estressantes, necessidades nutricionais e qualidade da madeira, que torne a floresta economicamente viável, podendo promover o aumento de produção sem que haja aumento da área de plantio (Marcatti et al., 2017).

A nutrição das mudas via adubação de seus substratos de crescimento é responsável pela obtenção de maior produtividade desponta como um dos principais



responsáveis pela obtenção de sua maior produtividade (nos viveiros) e qualidade, além da maior economicidade do processo de sua produção (Neves et al., 1990).

Na escolha do espaçamento, aspectos como clima, disponibilidade hídrica, material genético, idade de planejamento de corte, plantas daninhas do local, uso e qualidade da madeira e investimento disponível devem ser levados em consideração (Evans, 1992). O espaçamento influencia diretamente a taxa de crescimento das árvores, o crescimento do povoamento, a qualidade e sortimento de madeira, os tratos culturais, custos de implantação, manutenção e colheita e a conservação do solo (Resende et al., 2016). Em plantios mais densos foram observados uma maior relação entre a produtividade e competição do que em plantios de menor densidade (Resende et al., 2016). Segundo Berger et al. (2002), espaçamentos menores produzem árvores com diâmetros reduzidos em virtude de maior competição entre as plantas pelos recursos do meio, como água, nutrientes e luz. Porém, em termos de produção total por área, estes menores espaçamentos apresentam maior área basal e volume por hectare, para uma determinada idade (Dias, 2009). Além de afetar a produção, o espaçamento também implica nos tratos silviculturais subsequentes: interfere nas taxas de crescimento e sobrevivência das plantas, no volume de copa e galhos, na qualidade da madeira, na porcentagem de casca, na idade de corte, bem como nas práticas de colheita e manejo florestal e, conseqüentemente, nos custos de produção florestal (Rondon, 2002).

Na fase de implementação de florestas, o afogamento de coleto é um dos desafios que as empresas lidam. O enterramento de parte do caule das mudas por ocasião do plantio ou o seu aterramento no campo, por subsequentes tratos culturais ou enxurradas faz com que a porção do caule que passa a funcionar como “novo” coleto, é forçada a modificar-se em órgão subterrâneo, o que exige alterações na fisiologia da planta. Cuidados no plantio e preparo de solo evitam a sua ocorrência.

A presença de vegetação durante o estabelecimento de um plantio florestal pode resultar em subcrescimento das árvores pela competição por luz, água e nutrientes (Zutter et al., 1987). O controle por capina leva em consideração as espécies competidoras, sua abundância e crescimento, como também as condições de preparo da região (Van Heerden e Masson, 1991). Little (2007) observou que altitude, método de preparação do solo (queima dos resíduos anteriores ou não) e a interação entre esses

dois fatores estão relacionados ao período em que há supressão do crescimento em plantios de Eucalipto, indicado o momento que deve ser feita a intervenção da capina. Esse controle é intenso nos dois primeiros anos de implantação da cultura do eucalipto, podendo, em caso de reinfestação, estender-se para quase todo o ciclo da cultura (Santos, 2006).

Plantas daninhas podem se tornar hospedeiras de pragas e doenças, propagar incêndios florestais e causar perda de produtividade dos plantios devido a mato competição (Santos, 2006). O seu controle se torna dispendioso pelo uso de intensa mão de obra e utilização de controle químico ou métodos mecânicos, consumindo cerca de 25% dos custos de implantação de uma floresta (Woch, 2014). Pode ocorrer ainda dos herbicidas atingirem as plantas cultivadas, causando injúrias e redução na produtividade (Duke e Dayan, 2013).

Em florestas plantadas, as formigas cortadeiras se destacam como a principal praga, especialmente na fase de pré corte e plantio ou brotação. As empresas de reflorestamento têm empregado o controle químico de formigas cortadeiras de forma sistemática, através de iscas, termonebulização e fumigantes, sendo o aspecto econômico das operações de grande importância, em virtude dos altos custos envolvidos. Além do maior custo das iscas à base de sulfluramida, em relação às aquelas à base de dodecacloro, a adoção do cultivo mínimo e a proibição das queimadas, têm determinado aumentos na quantidade de iscas necessária para um controle satisfatório (Boaretto e Forti, 1997).

A fertilização é uma das técnicas silviculturais que pode ser utilizada visando elevar a produtividade florestal e reduzir o período de rotação (Barros et al., 1990). Sua efetividade depende de fatores como: índice de sitio, a seleção de fontes de nutrientes com base nas características do solo e clima, a aplicação do fertilizante quanto a forma, modo, época para haver a maximização das respostas das plantas e retorno econômico, havendo a necessidade de entender as interações entre clima-planta-solo-fertilizante (Barros et al., 1990). Para a avaliação da necessidade de adubação podem ser feitos análises de solo e análise visual da deficiência nos plantios. Em povoamentos equiâneos a quantidade de nutrientes existentes no solo e a exportada durante a exploração florestal são de grande importância na definição do balanço de nutrientes e da eventual

necessidade de aplicação de fertilizantes (Moreira *et al.*, 2010). A quantidade de nutrientes a ser reposta via fertilização será menor se a casca e os componentes da copa for deixada na área por ocasião da colheita, retirando-se somente a madeira (Miranda *et al.*, 2002).

Para obtenção de árvores de maiores diâmetros, podem ser realizados desbastes, visando garantir maior disponibilidade de nutrientes e luz para o aumento da área basal individual (Glufke *et al.*, 1997). Schneider (1991) descreveu que a medida que o número de árvores por hectare aumenta, ocorre um aumento significativo da área basal até atingir o ponto de competição entre as árvores e a consequente redução no crescimento seguida pela estagnação. Segundo ele, isto pode ser explicado pela diminuição na superfície da copa das árvores, o que ocasiona a redução da atividade fotossintética, a redução do incremento em diâmetro (Burger, 1980).

A área basal é em função da qualidade do sítio, da idade das árvores, da densidade do povoamento, e também da intensidade e idade em que são realizadas as intervenções silviculturais (Schneider, 1993). O uso de desbastes pode diminuir a produção total final, no entanto eleva a produtividade de sortimentos com dimensões maiores de toras (Schneider *et al.*, 1991), sendo que povoamentos mais jovens respondem melhor a repentina melhoria das qualidades do sítio causadas pela redução na competição entre as árvores (Glufke *et al.*, 1997).

Os danos causados pela exploração florestal pode levar o solo a um processo acelerado de degradação (Fernandes e Souza, 2003) pelo aumento do tráfego de máquinas, resultando em desequilíbrio de suas características físicas, químicas e biológicas e afetando progressivamente o seu potencial produtivo (Fernandes e Souza, 2003). O tráfego de máquinas pode ocasionar danos às árvores remanescentes, perda na capacidade de rebrota (Fernandes e Souza, 2003), compactação do solo, fenômenos erosivos e prejudica o crescimento de raízes (Seixas e Souza, 2007). O tipo e o nível de dano são relacionados com os módulos de colheita, sendo tanto no processo de colheita quanto no de extração dessa madeira para as estradas (Fernandes e Souza, 2003),

Devido à grande quantidade de matéria prima demandada dos plantios florestais, as práticas silviculturais aplicadas nos povoamentos podem causar a redução no estoque de nutrientes do solo, comprometendo a produtividade contínua nas próximas rotações

(Barichello, 2003). Para minimizar esse efeito, a permanência de resíduos da colheita (casca, folhas e galhos) sobre o solo é recomendada para parte significativa dos nutrientes extraídos durante o crescimento das árvores (Schumacher et al., 2003), além de reduzir os impactos nas características químicas do solo como manutenção do conteúdo de água disponível, redução de plantas invasoras e melhora na atividade biológica do solo (Chaer e Tótola, 2007).

São diversos fatores que interagem e influenciam o crescimento de um povoamento, de modo direto ou indireto. Variações abaixo ou acima dos níveis ótimos de um fator pode causar redução no crescimento ou até morte da vegetação. As práticas silviculturais adequadas utilizam de informações de diversos fatores para que possa verificar a necessidade da planta para que haja um aumento na produtividade.

## REFERÊNCIAS

ABER, JOHN D. et al. **Forest biogeochemistry and primary production altered by nitrogen saturation.** *Water, Air, and Soil Pollution, Netherlands*, v. 85, n. 3, p. 1665-1670, december 1995.

ABER, JOHN ET AL. **Forest processes and global environmental change: predicting the effects of individual and multiple stressors: we review the effects of several rapidly changing environmental drivers on ecosystem function, discuss interactions among them, and summarize predicted changes in productivity, carbon storage, and water balance.** *BioScience*, v. 51, n. 9, p. 735-751, september 2001

AGUIAR, MARIA IVANILDA DE. **Soil physical quality in agroforestry systems.** 2008. 89 f. Dissertação (Mestrado em Fertilidade do solo e nutrição de plantas; Gênese, Morfologia e Classificação, Mineralogia, Química,) - Universidade Federal de Viçosa, Viçosa, 2008.

ALFENAS, ACELINO C., E. A. V. ZAUZA, R. G. MAFIA, E T. F. DE ASSIS..**Clonagem e doenças do eucalipto,** Editora UFV, 2009.

ALMEIDA, AURO CAMPI DE; SOARES, JOÃO VIANEI. **Comparação entre uso de água em plantações de Eucalyptus grandis e floresta ombrófila densa (Mata Atlântica) na costa leste do Brasil.** *Revista árvore, Viçosa (Brasil)*, v. 27, p. 159-170, 2003.

AMARAL MACHADO, SEBASTIÃO ET AL. **Growth dynamics of young trees of Araucaria angustifolia and Pinus taeda Dinâmica de crescimento de plantios jovens de Araucaria angustifolia e Pinus taeda.** *Pesquisa Florestal Brasileira, Colobo (Brasil)*, v. 30, n. 62, p. 165-170, maio/julho 2010.

ANDRADE, CARLOS MAURICIO SOARES DE ET AL. **Fatores limitantes ao crescimento do capim-tanzânia em um sistema agrossilvipastoril com eucalipto, na região dos cerrados de Minas Gerais.** *Revista Brasileira de Zootecnia, Viçosa (Brasil)*, v. 30, p. 1178-1185, janeiro 2001.

ASHRAF, M. IRFAN ET AL. **A novel modelling approach for predicting forest growth and yield under climate change.** *PloS one, Canada*, v. 10, n. 7, p. e0132066, july 2015.

DE ASSIS, TEOTÔNIO FRANCISCO; ABAD, JÚPITER ISRAEL MURO; AGUIAR, AURÉLIO MENDES. **Melhoramento genético do eucalipto.** *Informe Agropecuário, Belo Horizonte (Brasil)*, v. 18, p. 32-51, 1996.

Assis, Teotônio Francisco de, Júpiter Israel Muro Abad, e Aurélio Mendes Aguiar. 1996. **“Melhoramento genético do eucalipto”.** *Informe Agropecuário, Belo Horizonte (Brazil)* 18: 32–51.

ATAÍDE, GLAUCIANA DA MATA ET AL.. **Interação árvores e ventos: aspectos ecofisiológicos e silviculturais.** Ciência Florestal, Santa Maria (Brasil) v. 25, p. 523-536, abril/junho 2015.

BAESSO, RAQUEL COUTO EVANGELISTA; RIBEIRO, ARISTIDES; SILVA, MARIANO PEREIRA. **Impacto das mudanças climáticas na produtividade do eucalipto na região norte do Espírito Santo e sul da Bahia.** Ciência Florestal, Santa Maria (Brasil), v. 20, p. 335-344, abril/junho 2010.

BALBINOT, RAFAELO ET AL.. **O papel da floresta no ciclo hidrológico em bacias hidrográficas The forest role in the hydrological cycle at hydrological basins.** Ambiência, Guarapuava (Brasil) v. 4, n. 1, p. 131-149, janeiro/abril 2008.

BALDOCCHI, DENNIS D.; VERMA, SHASHI B.; ANDERSON, DEAN E.. **Canopy photosynthesis and water-use efficiency in a deciduous forest.** Journal of Applied Ecology, Connecticut (USA), p. 251-260, abril 1987.

BARBOSA, JULIERME ZIMMER; CONSALTER, RANGEL; MOTTA, ANTONIO CARLOS VARGAS. **Fixação biológica de nitrogênio em Poaceae.** Evidência, Joaçaba (Brasil), v. 12, n. 1, p. 7-18, janeiro/junho 2012.

BARBOSA, L. R. et al.. **Percevejo bronzeado do eucalipto: reconhecimento, danos e direcionamentos para o controle.** Embrapa Florestas-Documents (INFOTECA-E), Colombo (Brasil), outubro 2012.

BARRETO, ARLETE CÔRTEZ ET AL. **Características químicas e físicas de um solo sob floresta, sistema agroflorestal e pastagem no sul da Bahia.** Revista Caatinga, Mossoró (Brasil) v. 19, n. 4, outubro/dezembro 2006.

BARROS, NAIRAM FELIX DE, REYNALDO CAMPOS SANTANA, REYNALDO CAMPOS ET AL. **Estimativa de biomassa de plantios de eucalipto no Brasil.** Revista Árvore, v. 32, n. 4, p. 697-706, Viçosa (Brasil), maio 2008.

BARROS, NF de; NOVAIS, RF de; NEVES, J. C. L. **Fertilização e correção do solo para o plantio de eucalipto.** Relação solo-eucalipto. Viçosa, MG: Folha de Viçosa, Viçosa (Brasil) p. 127-186, 1990.

BARTELINK, H. H. **Radiation interception by forest trees: a simulation study on effects of stand density and foliage clustering on absorption and transmission.** Ecological modelling, v. 105, n. 2-3, p. 213-225, january 1998.

BASSET, YVES ET AL. **IBISCA-Panama, a large-scale study of arthropod beta-diversity and vertical stratification in a lowland rainforest: rationale, study sites and field protocols.** Bulletin de L'Institut Royal des Sciences Naturelles de Belgique Entomologie, Brussel (BE), v.77, n.20, p. 39-69, 2007.

BAWA, KAMALJIT S. **Plant-pollinator interactions in tropical rain forests.** Annual review of Ecology and Systematics, Boston (USA) v. 21, n. 1, p. 399-422, 1990.

- BAZZAZ, FAKHRI A. **The response of natural ecosystems to the rising global CO<sub>2</sub> levels**. Annual review of ecology and systematics, Cambridge (USA) v. 21, n. 1, p. 167-196, 1990.
- BILLINGS, W. DWIGHT. **The environmental complex in relation to plant growth and distribution**. The Quarterly Review of Biology, Durham (USA) v. 27, n. 3, p. 251-265, september 1952.
- BINKLEY, DAN ET AL. **Explaining growth of individual trees: light interception and efficiency of light use by Eucalyptus at four sites in Brazil**. Forest Ecology and Management, USA v. 259, n. 9, p. 1704-1713, april 2010.
- BLACKARD, JOCK A.; DEAN, DENIS J. **Comparative accuracies of artificial neural networks and discriminant analysis in predicting forest cover types from cartographic variables**. Computers and electronics in agriculture, Fort Collins (USA) v. 24, n. 3, p. 131-151, december 1999.
- BOARETTO, M. A. C.; FORTI, L. C. **Perspectivas no controle de formigas cortadeiras**. Série técnica IPEF, Botucatu (Brasil) v. 11, n. 30, p. 31-46, maio 1997.
- BURGER, DIETRICH. **Ordenamento Florestal I—A Produção Florestal: 4ª Edição**. Curitiba: Fundação de Pesquisas Florestais do Paraná, Curitiba (Brasil), 1980.
- CAIN, STANLEY ADAIR ET AL. **Foundations of plant geography**. Foundations of plant geography., New York (USA), 1944.
- CAMPOS, J. C. CHAGAS. **Principais fatores do meio que afetam o crescimento das árvores**. Floresta, Brasil v. 2, n. 3, 1970.
- CAMPOS, JOÃO CARLOS CHAGAS; LEITE, HELIO GARCIA. **Mensuração florestal: perguntas e respostas**. Viçosa (Brasil), 2006.
- CARVALHO, AMÉRICO PEREIRA DE, OSMAR MENEGOL, EDILSON BATISTA DE OLIVEIRA, S. DO A. MACHADO, REINALDO OSCAR POTTER, PEDRO JORGE FASOLO, CARLOS ALBERTO FERREIRA, E ALEXANDRA BARTOSZECK.. **“Efeitos de característica do solo sobre a capacidade produtiva de Pinus taeda.”** *Embrapa Florestas-Artigo em periódico indexado (ALICE)*. 1999.
- CHEN, X. F. ET AL. **Effects of topography on simulated net primary productivity at landscape scale**. Journal of environmental management, v. 85, n. 3, p. 585-596, november 2007.
- CHIARELLO, FLÁVIO ET AL. **Artificial neural networks applied in forest biometrics and modeling: state of the art (january/2007 to july/2018)**. Cerne, Paraná (Brazil), v. 25, p. 140-155, may 2019.
- CHU, DUO.. **“Ecoregion Classification”**. In *Remote Sensing of Land Use and*

**Land Cover in Mountain Region: A Comprehensive Study at the Central Tibetan Plateau**, organizado por Duo Chu, 155–80. Singapore: Springer Singapore. 2020.

CLARK, DAVID A., S. C. PIPER, C. D. KEELING, E DAVID B. CLARK. “**Tropical rain forest tree growth and atmospheric carbon dynamics linked to interannual temperature variation during 1984–2000**”. *Proceedings of the national academy of sciences* 100 (10): 5852–57. 2003.

COOPER, WILLIAM S. **The fundamentals of vegetational change**. Ecology, Minnesota (USA) v. 7, n. 4, p. 391-413, october 1926.

COSTA, MARCOS HEIL, E JONATHAN A. FOLEY. **Combined effects of deforestation and doubled atmospheric CO2 concentrations on the climate of Amazonia**. *Journal of Climate* 13 (1): 18–34. 2000.

CURTIS, PETER S.; WANG, XIANZHONG. **A meta-analysis of elevated CO 2 effects on woody plant mass, form, and physiology**. *Oecologia, USA*, v. 113, n. 3, p. 299-313, january 1998.

DA SILVA, WILSON ET AL. **Altura e diâmetro de Eucalyptus citriodora e E. grandis, submetidos a diferentes teores de água em convivência com Brachiaria brizantha**. *Floresta, Paraná (Brasil)*, v. 27, n. 1/2, 1997.

DE ALMEIDA, ÁLVARO FERNANDO. **Interdependência das florestas plantadas com a fauna silvestre**. Série Técnica IPEF, Piracicaba (Brasil), v. 10, n. 29, p. 36-44, novembro 1996.

DE PAULA LIMA, WALTER. **Hidrologia florestal aplicada ao manejo de bacias hidrográficas**. Piracicaba (Brasil), dezembro 1996.

DE TOLEDO, ROBERTA ESTÊVÃO BRAGION, RICARDO VICTORIA FILHO, ALEXANDRE JOSÉ BEZUTTE, ROBINSON ANTONIO PITELLI, PEDRO LUÍS DA COSTA AGUIAR ALVES, CELINA FERRAZ DO VALLE, E SÍLVIO FERNANDES ALVARENGA. **Períodes de controle de Brachiaria sp e seus reflexos na produtividade de Eucalyptus grandis**. *Scientia Forestalis/Forest Sciences, Piracicaba (Brasil)*, n. 63, p. 221-232, june 2003.

DIAS, DANIELA PEREIRA. **Fotossíntese e crescimento em diâmetro de árvores em função da temperatura e da precipitação numa floresta primária de terra-firme na Amazônia Central**. INPE, Manaus (Brasil), maio 2009.

DIXON, MICHAEL; GRACE, J. **Effect of wind on the transpiration of young trees**. *Annals of Botany, Oxford (UK)*, v. 53, n. 6, p. 811-819, june 1984.

DOS SANTOS, A. F.; AUER, CELSO GARCIA; GRIGOLETTI JUNIOR, A. **Doenças do eucalipto no sul do Brasil: identificação e controle**. Embrapa Florestas-Circular Técnica (INFOTECA-E), Colombo (Brasil), june 2001.



DREZNER, TALY DAWN; FALL, PATRICIA L.; STROMBERG, JULIET C. **Plant distribution and dispersal mechanisms at the Hassayampa River Preserve, Arizona, USA.** *Global Ecology and Biogeography*, Australia, v. 10, n. 2, p. 205-217, march 2001.

DUKE, STEPHEN O.; DAYAN, FRANCK E. **Clues to new herbicide mechanisms of action from natural sources.** In: *Pest management with natural products*. American Chemical Society, p. 203-215. September 2013.

ENGEL, VERA LEX; FONSECA, RENATA CRISTINA BATISTA; OLIVEIRA, RE DE. **Ecologia de lianas e o manejo de fragmentos florestais.** *Série técnica IPEF*, v. 12, n. 32, p. 43-64, 1998.

EVANS, JULIAN. **Plantation forestry in the tropics: tree planting for industrial, social, environmental, and agroforestry purposes.** Oxford University Press, New York (USA), 1992.

FANG, RONG; STRIMBU, BOGDAN M. **Stem measurements and taper modeling using photogrammetric point clouds.** *Remote Sensing*, Corvallis (USA), v. 9, n. 7, p. 716, july 2017.

FERNANDES, HAROLDO CARLOS; SOUZA, AMAURY PAULO DE. **Compactação de um Latossolo Vermelho causada pelo tráfego do "Forwarder".** *Revista Árvore*, Viçosa (Brasil), v. 27, p. 279-284, maio 2003.

FISCHER, JOERN; LINDENMAYER, DAVID B. **Landscape modification and habitat fragmentation: a synthesis.** *Global ecology and biogeography*, Australia, v. 16, n. 3, p. 265-280, february 2007.

FONSECA, SEBASTIÃO MACHADO DA. **Manual prático de melhoramento genético de eucalipto.** Ed. UFV. 2010.

FREITAS, A. V. L., R. B. FRANCINI, E K. S. BROWN JR. **Insetos como indicadores ambientais. Métodos de estudos em biologia da conservação e manejo da vida silvestre.** Editora UFPR, 125–52. 2003.

FREITAS, ELIANE CRISTINA SAMPAIO DE. **Modelagem da produtividade de eucalipto por meio de redes neuronais artificiais.** Tese, UFV: Universidade Federal de Viçosa. 2017.

GALVAN, JÉSSICA. **Influência do tempo de secagem e estratificação da madeira na obtenção do carvão vegetal.** Trabalho de conclusão de curso, UFPR, Curitiba, 2018

GATTO, ALCIDES, NAIRAM FÉLIX DE BARROS, ROBERTO FERREIRA DE NOVAIS, IOVANDO MARCIANO DA COSTA, E JÚLIO CÉSAR LIMA NEVES. **Efeito do método de preparo do solo, em área de reforma, nas suas características, na composição**

**mineral e na produtividade de plantações de *Eucalyptus grandis*.** *Revista Árvore* 27: 635–46. 2003.

GERHARDT, FRITZ; FOSTER, DAVID R. **Physiographical and historical effects on forest vegetation in central New England, USA.** *Journal of Biogeography*, New England (USA), v. 29, n. 10-11, p. 1421-1437, october 2002.

GHOLZ, H. L.; EWEL, K. C.; TESKEY, R. O. **Water and forest productivity.** *Forest Ecology and Management*, v. 30, n. 1-4, p. 1-18, february 1990.

GLUFKE, CLARICE; FINGER, CÉSAR AG; SCHNEIDER, PAULO R. **Crescimento de *Pinus elliottii* Engelm sob diferentes intensidades de desbaste.** *Ciência Florestal*, Santa Maria (Brasil), v. 7, n. 1, p. 11-25, 1997.

GONÇALVES, JL de M.; DEMATTÊ, JOSÉ LUIS IORIATTI; COUTO, HTZ do. **Relações entre a produtividade de sítios florestais de *Eucalyptus grandis* e *Eucalyptus saligna* com as propriedades de alguns solos de textura arenosa e média no Estado de São Paulo.** *IPEF*, Piracicaba, Piracicaba (Brasil), v. 43, n. 44, p. 24-39, janeiro/dezembro 1990.

GONÇALVES, JL DE M., J. L. STAPE, V. BENEDETTI, V. A. G. FESSEL, E J. L. GAVA. **Reflexos do cultivo mínimo e intensivo do solo em sua fertilidade e na nutrição das árvores.** *Nutrição e fertilização florestal*. Piracicaba: IPEF, Piracicaba (Brasil), p. 1-57, 2000.

GRESSLER, ELIANA; PIZO, MARCO A.; MORELLATO, L. PATRÍCIA C. **Polinização e dispersão de sementes em *Myrtaceae* do Brasil.** *Brazilian Journal of Botany*, Brasil v. 29, p. 509-530, outubro/dezembro 2006.

GUIMARÃES, CLAUDINEI. **Controle e monitoramento de poluentes atmosféricos.** Elsevier Brasil, Rio de Janeiro (Brasil), 2017.

GUPTA, AMIT; LAM, MONICA. **The weight decay backpropagation for generalizations with missing values.** *Annals of Operations Research*, v. 78, p. 165-187, january 1998.

HALL, NIGEL P.; KEYS, ALFRED J. **Temperature dependence of the enzymic carboxylation and oxygenation of ribulose 1, 5-bisphosphate in relation to effects of temperature on photosynthesis.** *Plant Physiology*, USA, v. 72, n. 4, p. 945-948, march 1983.

HERINGER, INGRID; JACQUES, AINO VICTOR ÁVILA. **Adaptação das plantas ao fogo: enfoque na transição floresta-campo.** *Ciência Rural*, Santa Maria (Brasil), v. 31, p. 1085-1090, janeiro 2001.

HERNANDES, JOSÉ LUIZ; PEDRO JÚNIOR, MÁRIO JOSÉ; BARDIN, LUDMILA. **Variação estacional da radiação solar em ambiente externo e no interior de**

**floresta semidecídua.** Revista *Árvore*, v. 28, p. 167-172, 2004.

HIGA, R. C. V., A. R. HIGA, R. TREVISAN, E M. V. R. DE SOUZA. **Comportamento de vinte espécies de Eucalyptus em área de ocorrência de geadas na região sul do Brasil.** In: Embrapa Florestas-Artigo em anais de congresso (ALICE). In: Iufro Conference On Silviculture And Improvement Eucalypts= Conferência Iufro Sobre Silvicultura E Melhoramento De Eucaliptos, Colombo (Brasil), v. 1, p. 106-110., outubro 1997.

HSIAO, THEODORE C.; ACEVEDO, EDMUNDO. **Plant responses to water deficits, water-use efficiency, and drought resistance.** *Developments in Agricultural and Managed Forest Ecology*, v. 1, p. 59-84, 1975.

IMPERATRIZ-FONSECA, VERA LUCIA; NUNES-SILVA, PATRÍCIA. **As abelhas, os serviços ecossistêmicos e o Código Florestal Brasileiro.** *Biota Neotropica*, Campinas (Brasil), v. 10, p. 59-62, outubro 2010.

JANOS, DAVID. **Mycorrhizas, succession, and the rehabilitation of deforested lands in the humid tropics.** In: *Fungi and environmental change*. Cambridge University Press, for British Mycological Society. Cambridge (UK), p. 129-162. January 1996.

JOHNSEN, KURT, LISA SAMUELSON, ROBERT TESKEY, STEVE MCNULTY, E TOM FOX. **Process models as tools in forestry research and management.** *Forest Science*, Oxford (UK), v. 47, n. 1, p. 2-8, february 2001.

KITAO, M., T. T. LEI, T. KOIKE, H. TOBITA, E Y. MARUYAMA. **Susceptibility to photoinhibition of three deciduous broadleaf tree species with different successional traits raised under various light regimes.** *Plant, Cell & Environment*, v. 23, n. 1, p. 81-89, december 2001.

KLEIN, ALEXANDRA-MARIA, BERNARD E. VAISSIERE, JAMES H. CANE, INGOLF STEFFAN DEWENTER, SAUL A. CUNNINGHAM, CLAIRE KREMEN, E TEJA TSCHARNTKE. **Importance of pollinators in changing landscapes for world crops.** *Proceedings of the royal society B: biological sciences*, v. 274, n. 1608, p. 303-313, february 2007.

KOZLOWSKI, THEODORE T.; PALLARDY, STEPHEN G. **Growth control in woody plants.** Elsevier, California (USA), january 1997.

KUMAR, S.. **Ecological Factors that Affect the Growth of Plants.** Disponível em: < <http://www.biologydiscussion.com/plants/growth-of-plants/ecological-factors-that-affect-the-growth-of-plants-with-diagrams/15288>.> Acesso em 31 de outubro de 2021.

LAZARI, M.F. **Nitrificação em solos sob plantações de eucaliptos com diferentes idades.** Viçosa, MG, Universidade Federal de Viçosa, 2001.49p. (Tese de Mestrado)

LEK, SOVAN, MARC DELACOSTE, PHILIPPE BARAN, IOANNIS DIMOPOULOS, JACQUES LAUGA, E STÉPHANE AULAGNIER. **Application of neural networks to modelling nonlinear relationships in ecology**. *Ecological modelling*, v. 90, n. 1, p. 39-52, september 1996.

LEPSCH, I. F.; ESPÍNDOLA, C. R.; VISCHI-FILHO, O. J.; HERNANI, L. C.; SIQUEIRA, D.S. **Manual para levantamento utilitário do meio físico e classificação de terras no sistema de capacidade de uso**. Sociedade Brasileira de Ciência do Solo, Campinas (Brasil), 1983

LITTLE, KEITH M., CAROL A. ROLANDO, E CRAIG D. MORRIS. **An integrated analysis of 33 Eucalyptus trials linking the onset of competition-induced tree growth suppression with management, physiographic and climatic factors**. *Annals of forest science* 64 (6): 585–91.2007.

LONG, S. P.; OSBORNE, C. P.; HUMPHRIES, S. W. **Photosynthesis, rising atmospheric carbon dioxide concentration and climate change**. Scope-Scientific Committee On Problems Of The Environment International Council Of Scientific Unions, v. 56, p. 121-159, 1996.

MAESTRI, ROMUALDO, CARLOS ROBERTO SANQUETTA, JOSÉ ROBERTO SCOLFORO, SEBASTIÃO DO AMARAL MACHADO, E ANA PAULA DALLA CORTE. **Modelagem do crescimento florestal considerando variáveis do ambiente: revisão**. *Scientia Agraria, Curitiba (Brasil)*, v. 14, n. 3, setembro/dezembro 2013.

MARCATTI, GUSTAVO E., RAFAEL T. RESENDE, MARCOS DEON V. RESENDE, CARLOS ANTONIO AS RIBEIRO, ALEXANDRE R. DOS SANTOS, JOVANE P. DA CRUZ, E HELIO G. LEITE. **GIS-based approach applied to optimizing recommendations of Eucalyptus genotypes**. *Forest ecology and management*, v. 392, p. 144-153, may 2017.

MAZON DE ALCANTARA, ALINE EDWIGES, ANA DE ALBUQUERQUE SANTOS, LUIZA MARQUES DA SILVA MAYRA, DANIEL BINOTI, PEDRO BOECHAT SOARES CARLOS, JOSÉ GLERIANI, E HELIO LEITE. **Use of artificial neural networks to assess yield projection and average production of eucalyptus stands**. *African Journal of Agricultural Research, Africa*, v. 13, n. 42, p. 2285-2297, october 2018.

MCIVER, JAMES D. **Environmental effects of postfire logging: literature review and annotated bibliography**. Portland (USA), January 2000

MEDLYN, BELINDA E., REMKO A. DUURSMA, E MELANIE J. B. ZEPPEL. **Forest productivity under climate change: a checklist for evaluating model studies**. *Wiley Interdisciplinary Reviews: Climate Change*, v. 2, n. 3, p. 332-355, march 2011

MELO FILHO, JOSÉ FERNANDES DE; SOUZA, ANDRÉ LEONARDO VASCONCELOS; SOUZA, LUCIANO DA SILVA. **Determinação do índice de qualidade subsuperficial em um Latossolo Amarelo Coeso dos Tabuleiros**

**Costeiros, sob floresta natural.** Revista Brasileira de Ciência do Solo, Viçosa (Brasil), v. 31, n. 6, p. 1599-1608, dezembro 2007.

MIRANDA, G. M., ML DA SILVA, H. G. LEITE, E C. C. MACHADO. **Estimativa do custo de reposição dos nutrientes exportados pela colheita da casca da madeira em povoamentos de eucalipto.** Revista Árvore, v. 26, p. 149-154, 2002.

MOTTA, DANIEL SOUZA. **Identificação dos fatores que influenciam no comportamento do fogo em incêndios florestais.** Seropédica (Brasil), julho 2008.

NASCIMENTO, RODRIGO OLIVEIRA DO. **Fixação biológica de nitrogênio em florestas secundárias e florestas primárias queimadas na Amazônia Centro-Oriental.** Orientadora: Joice Nunes Ferreira. 2018. 77 f. Dissertação (Mestrado em Ciências Ambientais) - Instituto de Geociências, Universidade Federal do Pará, Museu Paraense Emílio Goeldi, Empresa Brasileira de Pesquisa Agropecuária, Belém, 2018.

NASON, J. D., P. R. ALDRICH, E J. L. HAMRICK. **Dispersal and the dynamics of genetic structure in fragmented tropical tree populations.** *Tropical forest remnants: ecology, management, and conservation of fragmented communities*, 304–20. 1997.

NEVES, J. C. L., J. M. GOMES, RF DE NOVAIS, E NF DE BARROS. **Nutrição mineral do eucalipto.** Relação solo-eucalipto, v. 1, p. 25-91, 1990.

NIELSEN, CHRISTIN NORGDARD. **Forest management for improved wind stability.** \_\_\_\_\_. Adaptive physiology and tree management, 2005.

NOBRE, CARLOS A.; NOBRE, ANTÔNIO D. **O balanço de carbono da Amazônia brasileira.** Estudos avançados, Manaus (Brasil), v. 16, p. 81-90, agosto 2002.

PAULA, RINALDO CESAR DE, ISMAEL ELEOTÉRIO PIRES, RITA DE CÁSSIA GONÇALVES BORGES, E COSME DAMIÃO CRUZ.. **Predição de ganhos genéticos em melhoramento florestal.** *Pesquisa agropecuária brasileira* 37: 159–65. 2002.

PENTEADO, SUSETE DO ROCIO CHIARELLO; LEDE, EDSON TADEU; REIS FILHO, WILSON. **Manual para o controle da vespa-da-madeira em plantios de pinus.** EMBRAPA, Colombo (Brasil), dezembro 2002.

PEREIRA, ANGELOCCI, LUIS ROBERTO; SENTELHAS, PAULO CESAR; ANTONIO ROBERTO. **Agrometeorologia fundamentos e aplicações práticas.** Agropecuária, Guairá, Buenos Aires (Argentina), 2002.

PEREZ-GARCIA, JOHN et al.. **Impacts of climate change on the global forest sector.** *Climatic change*, v. 54, n. 4, p. 439-461, september 2002.

PETERKEN, G. F.; GAME, M. **Historical factors affecting the number and distribution of vascular plant species in the woodlands of central Lincolnshire.** *The Journal of Ecology*, Strasburg (Franch), p. 155-182, 1984.

PETERKEN, GEORGE F. **Woodland conservation and management..** Springer Science & Business Media. 1993

Pissarra, T. C. T.; Politano, W.; Ferraudo, A. S. Avaliação de características morfométricas na PISSARRA, T. C. T.; POLITANO, W.; FERRAUDO, A. S. **Avaliação de características morfométricas na relação solo-superfície da Bacia Hidrográfica do Córrego Rico.** Revista Brasileira de Ciência do Solo, Jaboticabal (Brasil), v. 28, p. 297-305, 2004.

POUYÚ-ROJAS, ENRIQUE, E JOSÉ OSWALDO SIQUEIRA. **Micorriza arbuscular e fertilização do solo no desenvolvimento pós-transplante de mudas de sete espécies florestais.** *Pesquisa Agropecuária Brasileira* 35: 103–14. 2000.

PURETZ, BARBARA OLIVEIRA et al.. **Distribuição da vespa da galha do eucalipto.** *Pesquisa Florestal Brasileira, Paraná (Brasil)*, v. 35, n. 83, p. 329-334, setembro 2015.

RAISON, R. J.; MYERS, B. J.; BENSON, M. L. **Dynamics of Pinus radiata foliage in relation to water and nitrogen stress: I. Needle production and properties.** *Forest Ecology and Management*, v. 52, n. 1-4, p. 139-158, september 1992.

RALSTON, CHARLES W. **Evaluation of forest site productivity.** In: International review of forestry research. Elsevier, p. 171-201, 1964.

REDIN, MARCIEL et al.. **Impactos da queima sobre atributos químicos, físicos e biológicos do solo.** *Ciência Florestal, Santa Maria (Brasil)*, v. 21, p. 381-392, abril/junho 2011.

REIS FILHO, WILSON, FRANCIELE DOS SANTOS, PRISCILA STRAPASSON, E MARIANE APARECIDA NICKELE. **Danos causados por diferentes níveis de desfolha artificial para simulação do ataque de formigas cortadeiras em Pinus taeda e Eucalyptus grandis.** *Pesquisa Florestal Brasileira* 31 (65): 37–37. 2011.

RESENDE, RAFAEL T. et al.. **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, november 2016.

RIGATTO, PATRÍCIA APARECIDA; DEDECEK, RENATO ANTONIO; MATTOS, JORGE LUIS MONTEIRO. **Influência dos atributos do solo sobre a produtividade de Pinus taeda.** *Revista Árvore, Viçosa (Brasil)*, v. 29, p. 701-709, outubro 2005.

RILEY, RALPH H., E PETER M. VITOUSEK. **Nutrient dynamics and nitrogen trace gas flux during ecosystem development in montane rain forest.** *Ecology* 76 (1): 292–304. 1995.

DA ROCHA, SAMARA POZZAN et al.. **Propriedades físicas do solo e crescimento de eucalipto implantado em diferentes métodos de preparo do solo Soil physical**

**properties and eucalyptus growth planted after different tillage methods.** Sci. For., Piracicaba (Brasil), v. 43, p. 965-977, dezembro 2015.

RONDON, ELIAZEL VIEIRA. **Produção de biomassa e crescimento de árvores de Schizolobium amazonicum (Huber) Ducke sob diferentes espaçamentos na região de mata.** Revista Árvore, Viçosa (Brasil), v. 26, p. 573-576, outubro 2002.

ROSADO, ANTÔNIO MARCOS et al.. **Avaliação da tolerância à quebra por vento em árvores de eucalipto via teste de resistência.** Pesquisa Florestal Brasileira, Colombo (Brasil), v. 33, n. 75, p. 309-315, julho/setembro 2013.

ROTH, INGRID. **Stratification of a tropical forest as seen in dispersal types.** Springer Science & Business Media, 2012.

RUTTER, A. J. et al.. **Water consumption by forests.** Water Deficits and Plant Growth., London (UK), v. 2, p. 23-84, 1968.

RYAN, MICHAEL G. et al.. **Factors controlling Eucalyptus productivity: how water availability and stand structure alter production and carbon allocation.** Forest Ecology and Management, v. 259, n. 9, p. 1695-1703, abril 2010.

SAFI, YOUSSEF; BOUROUMI, ABDELAZIZ. **Prediction of forest fires using artificial neural networks.** Applied Mathematical Sciences, v. 7, n. 6, p. 271-286, 2013.

SANTANA, REYNALDO CAMPOS et al.. **Estimativa de biomassa de plantios de eucalipto no Brasil.** Revista Árvore, Viçosa (Brasil), v. 32, n. 4, p. 697-706, agosto 2008.

SANTOS, GERMI PORTO et al.. **Pragas do eucalipto.** Informe Agropecuário, Belo Horizonte, Belo Horizonte (Brasil), v. 29, n. 242, p. 43-64, janeiro/fevereiro 2008.

SANTOS, LEONARDO DAVID TUFFI. **Efeitos diretos e indiretos do glyphosate em eucalipto .** 2006.

SANTOS, REGINALDO FERREIRA; CARLESSO, REIMAR. **Déficit hídrico e os processos morfológico e fisiológico das plantas.** Revista Brasileira de Engenharia Agrícola e Ambiental, Campina Grande (Brasil), v. 2, n. 3, p. 287-294, setembro/dezembro 1998.

SCHNEIDER, P. R. et al.. **Efeito da intensidade de desbaste sobre o crescimento e produção de povoamentos de Pinus elliottii E.** SIMPÓSIO DE MANEJO DE FLORESTAS PLANTADAS, p. 150-167, 1991.

SCHNEIDER, PAULO RENATO. **Introdução manejo florestal.** Santa Maria (Brasil), 1993.

SEIXAS, FERNANDO, E CÍNTIA RODRIGUES DE SOUZA. **Avaliação e efeito da compactação do solo, devido à frequência de tráfego, na produção de madeira de**

**eucalipto**. *Revista Árvore* 31: 1047–52. 2007.

SHAKESBY, R. A., C. DE OA COELHO, A. D. FERREIRA, J. P. TERRY, E R. P. D. WALSH. **Fire, post-burn land management practice and soil erosion response curves in eucalyptus and pine forests, north-central Portugal**. *Soil erosion and degradation as a consequence of forest fires*, p. 111-132, 1994.

SHAKESBY, RICHARD A., DAVID J. BOAKES, CELESTE DE OA COELHO, AJ BENTO GONÇALVES, E RORY PD WALSH. **Limiting the soil degradational impacts of wildfire in pine and eucalyptus forests in Portugal: a comparison of alternative post-fire management practices**. *Applied Geography*, v. 16, n. 4, p. 337-355, october 1996.

SHAKESBY, RICHARD A., C. D. A. COELHO, ANTONIO D. FERREIRA, JAMES P. TERRY, ERORY PD WALSH. **Wildfire impacts on soil-erosion and hydrology in wet Mediterranean forest, Portugal**. *International Journal of Wildland Fire*, v. 3, n. 2, p. 95-110, 1993.

SILVA, NAJARA DA. **Caracterização e seleção de isolados de *Bacillus thuringiensis* efetivos contra *Sitophilus oryzae* L., 1763**. 2008. vii, 40 f. Dissertação (mestrado) - Universidade Estadual Paulista, Faculdade de Ciências Agrárias e Veterinárias, 2008.

SILVA, J. N., HENK FEITH, E J. C. PEREIRA. **Exploração e silvicultura pós-fogo em eucaliptais**. *O eucaliptal em Portugal-Impactes ambientais e investigação científica*. ISAPress, Lisboa, 285–312. 2007.

SIQUEIRA, JOSÉ OSWALDO et al.. **Influência do substrato de formação e da micorriza no crescimento de mudas de cafeeiro transplantadas**. *Pesquisa Agropecuária Brasileira*, Brasília (Brasil), v. 30, n. 12, p. 1417-1425, dezembro 1995.

SOARES, C. P. B.; LEITE, H. G. **Predição da produção de madeira de eucalipto em região com alta variabilidade pluviométrica**. *Scientia Forestalis*, Piracicaba (Brasil), v. 58, n. 103, p. 41-48, dezembro 2000.

SOUSA, LEONARDO CHAGAS DE. **Characterization of tension wood in *Eucalyptus grandis* and evaluation of its effect on Kraft pulp production**. 2004. 93 f. Dissertação (Mestrado em Manejo Florestal; Meio Ambiente e Conservação da Natureza; Silvicultura; Tecnologia e Utilização de) - Universidade Federal de Viçosa, Viçosa, 2004.

SPURR, STEPHEN HOPKINS et al.. **Forest ecology**. *Forest ecology*., New York (USA), n. 2. ed., 1973.

STAPE, JOSE LUIZ, DAN BINKLEY, MICHAEL G. RYAN, SEBASTIAO FONSECA, RODOLFO A. LOOS, ERNESTO N. TAKAHASHI, CLAUDIO R. SILVA, SERGIO R. SILVA, RODRIGO E. HAKAMADA, E JOSE MARIO DE A. FERREIRA. **The Brazil**



**Eucalyptus Potential Productivity Project: Influence of water, nutrients and stand uniformity on wood production.** *Forest Ecology and Management*, v. 259, n. 9, p. 1684-1694, april 2010.

STAPE, JOSE LUIZ, DAN BINKLEY, MICHAEL G. RYAN, E ANTONIO DO NASCIMENTO GOMES. **Water use, water limitation, and water use efficiency in a Eucalyptus plantation.** *Bosque* 25 (2): 35–41. 2004.

SUDARIĆ, A.; ŠIMIĆ, D.; VRATARIĆ, **Marija.** **Characterization of genotype by environment interactions in soybean breeding programmes of southeast Europe.** *Plant breeding*, v. 125, n. 2, p. 191-194, march 2006.

TALKKARI, ARI, HELI PELTOLA, SEPPO KELLOMÄKI, E HARRI STRANDMAN. **Integration of component models from the tree, stand and regional levels to assess the risk of wind damage at forest margins.** *Forest ecology and management*, v. 135, n. 1-3, p. 303-313, september 2000.

TELEWSKI, FRANK W. **A unified hypothesis of mechanoperception in plants.** *American journal of botany*, Michigan (USA), v. 93, n. 10, p. 1466-1476, october 2006.

THOMAS, ANDREW D.; WALSH, RORY PD; SHAKESBY, RICHARD A. **Post-fire forestry management and nutrient losses in eucalyptus and pine plantations, Northern Portugal.** *Land Degradation & Development*, v. 11, n. 3, p. 257-271, june 2000.

THORNTHWAITE, C. W.; MATHER, J. R. *Publications in climatology.* **The water balance**, v. 8, p. 1-104, 1955.

TJOELKER, M. G.; OLEKSYN, J.; REICH, P. B. **Seedlings of five boreal tree species differ in acclimation of net photosynthesis to elevated CO<sub>2</sub> and temperature.** *Tree physiology*, Victoria (Canada) v. 18, n. 11, p. 715-726, november 1998.

TOLFO, ANA LÍDIA TONANI et al.. **Parâmetros genéticos para caracteres de crescimento, de produção e tecnológicos da madeira em clones de Eucalyptus spp.** *Scientia Forestalis/Forest Sciences*, Piracicaba (Brasil), p. 101-110, abril 2005.

VAN HEERDEN, F.; MASSON, Peta H. **Weed species in newly regenerated pine plantations in the Eastern and Northern Transvaal: Factors affecting their distribution and abundance.** CSIR, Division of Forest Science and Technology, 1991.

VANCLAY, JEROME K. **Modelling forest growth and yield: applications to mixed tropical forests.** CAB international, Copenhagen (Denmark), 1994.

VOGEL, HAMILTON LUIZ MUNARI ET AL. CRESCIMENTO INICIAL DE PINUS TAEDA L.WHITEHEAD, DAVID, E CHRISTOPHER L. BEADLE. **Physiological regulation of**

**productivity and water use in Eucalyptus: a review.** *Forest ecology and management* 193 (1–2): 113–40. 2004.

WILLIAMS, RAY S.; LINCOLN, DAVID E.; NORBY, RICHARD J. **Leaf age effects of elevated CO<sub>2</sub>-grown white oak leaves on spring-feeding lepidopterans.** *Global Change Biology*, v. 4, n. 3, p. 235-246, january 1998.

WILSIE, CARROLL PATON et al.. Crop adaptation and distribution. **Crop adaptation and distribution.**, San Francisco (USA), 1962.

WOCH, RUDOLF. **Manejo de plantas daninhas em florestas plantadas.** Encontro Brasileiro de Silvicultura, v. 3, p. 2014, 2014.

YAMAMOTO, LEILA FUMIYO; KINOSHITA, LUIZA SUMIKO; MARTINS, FERNANDO ROBERTO. **Síndromes de polinização e de dispersão em fragmentos da Floresta Estacional Semidecídua Montana, SP, Brasil.** *Acta Botanica Brasilica*, v. 21, p. 553-573, setembro 2007.

XAVIER, MARIA EUGÊNIA VIEIRA. **Interações e ecologia química de *Costalimaita ferrugínea* (Fabricius, 1801) (Coleoptera: Chrysomelidae) em clones de *Eucalyptus urograndis* (Myrtaceae).** 2019. 64 f. Dissertação (Mestrado em Proteção de Plantas) – Centro de Ciências Agrárias, Programa de Pós-Graduação em Proteção de Plantas, Universidade Federal de Alagoas, Rio Largo, 2019.

ZHAO, HONG-LONG, TIAN-GEN CHANG, YI XIAO, E XIN-GUANG ZHU. **Potential metabolic mechanisms for inhibited chloroplast nitrogen assimilation under high CO<sub>2</sub>.** *Plant Physiology*, july 2021.

ZOBEL, DONALD B., ARTHUR MCKEE, GLENN M. HAWK, E C. T. DYRNESS. **Relationships of environment to composition, structure, and diversity of forest communities of the central western Cascades of Oregon.** *Ecological Monographs*, v. 46, n. 2, p. 135-156, april 1976.

ZUTTER, BRUCE R., LARRY R. NELSON, PATRICK J. MINOGUE, E DEAN H. GJERSTAD. **Hardwood plantation growth following weed control using herbicides and cultivation.** *Southern Journal of Applied Forestry* 11 (3): 134–38. 1987.



## CAPÍTULO 2: ESTIMATION OF EUCALYPTUS PRODUCTIVITY USING EFFICIENT ARTIFICIAL NEURAL NETWORK

Ricardo Rodrigues de Oliveira Neto <sup>1</sup>, Helio Garcia Leite <sup>1</sup>, José Marinaldo Gleriani <sup>1</sup>,  
Bogdan M. Strimbu <sup>2\*</sup>

<sup>1</sup> Department of Forest Engineering, Federal University of Viçosa, Viçosa, MG, Brazil

<sup>2</sup> Department of Forest Engineering, Resources and Management, Oregon State  
University, Corvallis OR, USA

\* Corresponding author. E-mail: bogdan.strimbu@oregonstate.edu

## ABSTRACT

The forest environment can be defined as the exterior forces and substances that affect forest development, structure and reproduction. To model the complex non-polynomial forest interrelations parametric and nonparametric representations were developed, such as Artificial Neural Network (ANN). ANNs, which seems to be more robust than statistical models to outliers and non-linear domains, face difficulties related to the choice of the training algorithm and structure or size of the network that directly affect its efficiency and generalization capabilities. The objective of the present study is to find the most efficient ANN configuration algorithms and pruning methods to estimate the eucalyptus productivity from geomorphologic, climatic, and continuous forest inventory data. Given the same hardware resources, we evaluated the efficiency of a Multilayer Perceptron ANN as the combination of the processing time to supply a solution and the accuracy of the results. We increase the efficiency of the network in two steps: one outside the ANN, thru Principal Component Analysis (PCA), and one inside the ANN, thru dedicated pruning methods. We used data from 507 Eucalyptus plantations, 3 years to 7 years old, ranging from 3 ha to 79 ha, located in Minas Gerais, Brazil, to test different network configurations. A configuration was a combination of number of neurons in the hidden layers, an ANN error back-propagation training algorithms and an ANN pruning methods. Each ANN was trained five times to assess the impact of the initial weights on the results, which led to a factorial experiment with 9000 combinations. We compared the ANNs performances using five metrics: processing time, bias, mean absolute error, root mean square error, and Pearson correlation coefficient. The most accurate result was supplied in in approximately 38.81 sec by an ANN using the PCA data, trained with the Scaled Conjugate Gradient algorithm with four neurons in the hidden layer and Magnitude Based Pruning method. However, an accuracy loss of less than 1% (i.e., the second most accurate results) was obtained in 1.7 sec from the same ANN configuration, except no pruning. Therefore, we found that the most efficient prediction of Eucalyptus productivity does not use all the data and or the most complex training algorithms.

**Keywords:** ANN Multilayer Perceptron, Principal Component Analysis, pruning methods, training algorithm, hidden layer

## RESUMO

O ambiente florestal pode ser definido como as forças e substâncias externas que afetam o desenvolvimento, a estrutura e a reprodução da floresta. Para modelar as complexas inter-relações florestais não polinomiais foram desenvolvidas representações paramétricas e não paramétricas, como a Rede Neural Artificial (RNA). As RNAs, que parecem ser mais robustas do que os modelos estatísticos para outliers e domínios não lineares, enfrentam dificuldades relacionadas à escolha do algoritmo de treinamento e estrutura ou tamanho da rede que afetam diretamente sua eficiência e capacidade de generalização. O objetivo do presente estudo é encontrar os algoritmos de configuração de RNA e métodos de poda mais eficientes para estimar a produtividade do eucalipto a partir de dados geomorfológicos, climáticos e de inventário florestal contínuo. Dados os mesmos recursos de hardware, avaliamos a eficiência de uma RNA Multilayer Perceptron como a combinação do tempo de processamento para fornecer uma solução e a precisão dos resultados. Aumentamos a eficiência da rede em duas etapas: uma fora da RNA, através da Análise de Componentes Principais (PCA), e uma dentro da RNA, através de métodos de poda dedicados. Usamos dados de 507 plantações de eucaliptos, com 3 a 7 anos de idade, variando de 3 ha a 79 ha, localizadas em Minas Gerais, Brasil, para testar diferentes configurações de rede. Uma configuração era uma combinação de número de neurônios nas camadas ocultas, algoritmos de treinamento de retropropagação do erro da RNA e métodos de poda da RNA. Cada RNA foi treinado cinco vezes para avaliar o impacto dos pesos iniciais nos resultados, o que levou a um experimento fatorial com 9.000 combinações. Comparamos o desempenho das RNAs usando cinco métricas: tempo de processamento, viés, erro absoluto médio, erro quadrático médio da raiz e coeficiente de correlação de Pearson. O resultado mais preciso foi fornecido em aproximadamente 38,81 segundos por uma RNA usando os dados de PCA, treinados com o algoritmo Scaled Conjugate Gradient com quatro neurônios na camada oculta e método de poda baseado em magnitude. No entanto, uma perda de precisão de menos de 1% (ou seja, o segundo resultado mais preciso) foi obtida em 1,7 segundos da mesma configuração de ANN, exceto sem poda. Portanto, descobrimos que a previsão mais eficiente da produtividade do Eucalyptus não utiliza todos os dados e um ou os mais complexos algoritmos de treinamento.

**Palavras-chave:** ANN Multilayer Perceptron, Análise de Componentes Principais, métodos de poda, algoritmo de treinamento, camada oculta.



## 1 INTRODUCTION

The forest environment can be defined as the exterior forces and substances that affect forest development, structure and reproduction (Billings, 1952). The complexity of the forest environment recommends that analysis of the interaction between plants and environmental factors must be analyzed together, as the whole is larger than the sum of its parts (Billings, 1952). To consider all attributes defining a forest simultaneously, we must acknowledge not only their dynamics but also how they change as one entity through time (Binkley et al., 2010a). The concurrent analysis of the complex interrelations within the forest have a non-polynomial complexity, which makes the investigation of forest environment computational difficult (Martinkoski et al., 2015; Sprott, 2003; Strimbu and Burkhart, 2015; Williams, 1997). Among the complex processes characterizing a forest, growth is arguably, the most studied. Growth and yield processes are influenced by a plethora of factors (Weiskittel et al., 2011), among them genotype, soil, climate and physiography being the main drivers (Burkhart and Tome, 2012; Pretzsch, 2009). Consequently, manipulation of the factors driving the forest growth and yield through enhanced silviculture is of fundamental importance when the focus is to increase the forest productivity (Otto et al., 2013a). Da Silva et al. (2016) found that among the natural resources required for plant growth, such as water, nutrients or light, nutrients availability is the resource most easily to manipulate by foresters, throughout soil preparation and fertilization. Multiple studies were focused on the forest growth (Binkley et al., 2010b; Braga et al., 1999; Burkhart and Tomé, 2012; Campoe et al., 2013; da Rocha et al., 2015; da Silva et al., 2016; de Jesus et al., 2015; Goncalves et al., 2014; Kim et al., 2015; Mazon de ALCANTARA et al., 2018; Otto et al., 2013b; Resende et al., 2018, 2016; Stape et al., 2004), but even that significant advances were achieved, much is still to be known about the factors that regulate forest productivity (Stape et al., 2004).

To build models with complex nonlinear interactions among variables, researchers have used a wide range of numerical, mathematical and statistical methods (Lek and Guégan, 1999), such as expert systems (Braga et al., 1999), genetic algorithm (D'Angelo et al., 1995) or artificial neural network (ANN) (Dreyer, 1993; Freitas, 2017). Haykin (2009) defines an ANN as a parallel combination of simple processing unit (or neurons), which can acquire knowledge from environment through a learning process and store the

knowledge in its connections. An ANN is a system of interconnected neurons organized in three types of layers: the input layer, the output layer, and the hidden layers located between them. The input layer is the interface to data, whereas the output layer supplies the ANNs response. Hidden neurons communicate only with other neurons and form the large internal network that determines the solution (Agatonovic-Kustrin and Beresford, 2000). The advantages of ANNs over regression rests in their generalizability, reduce susceptibility to noise and outliers, use of categorical data, and the ability to model nonlinear relations unknown to the modeler (Guan and Gertner, 1991; Tabe et al., 1999). However, ANNs requires a significant amount of data to train the network, cumbersome to develop, and is prone to overfitting (Abu-Mostafa et al., 2012; Haykin, 2009).

An ANN starts with the training phase, when the connections between the processing units are adjusted in a supervising learning framework (Haykin, 2009). The adjustments are made with different algorithms, like error Back Propagation or Resilient Propagation (Schmidhuber, 2015), which minimize the error between the observed and estimated output value (Heaton, 2008). The entire training process is iterative in nature, and stops when an acceptable error is achieved (Mohamad-Saleh and Hoyle, 2008). One of the features of a trained ANN, is that it can be used even when the relationships are imprecise and noisy. In forestry, the ANNs have been used to solve diverse problems, such as classification and mapping, modeling, measurement of productivity, spatial data analysis (Diamantopoulou, 2005; Diamantopoulou et al., 2015; Freitas, 2017; Guan and Gertner, 1991; Leite et al., 2011; Lek and Guégan, 1999; Mazon de Alcantara et al., 2018; Özçelik et al., 2010; Santi et al., 2017; Soares et al., 2011; Vieira et al., 2018).

Although ANNs seems to be more robust than conventional statistical or optimization modeling methods (Haykin, 2009; Tu, 1996), there are significant challenges that must be addressed, particularly the choice of the network structure and the processing time. When training ANNs, the choice of the network size and its consequent structure defines the ability of the ANN to supply accurate results, as according to (Iyer and Rhinehart, 1999) large networks not only that take longer time to learn but also tend to give accurate results for training data but not for validation data. If the network simply memorizes the given training patterns, it may perform well during training, but could fail when presented with slightly different inputs (Iyer and Rhinehart, 1999). The training effort

increases with the number of connections in the network, and it was proven that there is an optimal number of neurons in the hidden layers (Boger and Guterman, 1997). The structure of the network has also a direct impact on the generalization capabilities (Abu-Mostafa et al., 2012; Haykin, 2009; Kavzoglu and Mather, 1999), namely in the ability to recognize patterns that are not present within the training dataset. The generalization capacity decreases with the ratio of the number of connections to the number of training examples (Boger and Guterman, 1997). To solve the challenges faced by ANNs related to the size and structure of the network, the most popular approach is to reduce the size of the ANN (Karnin, 1990; Morgan et al., 2000; Reed, 1993). Among the methods used to reduce the size of an ANN the most popular are pruning (Zell et al., 1994), which is focused on elimination of neurons or connections, or principal component analysis (PCA), which starts with a reduced number of neurons defined by orthogonal combinations (Bishop, 1994).

The pruning process starts by training an ANN with a large number of neurons in the hidden layer(s). After or during the training, depending on the pruning method, the redundant neurons or the least important connections in the ANNs are eliminated (Boger and Guterman, 1997). Non-contributing units (NCU) (Reed, 1993), Skeletonization (SKE) (Dreyer, 1993), Optimum brain damage (OBD) (LeCun et al., 1990), Optimal brain surgeon (OBS) (Hassibi and Stork, 1993) are some of the algorithms aiming at removing the least effective interconnections from a large ANN (Zell et al., 1994). Starting with a large network offers the advantage of quick learning (reference) and reduces the impact of initial conditions and learning parameters (Karnin, 1990).

In eventuality that input data contains significantly correlated variables, the ANN can lack generalization, as is likely not representative of the main attributes defining the analyzed processes (Bishop, 1994). To limit the correlation among the input variables, researchers have used PCA, which identifies a set of variables that are orthogonal, consequently independent (Rencher, 2002). The PCA is fundamentally different than pruning, as it is executed before the training of ANN, during the pre-processing stage. Used in conjunction with ANN, the PCA serves two purposes: first, decreases the complexity of the network by reducing dimensionality of the problem, and secondly, reduces the correlations within the input data while maintaining the relevant variables

(Turk and Pentland, 1991). Therefore, PCA not only increases the computation speed but also decreases the chance of including redundant information in the network.

The Brazilian planted tree industry is a worldwide reference for its performance, as it is based on sustainability, competitiveness, and innovation (IBÁ, 2017). Eucalyptus has been widely used in forest plantations in Brazil due to its adaptation to different edaphic and climatic conditions, its rapid growth, wide use and knowledge of silvicultural practices (Freitas, 2017). Brazil is among the world's leading producers of pulp, paper and wood panels and leader in pig iron, with more than 120 industries that use charcoal in their production (IBÁ, 2017). With approximately 7.84 million hectares of planted trees, the Brazilian planted tree industry is responsible for 91% of all wood produced for industrial purposes in the country and 6.2% of the Brazilian GDP, and it is one of the industries with the greatest potential to help build a green economy (IBÁ, 2017). The increasing demand for forest products and scarce land availability, new technologies and studies are needed to increase forest productivity without increasing planted area (Freitas, 2017).

A significant number of ANN applications are present in forestry, ranging from terrain stability (Pavel et al., 2011) to forest inventory (Diamantopoulou, 2005; Özçelik et al., 2010; Zhang et al., 2000) or climate (Corne et al., 2004; Zhang et al., 2000). Most forestry related studies using ANNs tailored the network to the allocated tasks. However, the amount of resources needed to complete the task (e.g., CPU speed or memory size), the time needed to supply the results, the complexity and expressiveness (Livni et al., 2014), namely the efficiency, garnered limited interest in forestry. Given the same resources, an efficient ANN is a network that provides an accurate solution in a very short amount of time. Several studies (Cheng and Titterington, 1994; Maier and Dandy, 2000) suggested that an efficient ANN applied to a particular problem is identified by focusing on the network structure and on the selection of the variables relevant to the process of interest. Therefore, the present study has two objectives: 1) to find the most efficient configuration and algorithm to estimate the productivity of Eucalyptus plantations at rotation age using ANNs; and 2) to test if pruning and PCA methods can improve the ANNs performances.

## 2 METHODS

### 2.1 Study area and data

The present study uses data from 507 *Eucalyptus* plantations stands located in the Minas Gerais state from Brazil. The plantations have ages between 3 years and 7 years, their size ranges from 3 ha and 79 ha, and grow on sites with productivity between 16.43 to 50.99 m<sup>3</sup>/ha/year. The data describing the plantations were obtained from three sources: the continuous forest inventory, soil measurements, and weather stations. The continuous forest inventory supplied the genotype and spacing, which served as input variables, and the annual increment of wood volume at the sixth measurement year, which is the predicted variable. The soil measurements were focused on physical and chemical properties in the first and third year, as well as on the fertilizations during the whole rotation. A total of 735 weather stations and 3635 rain gauges were used to estimate the variables thru interpolation. The water balance was calculated by the method of Thornthwaite and Mather (Thornthwaite e Mather, 1955), assuming a maximum storage capacity of 300 mm, as suggested by (Pereira et al., 2002).

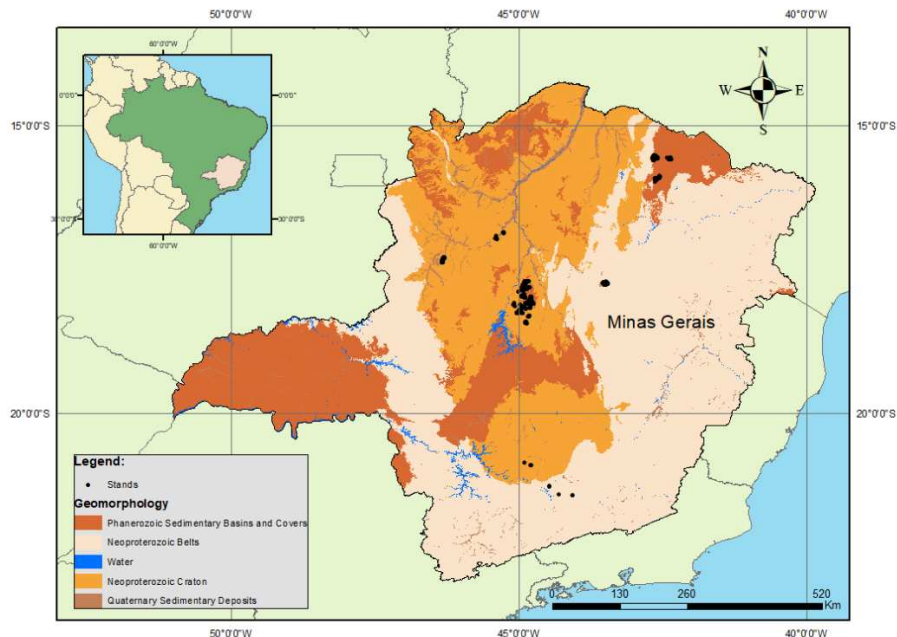


Figura 3 - Study area with the location of the plantation. The texture of the map is the geomorphology according to IBGE (2014).

The dataset contains 105 variables, out of which two were categorical, namely genotype and spacing, and the rest continuous (e.g., temperature or precipitation in year 0) (Table 3). The different genotype values were represented as G1, G2, G3, G4, G5 and G6. The spacing, expressed in meters, was 3.5 x 2.0, 3.5 x 2.5, 3.0 x 3.0, 3.0 x2.5, 3.0 x2.0 and 4.0 x 2.0. To ensure compatibility of the variable in term of magnitude, which can lead to computation errors (Rencher 2002; Tabachnick e Fidell, 2001), all continuous variables were standardization to reach values between 0 and 1 (Eq.1):

$$x_{normalized} = \left( \frac{x - \min(x)}{\max(x) - \min(x)} \right) \quad 1$$

Where x is the variable to be standardization and min and max are the minimum and maximum functions.

Tabela 3 - Continuous variables, subject to standardization.

<b>Continuous Input</b>	<b>Unit</b>	<b>Min</b>	<b>Max</b>
Total Sand (0-20 cm)	%	8.78	87.7
Clay (0-20 cm)	%	6	76
Silt (0-20 cm)	%	1.9	36.69
Al saturation (m)	%	0.72	93.9
Base saturation (V)	%	0.81	49.17
P available (P)	mg dm <sup>-3</sup>	0.47	16.86
K available (K)	mg dm <sup>-3</sup>	2.52	239.08
pH (H <sub>2</sub> O)	-	3.99	6.14
pH (CaCl <sub>2</sub> )	-	3.8	5.1
CTC	cmol <sub>c</sub> dm <sup>-3</sup>	2.19	17.16
H+Al	cmol <sub>c</sub> dm <sup>-3</sup>	1.82	16.83
Al saturation (m)	cmol <sub>c</sub> dm <sup>-3</sup>	0.02	2.76
Mg	cmol <sub>c</sub> dm <sup>-3</sup>	0.01	0.92
Ca	cmol <sub>c</sub> dm <sup>-3</sup>	0.01	1.87
Organic Matter	dag kg <sup>-1</sup>	0.7	8.17
P-remain	mg L <sup>-1</sup>	2.01	47.93
Rain 5th year	mm year <sup>-1</sup>	732.92	1946.25
Rain 4th year	mm year <sup>-1</sup>	620.68	2037.49
Rain 3th year	mm year <sup>-1</sup>	620.68	2137.08

<b>Continuous Input</b>	<b>Unit</b>	<b>Min</b>	<b>Max</b>
Rain 2th year	mm year <sup>-1</sup>	620.68	1878.03
Rain 1st year	mm year <sup>-1</sup>	557.37	2137.08
Rain year 0	mm year <sup>-1</sup>	677.52	1741.4
Rain year -1	mm year <sup>-1</sup>	647.24	1915.64
Rain year -2	mm year <sup>-1</sup>	647.24	1682.24
Temperature year 0	°C	14.34	31.47
Temperature year 1	°C	14.45	31.47
Temperature year 2	°C	15.02	31.3
Temperature year 3	°C	13.75	31.31
Temperature year 4	°C	14.17	31.31
Temperature year 5	°C	14.57	31.38
Wind Speed year 0	m s <sup>-1</sup>	0.97	1.83
Wind Speed year 1	m s <sup>-1</sup>	0.97	1.7
Wind Speed year 2	m s <sup>-1</sup>	1.1	1.65
Wind Speed year 3	m s <sup>-1</sup>	1.1	1.86
Wind Speed year 4	m s <sup>-1</sup>	1.02	1.74
Wind Speed year 5	m s <sup>-1</sup>	1.03	1.62
Potential Evapotranspiration year 0	mm year <sup>-1</sup>	1190.73	1631.69
Potential Evapotranspiration year 1	mm year <sup>-1</sup>	1225.17	1649.48
Potential Evapotranspiration year 2	mm year <sup>-1</sup>	1133.52	1679.51
Potential Evapotranspiration year 3	mm year <sup>-1</sup>	1154.58	1712.15
Potential Evapotranspiration year 4	mm year <sup>-1</sup>	1258	1712
Potential Evapotranspiration year 5	mm year <sup>-1</sup>	1188	1671
Air Humidity year 0	%	62.55	79.25
Air Humidity year 1	%	62	77.98
Air Humidity year 2	%	60.69	81.07
Air Humidity year 3	%	59.97	78.82
Air Humidity year 4	%	59.97	75.28
Air Humidity year 5	%	61.72	77.73
Radiation year 0	MJ m <sup>-2</sup>	16.41	20.7
Radiation year 1	MJ m <sup>-2</sup>	17.1	20.86
Radiation year 2	MJ m <sup>-2</sup>	15.54	20.86
Radiation year 3	MJ m <sup>-2</sup>	15.88	20.58
Radiation year 4	MJ m <sup>-2</sup>	17.01	20.96
Radiation year 5	MJ m <sup>-2</sup>	16.17	20.96
Hidrological Deficit year 5	mm year <sup>-1</sup>	185.2	857.42
Hidrological Deficit year 4	mm year <sup>-1</sup>	146.5	1000.66

<b>Continuous Input</b>	<b>Unit</b>	<b>Min</b>	<b>Max</b>
Hidrological Deficit year 3	mm year <sup>-1</sup>	76.62	1000.66
Hidrological Deficit year 2	mm year <sup>-1</sup>	122.66	100.66
Hidrological Deficit year 1	mm year <sup>-1</sup>	184.67	869.22
Hidrological Deficit year 0	mm year <sup>-1</sup>	146.88	915.52
Hidrological Deficit year -1	mm year <sup>-1</sup>	65.39	915.52
Hidrological Deficit year -2	mm year <sup>-1</sup>	78.49	838.73
Rain median (1980 - 2013)	mm year <sup>-1</sup>	812.63	1513.39
Max Temp median (1980 - 2013)	°C	25.87	30.75
Med Temp median (1980 - 2013)	°C	14.66	18.99
MinTemp median (1980 - 2013)	°C	20.32	24.87
Wind Speed median (1980 - 2013)	m s <sup>-1</sup>	1.18	1.44
Potential Evapotranspiration (1980 - 2013)	mm year <sup>-1</sup>	1182.81	1582.27
Air Humidity median (1980 - 2013)	%	63.84	78.02
Hidrological deficit median (1980 - 2013)	mm year <sup>-1</sup>	111	799
Radiation median (1980 - 2013)	MJ m <sup>-2</sup>	16.26	19.26
N Fertilization	kg ha <sup>-1</sup>	0	60.93
P <sub>2</sub> O <sub>5</sub> Fertilization	kg ha <sup>-1</sup>	0	325.81
K <sub>2</sub> O Fertilization	kg ha <sup>-1</sup>	53.71	512.14
CaO Fertilization	kg ha <sup>-1</sup>	0	1100.78
MgO Fertilization	kg ha <sup>-1</sup>	0	255.45
S Fertilization	kg ha <sup>-1</sup>	0	45.92
B Fertilization	kg ha <sup>-1</sup>	0	9.26
Cu Fertilization	kg ha <sup>-1</sup>	0	5.75
Zn Fertilization	kg ha <sup>-1</sup>	0	7.72

## 2.2 Principal Component Analysis

An efficient ANN does not necessarily requires all the 105 variables as input, particularly if they are strongly correlated (Bishop, 1994). One method to eliminate redundant variable (Guyon e Elisseeff, 2003; Khalid et al., 2014) is Principal Component Analysis, henceforth PCA, (Howley et al. 2006; Wu e Chau, 2011). PCA is a dimensional reduction technique that find linear transformations of the original input variables,  $x_1, x_2,$



...,  $x_q$ , into uncorrelated variables  $y_1, y_2, \dots, y_p$ , called principal components (Tabachnick e Fidell, 2001). To find a  $y$  component, PCA maximizes the variance of the linear combination of the  $x$  variables for that particular component (Rencher, 2002). Conventionally, the components are chosen such that  $y_1$  has maximum variance among all  $y$ s,  $y_2$  has maximum variance subject to being uncorrelated with  $y_1$ , and so forth (Eqs 1 and 2) (Mohamad-Saleh e Hoyle, 2008).

$$y_i = Ax_i \quad 2$$

where  $y_i$  is the PCA value,  $x_i$  is the original input, and  $A$  is an orthogonal matrix.

The variances of the principal components are the eigenvalues of the covariance matrix (Rencher, 2002), which is a diagonal matrix (Eq. 3). The significant components (namely the largest eigenvalues) are used to transform the original data into a domain on which the variables are orthogonal, which subsequently serve as input to the ANN (Neumann, 2002).

$$\mathbf{y} = \mathbf{A}\mathbf{S}\mathbf{A}^T = \begin{pmatrix} s_{y_1}^2 & \dots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \dots & s_{y_p}^2 \end{pmatrix} \quad 3$$

where  $\mathbf{S}$  is the covariance matrix of  $\mathbf{y}$ ,  $\mathbf{A}^T$  is the transpose of  $\mathbf{A}$ , and  $s_{y_i}^2$  are the diagonal values of  $\mathbf{S}$ .

The usage of PCA in conjunction with ANN, a method labeled in this paper as PCA-ANN, has been applied in other studies (Charytoniuk e Chen, 2000; Mohamad-Saleh e Hoyle, 2008; Neumann, 2002; Oliveira-Esquerre et al., 2002; Tabe et al., 1999) to reduce the dimension of the input space. in the artificial neural network (ANN) models while lowering the training time and preserving or even improving the ANN model accuracy (Zekić-Sušac et al., 2013).

## 2.3 Artificial Neural Network and pruning

### 2.3.1 Structure of the ANN and training algorithms

Execution of any ANN depends on a large number of choices, chief among them being the structure of the network and the training algorithm. Intuitively, an efficient ANN should use the optimal input not all the available variables; therefore, we have reduced the size of the neural network using two approaches: one by using a subset of the original variables selected thru PCA and one by pruning the structure of the ANN during its training.

In our study, we have decided to use the multilayer perceptron (MLP) ANN architecture, as it is a simple structures yet supplies accurate results (Haykin, 2009). MLP is a feed-forward networks (Zell et al., 1994), wherein connections between the nodes do not form a cycle (the information moves only forward, from the input to the output nodes (Figure 4). Haykins (2009) detailed the basic features of an MLP, which are:

- (1) Neurons of a same layer are not connected among them but only to those of other layers.
- (2) Signals flow only in one direction, from the input layer to the output layer, which is why this class of ANN is also called feed-forward neural networks.
- (3) The number of neurons in the input layer is equal to the number of the variables used as input in your model,
- (4) The number of neurons in the output layer is equal to the number of classes or homogenous groups of objects supposedly present in the learning database, and
- (5) The number and size of hidden layers should be adequately fixed for each particular application.




Figura 4 - Multilayer perceptron with two hidden layers and an output layer. (adapted from Haykin, 2009)

MLP ANN architecture trained with backpropagation based algorithms is currently the most used the network with backpropagation methods is currently the most popular in forestry applications (Blackard e Dean, 1999), being used to predict forest fire (Safi e Bouroumi, 2013), to estimate volume of eucalypt trees (da Silva et al., 2010), to model nonlinear ecological relationships (Castro et al., 2013), or to reduce sample intensity (Tavares Júnior et al., 2019).

An ANN algorithm adjusts its weights to obtained the desired system behavior according to the Hebbian rule, which contains two parts (Changeux e Danchin, 1976; Haykin, 2009; Stent, 1973):

- If two neurons on either side of a synapse (i.e., connection) are activated simultaneously, also labeled as synchronously, then the strength of that synapse is selectively increased.
- If two neurons on either side of a synapse are activated asynchronously, then that synapse is selectively weakened or eliminated.

In its general form, the Hebbian rule is (Bergmeir e Benítez Sánchez, 2012):

$$\Delta w_{ij}(t) = g(a_j(t), t_j)h(o_i(t), w_{ij})$$

where:

$w_{ij}$  weight of the link from unit  $i$  to unit  $j$ ;

$a_j(t)$  activation of the unit  $j$  in the step  $t$ ;

$t_j$  teaching input, in general the desired output of unit  $j$ ;

$o_i(t)$  output of unit  $i$  at time  $t$ ;

$g(\dots)$  function, depending on the activation of the unit and the teaching input;

$h(\dots)$  function, depending on the output of the preceding element and the current weight of the link.

Similarly to any feed-forward ANN, we trained the MLP architecture in two phases (Haykin, 2009), forward propagation followed by back propagation. During the forward propagation phase an input is presented to the network and then is propagated forward until reaches the output. In this phase, all the weights are fixed. The forward propagation estimated output is compared with the observed output. The difference between the estimated and observed outputs is then propagated backward and used to adjust the weights such that the network is improved. The sequence forward-backward propagation is executed until a predefined error is reached.

We have selected six feed-forward ANNs training algorithms: Standard Backpropagation (Younger et al., 2001), Backpropagation Momentum (Hagiwara, 1992; Vogl et al., 1988), Backpropagation Chunk (Zell et al., 1994), Backpropagation Weight Decay (Hinton, 1989; Werbos, 1988), Resilient Propagation (Riedmiller e Braun, 1993) and Scaled Conjugate Gradient (Møller, 1993). The choice of the six algorithm is based on their presence in studies with approximated function (Chakraborty et al., 1992; Geva e Sitte, 1992; Guliyev e Ismailov, 2016; Habarulema e McKinnell, 2012).

The Backpropagation algorithm is a family of methods that use a gradient descent approach that exploit the chain rule. Its iterative, recursive, and efficient method for calculating the weights improves the network until it is able to perform the task for which it is being trained (Goodfellow, et al., 2016). The correction applied to the weights connecting the neuron  $i$  to neuron  $j$  is the delta rule (Haykin, 2009):

$$\Delta w_{ji}(t) = \eta \delta_j(t) o_i(t)$$

where  $\Delta w_{ji}(t)$  is the weight correction in the cycle  $t$ ;  $\eta$  is the learning rate;  $\delta_j(t)$  is the local gradient of the unit  $j$  in the cycle  $t$  (error of the unit  $j$ ) and the  $o_i(t)$  is the input signal of the neuron  $j$  (from neuron  $i$ ).

The learning rate  $\eta$  is used to measure how fast the weights are updated to try minimize the errors (Haykin, 2009). This value is restricted in a range of  $0 \leq \eta \leq 1$ . (Bullinaria, 2014) says that the choice of an optimal value for this parameter is limited for

two opposite factors: if too small, the time to reach the minimum of the error function will be too long; if too big, the weights updates can miss some optimal solution and their values can oscillate. (da Silva et al., 2010) suggest values between 0.05 and 0.75. In this study we used 0.4. The Standard Backpropagation algorithm use only the learning rate as a parameter.

The Backpropagation Momentum is a modification of the Standard Backpropagation by adding a new parameter (momentum rate ( $\mu$ )), with the purpose of accelerating the learning rate (Hagiwara, 1992). The momentum rate ( $\mu$ ) regulate how much the weights is going to be changed in each interaction, speeding up the training process (Haykin, 2009). The Hebbian formulation of the algorithm is:

$$\Delta w_{ji}(t) = \eta \delta_j(t) o_i(t) + \mu \Delta w_{ji}(t)$$

where the  $\mu$  is the momentum rate.

Backpropagation Chunk is another modification of the Standard Backpropagation. This algorithm creates a new parameter, called chunk, whose size is the number of patterns to be present inside the network before making any alternations to the weights. This algorithm is encountered when training is based on large data sets or when convergence is too slow (Zell et al., 1994).

Backpropagation Weight Decay decreases the weights of the links while training them with Backpropagation Standard algorithm. In addition to each update of a weight by backpropagation, the weight is decreased by a part  $d$  of its old value (Bergmeir e Benítez Sánchez, 2012). This algorithm forces some of the weights to take values close to zero, while permitting other weights to retain relatively large values. The weights are grouped roughly into two categories (Haykin, 2009): that have a significant influence on the network's performance and who have practically little or no influence on the network's performance. The fundamental belief is that small weights represent idiosyncratic patterns in the training set and should not be maintained, for generalization purposes. The implementation of weight decay is to add a bias term,  $\beta$ , to the original function (Gupta e Lam, 1998):

$$\Delta w_{ij}(t) = \eta \delta_j(t) o_i - \beta w_{ij}(t)$$

where  $w_{ij}$  is the weight that connect the neuron  $i$  to  $j$ ;  $t$  is the cycle;  $\eta$  is the learning factor;  $\delta_j$  is the error of the unit  $j$ ;  $o_i$  is of the preceding unit  $i$ ;  $\beta$  is the decrease parameter.

Resilient Propagation is a local adaptive algorithm, performing supervised batch learning in the multi-layer perceptron neural network (Riedmiller e Braun, 1993). The basic principle consists in elimination of the weights with undesired influence on the partial derivatives. Consequently, only the sign of the derivative is considered to indicate the direction of the weight update. The size of the weight change is exclusively determined by a weight-specific, so-called 'update-value' (Zell et al., 1994). Every time the partial derivative of the weight  $w_{ij}$  changes its sign, which indicates that the last update was too big and the algorithm has jumped over a local minimum, the update-value is decreased by the factor  $\eta$ . The Resilient Propagation algorithm has three parameters: the initial update-value, a limit for the maximum step size and the weight decay exponent  $\alpha$ .

All Backpropagation variants and Resilient propagation are based on the gradient descend algorithm, have poor convergence rate and depend on the parameters specified by the user without theoretical basis for choosing them (Møller, 1993). To avoid these limitations, the Scaled Conjugate Gradient (SCG) algorithm uses the line search per learning iteration and a Levenberg-Marquardt approach to scale the step size (Gill et al., 1981). While standard backpropagation always proceeds down the gradient of the error function and depends on parameters which have to be specified by the user, a conjugate gradient method will choose the search direction and the step size using the information of the second order approximation of the error in the previous step (Gill et al., 1981). Therefore, the minimization performed in one step is not partially undone by the next, as it is the case with standard backpropagation and other gradient descent methods (Zell et al., 1994).

The SCG is fully automated and includes no critical user-dependent parameters. The learning rate and the step size is updated in each iteration as follow:

$$w_{k+1} = w_k + \alpha_k \rho_k$$

$$\rho_k = \exp\left(\frac{-\Delta E}{N}\right)$$

$$\alpha_k = \frac{E'(w_k + \sigma_k * \rho_k) - E'(w_k)}{\sigma_k} + \lambda_k * \rho_k$$

Where:

$w_{k+1}$  is the value of the weight in the iteration  $k + 1$ ;  $w_k$  is the value of the weight in the iteration  $k$ ;  $\alpha_k$  is the size of the step (an simple approximation of the Hessian matrix of the error function);  $\rho_k$  is a new conjugate direction ;  $\Delta E$  is the error;  $N$  is the number of weights;  $E'(w_k)$  is the first derivate of the error function;  $E'(w_k + \sigma_k * \rho_k)$  is the first derivate of the error function with the values of the weight updated;  $\lambda_k$  is scalar to regulate the Hessian matrix;

Irrespective of the neural network, the numbers of neurons in the hidden layer plays a significant role in the efficiency of an ANN, avoid overtraining, and increases the capacity of generalization (Haykin, 2009). Overfitting is thought to occur when the network has more degrees of freedom (i.e., the number of weights) than the number of the training samples (Reed, 1993). Abu-Mostafa et al. (2012) suggest that a good ratio for degrees of freedom/samples is 1/10. As in our study we have only 507 samples, we decided to evaluate the impact of the number of neurons from the hidden layer by varying their number from 1 to 30 (ratio 1/5 throw 1/0.16 using original data and 1/41 throw 1/1.38 using PCA data), in increments of 1.

We used the MLP architecture as implemented by the RSNNS package (Bergmeir e Benítez Sánchez, 2012) for R project version 3.5.2 (Gentleman e Ihaka, 2014). Both the input and hidden activation functions use the logistic model, as suggested by Eliane (2017). The stop criteria used was 1000 cycles or 0.001 average error. We split the data following the recommendations of Eliane (2017), with 90% for training and 10% for testing.

### 2.3.2 Structure of the ann and training algorithms

Among the ANN pruning methods available we have focused only on the Magnitude Based Pruning (MP), Optimal Brain Damage (OBD), Optimal Brain Surgeon (OBS), Skeletonization (SKE) and Non-contributing Units (NCU). These pruning techniques is based on removing the least effective inter connections in an initially large network (Kavzoglu e Mather, 1999) and each one is an improvement (and more complex) than the previous one. Each pruning methods eliminates the neurons and the links among them by concentrating on a particular facet of the neural network. The five pruning

methods train and prune an ANN alternately, according to the following algorithm (Zell et al., 1994):

- Step 1: Choose a reasonable network architecture.
- Step 2: Train the ANN with a training algorithm.
- Step 3: Compute the saliency of each element (weights or neurons).
- Step 4: Prune the element with the smallest saliency.
- Step 5: Retrain the ANN.
- Step 6: If the error is too big, repeat the procedure from step 3 on.
- Step 7: If the error is less than a desired value, then stop.

The difference among the five pruning algorithms is on the decision which element will be removed. The Magnitude Based Pruning is the simplest pruning algorithm, as after each training, the link with the smallest weight is removed (Zell et al., 1994). The Optimal Brain Damage (OBD) (LeCun et al., 1990) uses the second-order derivatives of the error function to control the network pruning (Kavzoglu e Mather, 1999). The objective is to remove weights associated with inter-neurons connections whose removal will result in the least increase of network error (Kavzoglu e Mather, 1999). This method use the Hessian matrix, increasing the computational cost (Zell et al., 1994). The Optimal Brain Surgeon (OBS) (Hassibi e Stork, 1993) is a development of OBD, in which the Hessian matrix is computed to assess saliency and weight change for every link (Kavzoglu e Mather, 1999). OBS uses much more resources (i.e., memory and process time) than OBD. The Skeletonization (SKE) (Mozer e Smolensky, 1989) prunes units by estimating the change of the error function when the unit is removed (like OBS and OBD do for links) (Zell et al., 1994). The Non-contributing Units (NCU) (Sietsma e Dow, 1991) uses arithmetic mean to find units that don't contribute to the net's behavior (Zell et al., 1994).

The computations were implemented using the default parametrization of each pruning algorithm, as implemented in the RSSN package (Zell et al., 1994) (Table 4).



Tabela 4 - Parameters for pruning algorithm.

Parameter	Value
Maximum error increase (%)	10
Accepted error	1
Learn cycles for retraining	1000
minimum error to stop	0.01
initial value for matrix	1.00E-06

## 2.4 The ANN assessment

The most efficient ANN configurations were identified using four statistics, similar to Fang and Strimbu (2017): bias (Eq.4), mean absolute error (Eq. 5), root mean square error (RMSE) (Eq. 6), and Pearson correlation coefficient (Eq. 7). The Pearson correlation coefficient indicate the direct relationship between the observed and computed values, the RMSE measures the precision, whereas the bias estimates the accuracy (Freedman et al., 1980).

$$bias = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)}{n} \quad 4$$

$$Mean\ Absolute\ Error = MAE = \frac{\sum_{i=1}^n |y_i - \hat{y}_i|}{n} \quad 5$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad 6$$

$$r_{\hat{y}} = \frac{n^{-1} \sum_{i=1}^n (\hat{y}_i - \hat{y}_m)(y_i - \bar{y})}{\sqrt{n^{-1} \sum_{i=1}^n (\hat{y}_i - \hat{y}_m)^2 n^{-1} \sum_{i=1}^n (y_i - \bar{y})^2}} \quad 7$$

where  $y_i$  is the observed value of output sample  $i$ ;  $\hat{y}_i$  is the estimated value of output sample  $i$ ;  $\hat{y}_m$  is estimated mean values;  $n$  is the number of observations;  $\bar{y}$  is the mean of all the observed stands.

To ensure that all possible combinations of the factors defining the performance of an ANN are present, we have used a factorial experiment, with 2160 values (i.e., 2 datasets x 6 training algorithms x 30 number of neurons x (5 pruning methods + no pruning)). Because the values for the initial weights are randomly selected, for each of the combination we have rerun the ANN five times, which lead to 10,800 values. The ANNs were trained five times with random initialization of weights to try to avoid problems of local minima (Iyer e Rhinehart ,1999).

We executed a formal assessment of the ANNs performances by integrating all the metrics. A possible integration is simply the sum of the ranks of the ANNs according to each metric. However, inference based on rank is non-parametric in nature, therefore we also performed hierarchal cluster analysis (Rencher, 2002) , using correlation coefficient, RMSE, bias and processing time to identify if the ANNs can be grouped. The agglomeration criterion was performed with Ward method, as suggested by Rencher (2002) We selected the best model or group of models using scree plot (Tabachnick e Fidell, 2001), and presented the results as suggested by Hardle and Simar (2003) We executed the computation in R-project version 3.5.2 (Gentleman e Ihaka, 2014).

### 3 RESULTS

We applied PCA method to all 105 original variables and selected 12 principal components that totalize 90% of all variation in the input data (Table 5). Each principal component is a linear product between the standardized observed variable and its contribution to that principal component.

Table 5 - Principal Components supplying >90% of all variation, their eigenvalues and relative contribution [%]

Principal Component	Eigenvalue	Variance (%)	Cumulative Variance [%]
1	37.52	39.91	39.91
2	14.88	15.83	55.74
3	8.24	8.77	64.51
4	5.66	6.02	70.54
5	4.66	4.95	75.49
6	3.11	3.31	78.80
7	2.75	2.93	81.73
8	2.10	2.23	83.96
9	1.74	1.85	85.81
10	1.43	1.52	87.33
11	1.33	1.41	88.74
12	1.19	1.26	90.01

The 20st least unbiased ANNs contains pruned and unpruned networks (Table 3) Using input without preprocessing, the best ANN produced correlation values between 0.579 and 0.792, RMSE from 2.96 to 4.29, *bias* from -0.11 to 0.29 and processing time from 12.88 to 31.73 sec. These values were obtained using Resilient Propagation with seven neurons and the Skeletonization (SKE) pruning method.

For the models using PCA data the correlations were from 0.28 to 0.76, RMSE from 2.63 to 4.4, *bias* from -0.13 to 0.27 and processing time from 0.99 to 48.18 sec. Statistically, the best results are using Scale Conjugate Gradient (SCG) with Magnitude Based Pruning (MP) and four neurons. A higher number of neurons and use of pruning methods increase the processing time without give the same order in accuracy.

Among the top 20 ANNs, only one uses input data without preprocessing, namely without PCA, and five supply the best results using pruning methods (Table 6) Overall, the best results for predict the *Eucalyptus* productivity using edaphics, climatic, fertilization and inventory data were obtained training the ANN on the PCA data but with no pruning.

Table 6 - Statistics for top 20 ANNs according to bias.

(The abbreviations in the table are for training algorithm: BPM = Backpropagation Momentum; BPW = Backpropagation Weight Decay; BPC = Backpropagation Chunk; SBP = Standard Backpropagation; RPR = Resilient)

Data	Algorithm	Neurons	Pruning	Correlation	RMSE	Bias	MAE	Time
PCA	SCG	4	-	0.7 (0.61-0.76)	3.25 (2.88-3.55)	0.315 (0.278-0.343)	6.13 (5.58-6.69)	1.14 (1.01-2.48)
PCA	Back Propagation	18	-	0.65 (0.29-0.69)	3.28 (2.63-7.56)	0.325 (0.321-0.364)	8.89 (8.26-9.33)	1.32 (1.23-1.37)
PCA	B Momentum	21	-	0.66 (0.59-0.73)	3.67 (3.29-4.22)	0.356 (0.318-0.407)	5.56 (5.26-5.77)	1.12 (0.99-1.47)
PCA	B Weight Decay	6	-	0.63 (0.61-0.69)	4 (3.7-4.19)	0.386 (0.357-0.404)	5.78 (5.71-5.93)	1.29 (1.19-1.5)
PCA	Resilient	7	-	0.66 (0.61-0.72)	3.99 (3.21-3.76)	0.333 (0.31-0.363)	6.02 (5.45-6.7)	1.8 (1.73-1.95)
PCA	B Momentum	4	-	0.67 (0.63-0.69)	3.79 (3.67-3.91)	0.366 (0.355-0.377)	5.88 (5.53-6.17)	1.84 (1.42-1.98)
PCA	SCG	19	-	0.66 (0.59-0.73)	3.36 (3.05-3.63)	0.325 (0.295-0.350)	7.42 (6.36-8.13)	2.42 (1-3.13)
PCA	B Momentum	18	-	0.63 (0.59-0.67)	4.1 (3.92-4.25)	0.396 (0.379-0.411)	6.04 (5.72-6.32)	1.86 (1.77-2)
PCA	Resilient	6	-	0.65 (0.58-0.71)	3.45 (3.21-3.74)	0.36 (0.309-0.374)	6.14 (5.36-6.5)	2.81 (1.21-3.41)
PCA	SCG	5	-	0.61 (0.56-0.7)	3.52 (3.2-3.74)	0.341 (0.308-0.361)	6.64 (6.26-6.89)	2.71 (1.11-3.33)
PCA	B Chunck	21	-	0.63 (0.57-0.65)	4.04 (3.82-4.38)	0.391 (0.368-0.423)	5.92 (5.68-6.43)	2.3 (1.93-2.42)
PCA	B Momentum	30	-	0.64	3.98	0.385	5.96	2.66

Data	Algorithm	Neurons	Pruning	Correlation	RMSE	Bias	MAE	Time
				(0.6-0.7)	(3.76-4.3)	(0.363-0.415)	(5.5-6.23)	(1.3-3.1)
PCA	B Chunck	30	-	0.65 (0.61-0.7)	3.99 (3.7-4.33)	0.386 (0.357-0.418)	6.15 (5.97-6.4)	3.08 (2.46-3.33)
PCA	SCG	4	MP	0.7 (0.56-0.76)	3.01 (2.93-3.86)	0.312 (0.282-0.372)	6.3 (5.47-7.15)	18.97 (15.21-48.18)
PCA	B Weight Decay	30	-	0.62 (0.58-0.67)	4.15 (3.72-4.4)	0.401 (0.359-0.425)	6 (5.62-6.21)	2.66 (1.3-3.1)
PCA	Back Propagation	30	-	0.61 (0.6-0.63)	4.22 (4.14-4.35)	0.407 (0.399-0.420)	6.02 (5.88-6.23)	2.56 (2.3-3)
PCA	Resilient	7	NCU	0.57 (0.42-0.68)	3.73 (3.28-4.25)	0.3621 (0.317-0.410)	5.91 (5.52-6.65)	12.78 (5.42-36.2)
All	Resilient	7	SKE	0.63 (0.58-0.79)	3.92 (2.96-4.3)	0.362 (0.285-0.415)	5.59 (5.31-5.8)	20.92 (12.88-31.73)
PCA	Resilient	4	OBD	0.58 (0.47-0.68)	3.75 (3.3-4.31)	0.363 (0.319-0.416)	6.37 (5.95-6.98)	21.07 (18.78-22.98)
PCA	SCG	4	OBD	0.61 (0.49-0.69)	3.55 (3.34-3.99)	0.344 (0.323-0.385)	5.9 (5.25-6.66)	24.82 (17.77-33.16)

The top 10 ANN performing the best overall were trained on a reduced dataset and had no pruning (Table 7). The top two ANNs did not excel in any metric, but they were ranked in top three in at least two (four for the best performance). Was interesting to notice all the six training algorithms, produced outputs ranked in top 20, in term of bias, but only four pruning algorithms were present (i.e., Magnitude Based Pruning, Optimal Brain Damage, Skeletonization and Non-contributing Units), none of which were overall ranked in top 10 (Table 7). Another interesting result is associated with the number of neurons, which clearly shows a dichotomy, as the number of neurons needed for accuracy are either few ( $\leq 7$ ) or many ( $\geq 18$ )

Tabela 7 - Ranking of the top 20 ANNs according to correlation, bias, MAE, RMSE, and time to produce the solution. (BPM = Backpropagation Momentum; BPW = Backpropagation Weight Decay; BPC = Backpropagation Chunk; SBP = Standard Backpropagation; RPR = Resilient Propagation; SCG- Scaled Conjugate Gradient; and for pruning method: MP Magnitude Based Pruning, OBD Optimal Brain Damage, SKE Skeletonization; NCU -Non-contributing Units.

Data	Algorithm	Neurons	Pruning	Rank					
				Correlation	RMSE	Bias	MAE	Time	Overall
PCA	SCG	4	-	2	2	2	3	9	1
PCA	SBP	18	-	12	3	3	6	24	2
PCA	BPM	21	-	8	10	11	1	30	3
PCA	BPW	6	-	20	27	26	5	78	4
PCA	RPR	7	-	7	26	5	54	92	5
PCA	BPM	4	-	6	15	17	61	99	6
PCA	SCG	19	-	9	4	4	130	147	7
PCA	BPM	18	-	19	33	33	65	150	8
PCA	RPR	6	-	10	5	13	143	171	9
PCA	SCG	5	-	25	6	6	139	176	10
PCA	BPC	21	-	18	29	29	123	199	11
PCA	BPM	30	-	16	24	25	135	200	12
PCA	BPC	30	-	10	25	26	149	210	13
PCA	SCG	4	MP	1	1	1	219	222	14
PCA	BPW	30	-	23	36	36	135	230	15
PCA	SBP	30	-	26	38	38	134	236	16
PCA	RPR	7	NCU	37	13	14	212	276	17
All	RPR	7	SKE	20	20	15	229	284	18
PCA	RPR	4	OBD	33	14	16	231	294	19
PCA	SCG	4	OBD	27	8	8	260	303	20

Different studies suggest that the ideal size of the data required for meaningful and reliable ANNs is approximately 10 times the number of weights in the network (Haykin, 2009), as the more complex the ANN are, the more parameters the network consumes. And, the more parameters it consumes, the more data are needed for training the network (Alwosheel et al., 2018). Since in this study we use only 507 samples, it is expected that the best results come those obtained with PCA, due to the lower number of connections in the input layer, considering that we have selected 12 principal components.

The hierarchical cluster analysis supports the simple summary results, with PCA outputs clearly distinguished from the models that uses the original data (Figure 5), by providing superior results in processing time (0.99 to 1100 sec.), correlation (0.14 to 0.76), RMSE (2.88 to 7.56) and bias (-0.27 to 0.59). The results based on original data were the worst in processing time (7.75 to 13229 sec.), correlation (0.1 to 0.79), RMSE (2.95 to 9.33) and bias (-0.28 to 0.61).

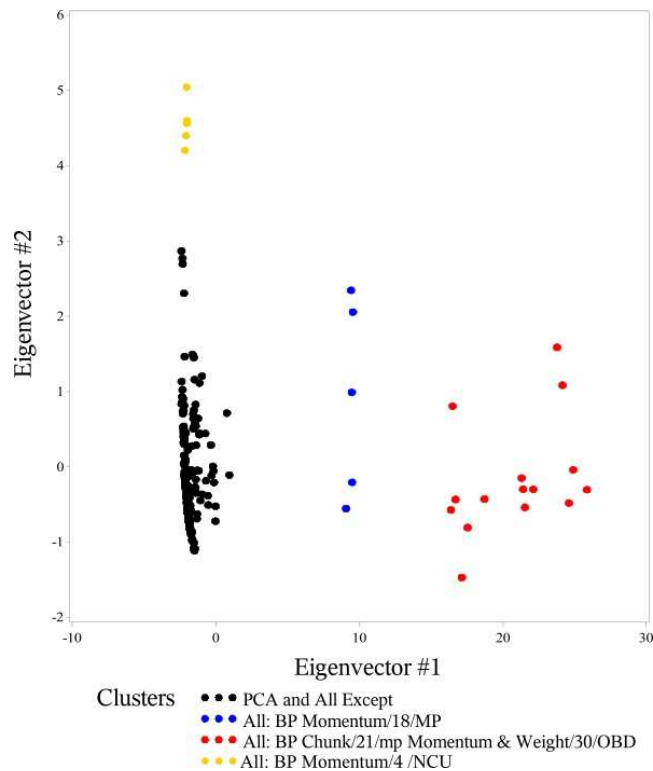


Figura 5 - Hierarchical Cluster Analysis of the ANNs performances

The best ANN in term of bias, RMSE, and correlation coefficient, has four neurons in the hidden layer, was trained on the PCA data (pre-processed) with the Scaled Conjugate Gradient algorithm, and the pruning was executed with the

Magnitude Based Pruning (MP) method. However, the ANN with the same elements, except pruning, delivered similar results in almost one second, less than one order of magnitude timewise (i.e., 18.97 vs 1.14 (Table 7)). The pair comparison t-test executed using 30 repetition shows that there is no difference between the estimation of the two ANN configurations (p-value=0.212). The values generated across the range of IMA6 supports t-test findings, as they align around the first bisector of the first quadrant (Figure 6).

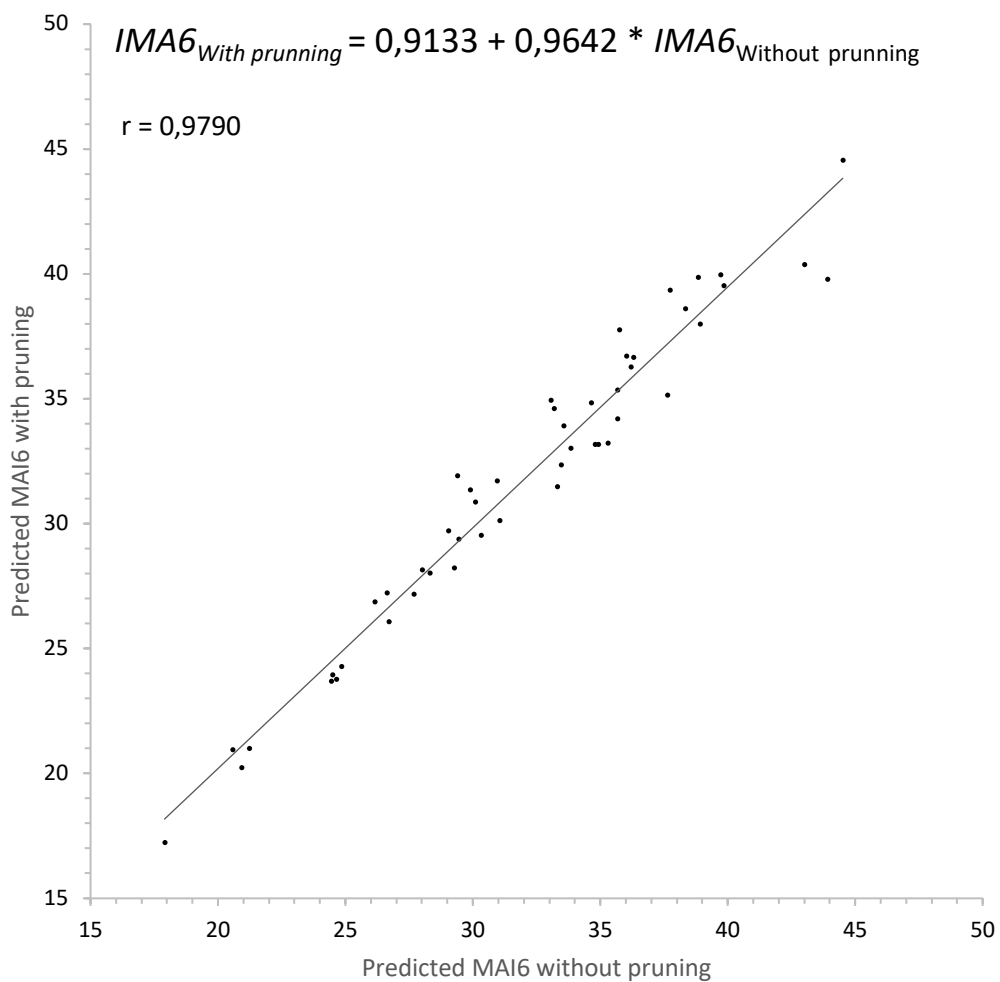


Figura 6 - Performance of the pruned and unpruned ANNs, one of which supplied the top results in term of bias, RME and correlation coefficient.

The residual and observed/predicted plots of the two ANNs configurations (i.e., networks with and without pruning that had four neurons in the hidden layer and was trained on the PCA data with the Scaled Conjugate Gradient algorithm) shows no tendencies in the training and test data, and for the test data (**Erro! Fonte de**



**referência não encontrada.**Figure 7). However, the model without pruning exhibits less variability than the model with pruning, which supports the conclusion that Eucalyptus productivity can be predicted accurately from edaphic, climatic, physiographic and fertilization data (Figure 7).

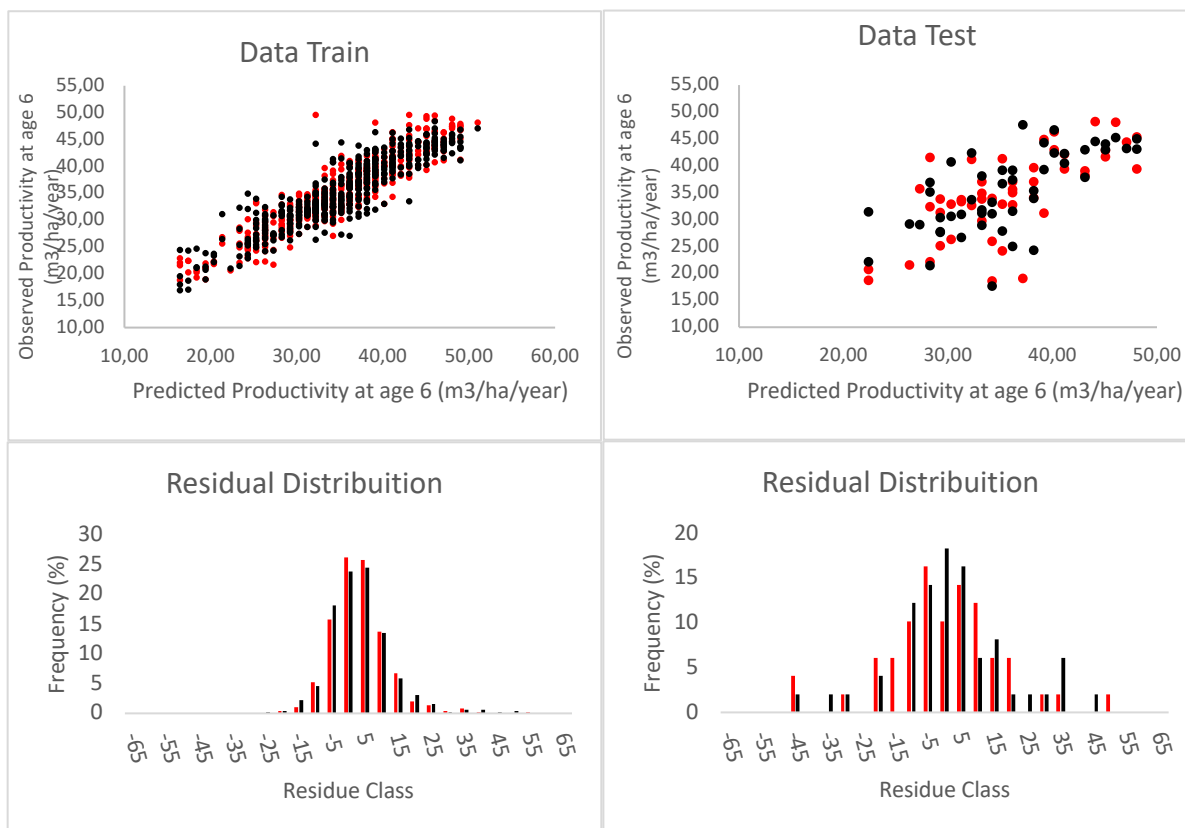


Figura 7 - Observed vs Predicted values and Residuals of ANNs trained with SCG with four neurons in the hidden layer (red – no pruning, black –pruned)

When compared with other growth and yield models, our study shows best results in precision and some in accuracy over models that use environmental and silvicultural variables without using only forest inventory data .Models like 3-PG, although generalists like ANN, are more complex and need more processing steps, making their practical application difficult (Maestri et al., 2013). Other ANNs uses techniques to reduce the number of input variables, making these ANNs less generalist. Other models that use inventory data (dbh, height and age) have better results in accuracy, showing the importance of this data to modeling growth and yield.

Tabela 8 - Growth and yield models.

<b>Paper</b>	<b>Method</b>	<b>Bias</b>	<b>Bias Ratio</b>	<b>RMSE</b>	<b>RMSE ratio</b>	<b>Variables</b>
(Freitas, 2017)	ANN	0.25	1.26	23.09	0.141	Genotype, spacing, soil texture and chemical properties, precipitation, temperature, wind speed, average potential evapotranspiration, air humidity, hidrological deficit and fertilization: N, P, K, Ca, Mg, S, B, Cu, Zn.
(Mazon de Alcantara et al., 2018)	ANN	-0.016	-19.69	9.15	0.355	Dominant Height, basal area, temperature, relative humidity, average precipitation, wind speed, total radiation
(Mazon de Alcantara et al., 2018)	ANN	-	-	22.1	0.147	Temperature, Relative humidity, Average precipitation, Wind speed, Total radiation
(Binoti et al., 2015)	ANN	-	-	18.11	0.179	Age, Genotype, Basal Area
(de Oliveira et al., 2018)	3PG	-44.53	-0.01	11.18	0.291	Ratio of foliage, NPP to roots , litterfall rate, root turnover, temperature, parameter related with soil water availability, sleaf area paremeters, coefficient for absorption of PAR by canopy , canopy parameters, Ratio NPP/GPP, stomatal response/atmospheric vapour pressure deficit, allometric relations, height vs dbh, volume vs dbh, mas vs volume

<b>Paper</b>	<b>Method</b>	<b>Bias</b>	<b>Bias Ratio</b>	<b>RMSE</b>	<b>RMSE ratio</b>	<b>Variables</b>
(de Oliveira et al., 2018)	3PG	-5.42	-0.06	5.82	0.558	Same as above
(Stape et al., 2004b)	3PG	48.81	0.01	12.3	0.264	NPP/GPP ratio, canopy efficiency, leaf area, age canopy cover, canopy albedo, intercepted rainfall, stomatal conductance, stomatal response/atmospheric vapour pressure deficit, litterfall, foliage/stem, stem mass/dbh, NPP to roots, fertility parameter, available soil water, soil texture, temperature.
(Stape et al., 2004b)	3PG	8.55	0.04	5.6	0.580	Same as above
(da Silva et al., 2016)	Lidar	-0.58	-0.54	12.02	0.270	Height of the top of the canopy and the skewness of the vertical distribution of lidar points
(Cunha, 2016)	Regression	-0.521	-0.6	19.67	0.165	Basal area, Age, Site index

## 4 DISCUSSIONS

The quality of forest management plans hinges on the reliability of growth and yield models to predict forest productivity (Ashraf et al., 2015). The growth and yield models are adjusted with historical data and exhibits low bias at regional scales (Monserud, 2003; Vanclay, 1994) or where the growing conditions are similar to the conditions for which they were developed (Ashraf et al., 2015). Because the assumption that climatic and environmental conditions significant changed in the last 50 years (Johnsen et al., 2001; Medlyn et al., 2011; Monserud, 2003), it has been realized that predictions using traditional empirical models could be biased (Ashraf et al., 2015). Therefore, either new techniques that are more adjusted to the changes in the environment are developed (Strimbu et al., 2017) or valid models that include many environmental variables, like Artificial Neural Network (ANN), are produced. Multiple studies showed that in ANNs can outperform classical regression models (Chiarello, 2019), but the presence of a large number of variables when trying to predict forest productivity hinders network performance. Therefore, the number of variables was commonly reduced with sensibility analysis or just not using all of them (Freitas, 2017; Mazon de Alcantara et al., 2018). An alternative to sensitivity analysis is PCA-ANN, which was used in image classification and pattern recognition (Jilani et al., 2011; Kumar et al., 2011; Li et al., 2007; Toufiq e Islam, 2014) or function approximation (He e Ma, 2010; Jang, 2018; Jang, 2017; Noori et al., 2010; Zhang et al., 2006). PCA-ANN improves accuracy and facilitate the learning process by the reduction of the input information. The PCA-ANN has been instrumental in tree classification (Tan e Haider, 2010) and ecoregion classification (Chu, 2020), but the authors have no knowledge of neither PCA or ANN pruning being used to estimate forest productivity. Our study provides evidence that using a simplified dataset can improve the ANN performances significantly. Even more, the time consumed for pruning procedures, aiming at reducing the network, is not justified, as no significant bias was obtained.

Mazon de ALCANTARA et al. (2018) argued that eucalyptus plantations are hard to model because of the wide range of physiographic, edaphic and climatic conditions, the silvicultural practices, and the obsolete databases, which are often discarded (Oliveira et al., 2009). The whole stands models that predict productivity (Campos e Leite, 2006; Mazon de Alcantara et al., 2018), are based on annual inventory, which do not include environmental variables. To improve existing models,

Soares and Leite (2000) considered explicitly the climatic changes, which increase models uncertain (the modeling process is often based on the assumption that environmental conditions are constant). The study of Binoti et al. (2015), which used ANN to predict production of even-aged stands of eucalyptus, highlighted the importance of categorical variables to model forest productivity. The best results obtained by the ANNs of Binoti et al. (2015) have higher RMSE than the present study, likely because of a suboptimal network architecture. Using the same data of our study to project production of eucalyptus but different ANN approaches, namely training only with climatic and edaphic variables (Mazon de Alcantara et al., 2018) or variables select by sensibility analysis (Freitas, 2017), worse RMSE we obtained on the validation model data. Even using all the variables, our models provide more accurate results than similar studies, showing that complexity reduction can improve the estimation of Eucalyptus productivity even with many inputs variables, noisy and few samples. Nevertheless, the method of variable reduction seems to play a role in accuracy, as sensitivity analysis lead to inferior results than PCA or punning (Freitas, 2017). The difference among the strategies used to reduce ANN complexity can be explained by focusing on the training. The weights in PCA-ANN are trained only one time, whereas in pruned ANN the weights are analyzed to determine the level of participation in the final solution twice. If the participation is poor, then the connection is removed and the ANN is trained again (Kavzoglu e Mather, 1999).

Our study shows that PCA preprocessing reduces the dimensionality of the input data, making not only the learning process more efficient but also leading to a simpler configuration of the ANN. As a good practice, ANN with small numbers of neurons and simple configurations should be preferred, because if a problem is solvable with a network of a given size, it can also be solved by another network that imbeds the smaller one (Karnin, 1990). Our findings support the choice of a smaller network, which is more efficient in both forward computations and learning, as the computation cost, measured by the number of arithmetic operations, grows (almost) linearly with the number of synaptic connections. Evermore, we found that larger networks tend to memorize the training patterns and therefore have poor generalization ability, as pointed by Karnin (1990). This phenomenon, known in classification theory as 'tuning to the noise', occurs whenever the number of free parameters of the classifier is large relative to the training data, which was almost the case of our data. Nevertheless, our results show unequivocally that efficient ANN have

reduced complexity and are able to predict accurately *Eucalyptus* productivity from edaphics, climatic, fertilization, and inventory data.

## 5 CONCLUSION

The forest environment can be defined as the exterior forces and substances that affect forest development, structure and reproduction. To model the complex non-polynomial forest interrelations parametric and nonparametric representations were developed, such as Artificial Neural Network (ANN). ANNs, which seems to be more robust than statistical models to outliers and non-linear domains, face difficulties related to the choice of the training algorithm and structure or size of the network that directly affect its efficiency and generalization capabilities. The objective of the present study is to find the most efficient ANN configuration algorithms and pruning methods to estimate the eucalyptus productivity from geomorphologic, climatic data. Given the same hardware resources, we evaluated the efficiency of a Multilayer Perceptron ANN as the combination of the processing time to supply a solution and the accuracy of the results. We increase the efficiency of the network in two steps: one outside the ANN, thru Principal Component Analysis (PCA), which reduces the size of the input, and one inside the ANN, thru dedicated pruning methods, which reduces the number of connections and neurons. We compared the ANNs performances using five metrics: processing time, bias, root mean square error, and Pearson correlation coefficient. The most accurate result was supplied in approximately 38.81 sec by an ANN using the PCA data, trained with the Scaled Conjugate Gradient algorithm with four neurons in the hidden layer and Magnitude Based Pruning method. However, an accuracy loss of less than 1% (i.e., the second most accurate results) was obtained in 1.7 sec from the same ANN configuration, except no pruning. Therefore, we found that the most efficient prediction of *Eucalyptus* productivity does not use all the data and or the most complex training algorithms.

## REFERENCE

- ABU-MOSTAFA, Y.S., MAGDON-ISMAIL, M., LIN, H.-T., **Learning from data.** AMLBook New York, NY, USA. 2012.
- AL-AKHRAS, M., EL HINDI, K., HABIB, M., SHAWAR, B.A., **.Instance reduction for avoiding overfitting in decision trees.** Journal of Intelligent Systems 30, 438–459. 2021.
- ALCANTARA, A.E.M. DE, SANTOS, A.C. DE A., SILVA, M.L.M. DA, BINOTI, D.H.B., SOARES, C.P.B., GLERIANI, J.M., LEITE, H.G., **Use of artificial neural networks to assess yield projection and average production of eucalyptus stands.** AJAR 13, 2285–2297. 2018
- ALWOSHEEL, A., VAN CRANENBURGH, S., CHORUS, C.G., **Is your dataset big enough? Sample size requirements when using artificial neural networks for discrete choice analysis.** Journal of choice modelling 28, 167–182. 2018.
- ANSARI, A.S., **Influence of Forests on Environment.** Presented at the XII World Forestry Congress, Québec City. 2003.
- ASHRAF, M.I., MENG, F.-R., BOURQUE, C.P.-A., MACLEAN, D.A., **A Novel Modelling Approach for Predicting Forest Growth and Yield under Climate Change.** PLoS ONE 10, 2015.
- BERGMEIR, C.N., BENÍTEZ SÁNCHEZ, J.M., **. Neural networks in R using the Stuttgart neural network simulator: RSNNS.** American Statistical Association.
- BILLINGS, W.D., 1952. **The Environmental Complex in Relation to Plant Growth and Distribution.** The Quarterly Review of Biology 27, 251–265. 2012.
- BINKLEY, D., CAMPOE, O.C., ALVARES, C., CARNEIRO, R.L., CEGATTA, Í., STAPE, J.L., **.The interactions of climate, spacing and genetics on clonal Eucalyptus plantations across Brazil and Uruguay.** Forest Ecology and Management 405, 271–283. 2017.
- BINKLEY, D., STAPE, J.L., BAUERLE, W.L., RYAN, M.G., **Explaining growth of individual trees: Light interception and efficiency of light use by Eucalyptus at four sites in Brazil.** Forest Ecology and Management, Productivity in Tropical Plantations 259, 1704–1713. 2010a.
- BINKLEY, D., STAPE, J.L., BAUERLE, W.L., RYAN, M.G., **Explaining growth of individual trees: light interception and efficiency of light use by Eucalyptus at four sites in Brazil.** Forest Ecology and Management 259, 1704–1713. 2010b.
- BINOTI, M.L.M. DA S., LEITE, H.G., BINOTI, D.H.B., GLERIANI, J.M., **Prognose Em Nível De Povoamento De Clones De Eucalipto Empregando Redes Neurais Artificiais.** CERNE 21, 97–105. 2015.

BISHOP, C.M.,. **Neural networks and their applications**. Review of scientific instruments 65, 1803–1832. 1994

BLACKARD, J.A., DEAN, D.J., **Comparative accuracies of artificial neural networks and discriminant analysis in predicting forest cover types from cartographic variables**. Computers and Electronics in Agriculture 24, 131–151. 1999.

BOGER, Z., GUTERMAN, H., in: 1997 IEEE International Conference **Knowledge extraction from artificial neural network models**, on Systems, Man, and Cybernetics. Computational Cybernetics and Simulation. IEEE, pp. 3030–3035. 1997.

BRAGA, F. DE A., BARROS, N., SOUZA, A. DE, COSTA, L. DA, **Características ambientais determinantes da capacidade produtiva de sítios cultivados com eucalipto**. Revista brasileira de ciência do solo 23, 291–298. 1999.

BURKHART, H.E., TOME, M., **Modeling Forest Trees and Stands**. Springer, New York NY USA. 2012.

CAMPOE, O.C., MUNHOZ, J.S.B., ALVARES, C.A., CARNEIRO, R.L., DE MATTOS, E.M., FERREZ, A.P.C., STAPE, J.L., **Meteorological seasonality affecting individual tree growth in forest plantations in Brazil**. Forest Ecology and Management, Special section: Drought and US Forests: Impacts and Potential Management Responses 380, 149–160. 2016.

CAMPOE, O.C., 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 288, 43–48. 2013.

CAMPOS, J.C.C., LEITE, H.G.,. **Mensuração florestal: perguntas e respostas**. UFV. 2006

CHAKRABORTY, K., MEHROTRA, K., MOHAN, C.K., RANKA, S., **Forecasting the behavior of multivariate time series using neural networks**. Neural networks 5, 961–970. 1992.

CHENG, B., TITTERINGTON, D.M., **Neural networks: A review from a statistical perspective**. Statistical science 2–30. 1994.

CHIARELLO, F., **Artificial Neural Networks Applied in Forest Biometrics and Modeling: State of the Art (2007 to 2018)**. CERNE 25, 140–155. 2019.

CHU, D., **Ecoregion Classification**, in: Chu, D. (Ed.), Remote Sensing of Land Use and Land Cover in Mountain Region: A Comprehensive Study at the Central Tibetan Plateau. Springer Singapore, Singapore, pp. 155–180. 2020.



CORNE, S.A., CARVER, S.J., KUNIN, W.E., LENNON, J.J., VAN HEES, W.W. VAN, **Predicting forest attributes in southeast Alaska using artificial neural networks.** *Forest Science* 50, 259–276. 2004.

CUNHA, A.B., **Modelagem do crescimento e produção de povoamentos de Eucalyptus por diferentes métodos de classificação de índice de local.** Dissertation. 2016.

DA 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** *Soil physical properties and eucalyptus growth planted after different tillage methods.* *Sci. For.*, 43, 965-977.2015.

DA SILVA BINOTI, M.L.M., LEITE, H.G., BINOTI, D.H.B., GLERIANI, J.M.,. **Prognose em nível de povoamento de clones de eucalipto empregando redes neurais artificiais.** *Cerne* 21, 97–105. 2015.

DA SILVA, R., HAKAMADA, R., BAZANI, J., OTTO, M., STAPE, J., **Fertilization response, light use, and growth efficiency in Eucalyptus plantations across soil and climate gradients in Brazil.** *Forests* 7, 117. 2016.

D'ANGELO, D.J., MEYER, J.L., HOWARD, L.M., GREGORY, S.V., ASHKENAS, L.R., **Ecological uses for genetic algorithms: predicting fish distributions in complex physical habitats.** *Canadian Journal of Fisheries and Aquatic Sciences* 52, 1893–1908. 1995.

DE JESUS, G.L., SILVA, I.R., ALMEIDA, L.F.J., DOS 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* 39, 1190–1203. 2015.

DE OLIVEIRA, C.M.M., DELGADO, R.C., DE ARAÚJO, E.J.G., DE ALMEIDA, A.Q., ROSA, T.C., DE OLIVEIRA, J.F., **Modelo 3-Pg Na Previsão Do Potencial Produtivo De Áreas Para Plantios Comerciais De Eucalyptus Spp.** *Ciência Florestal* 28, 249–262. 2018.

DIAMANTOPOULOU, M.J., **Artificial neural networks as an alternative tool in pine bark volume estimation.** *Computers and electronics in agriculture* 48, 235–244. 2005.

DIAMANTOPOULOU, M.J., ÖZÇELİK, R., CRECENTE-CAMPO, F., ELER, Ü., **Estimation of Weibull function parameters for modelling tree diameter distribution using least squares and artificial neural networks methods.** *Biosystems Engineering* 133, 33–45. 2015.

DREYER, P., **Classification of land cover using optimized neural nets on SPOT data.** *Photogrammetric Engineering and Remote Sensing*; (United States) 59. 1993.

FANG, R., STRIMBU, B., **Stem Measurements and Taper Modeling Using Photogrammetric Point Clouds**. Remote Sensing 9, 21. 2017.

FREEDMAN, D., PISANI, R., PURVES, R., **Statistics**. W.W.Norton&Company, New York NY. 1980.

FREITAS, E.C.S. DE, **Modelagem da produtividade de eucalipto por meio de redes neurais artificiais** (Thesis). Universidade Federal de Vicosa, UFV. 2017.

GENTLEMAN, R., IHAKA, R., **R**. University of Auckland, New Zealand, Auckland, New Zealand. 2014.

GEVA, S., SITTE, J., **A constructive method for multivariate function approximation by multilayer perceptrons**. IEEE transactions on neural networks 3, 621–624. 1992.

GONCALVES, J. DE 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**. Embrapa Agrossilvipastoril-Artigo em periódico indexado (ALICE). 2014.

GUAN, B.T., GERTNER, G., **Modeling red pine tree survival with an artificial neural network**. Forest Science 37, 1429–1440. 1991.

GULIYEV, N.J., ISMAILOV, V.E., **A single hidden layer feedforward network with only one neuron in the hidden layer can approximate any univariate function**. Neural computation 28, 1289–1304. 2016.

GUYON, I., ELISSEEFF, A., **An Introduction to Variable and Feature Selection**. Journal of Machine Learning Research 3, 1157–1182. 2003.

HABARULEMA, J.B., MCKINNELL, L.-A., **Investigating the performance of neural network backpropagation algorithms for TEC estimations using South African GPS data**, in: Annales Geophysicae. Copernicus GmbH, pp. 857–866. 2012.

HAGIWARA, M., **Theoretical derivation of momentum term in back-propagation**, in: [Proceedings 1992] IJCNN International Joint Conference on Neural Networks. IEEE, pp. 682–686. 1992.

HARDLE, W., SIMAR, L., **Applied multivariate statistical analysis**. Springer-Verlag, New York. 2003.

HAYKIN, S.O., **Neural Networks and Learning Machines: International Version**, ed. Upper Saddle River [etc.] Pearson Education. 2009.

HE, F., MA, C., **Modeling greenhouse air humidity by means of artificial neural network and principal component analysis**. Computers and Electronics in Agriculture 71, S19–S23.

HEATON, J., **Introduction to neural networks with Java**. Heaton Research, Inc. 2010.

HINTON, G.E., **Deterministic Boltzmann learning performs steepest descent in weight-space**. *Neural computation* 1, 143–150. 1989.

HOWLEY, T., MADDEN, M.G., O'CONNELL, M.-L., RYDER, A.G., **The Effect of Principal Component Analysis on Machine Learning Accuracy with High Dimensional Spectral Data**, in: Macintosh, A., Ellis, R., Allen, T. (Eds.), *Applications and Innovations in Intelligent Systems XIII*. Springer London, pp. 209–222. 2006.

IBÁ, 2017. **Relatório anual 2017**: ano base 2016. IBÁ Brasília.

IYER, M.S., RHINEHART, R.R., **A method to determine the required number of neural-network training repetitions**. *IEEE Transactions on Neural Networks* 10, 427–432. 1999.

JANG, D., **A parameter classification system for nonrevenue water management in water distribution networks**. *Advances in Civil Engineering* 2018.

JANG, D.W., **Estimation of Non-Revenue Water Ratio Using PCA and ANN in Water Distribution Systems**. Ph. D. Thesis, Incheon National University, Incheon, Korea. 2017.

JILANI, T.A., YASIN, H., YASIN, M.M., **PCA-ANN for classification of Hepatitis-C patients**. *International Journal of Computer Applications* 14, 1–6. 2011.

JOHNSEN, K., SAMUELSON, L., TESKEY, R., MCNULTY, S., FOX, T., **Process Models as Tools** in *Forestry Research and Management*. *for sci* 47, 2–8. 2001.

KARNIN, E.D., **A simple procedure for pruning back-propagation trained neural networks**. *IEEE transactions on neural networks* 1, 239–242. 1990.

KAVZOGLU, T., MATHER, P.M., **Pruning artificial neural networks: an example using land cover classification of multi-sensor images**. *International Journal of Remote Sensing* 20, 2787–2803. 1999.

KHALID, S., KHALIL, T., NASREEN, S. **A survey of feature selection and feature extraction techniques in machine learning**, in: *2014 Science and Information Conference*. Presented at the 2014 Science and Information Conference, pp. 372–378. , 2014.

KIM, T.J., BULLOCK, B.P., STAPE, J.L., **Effects of silvicultural treatments on temporal variations of spatial autocorrelation in Eucalyptus plantations in Brazil**. *Forest Ecology and Management* 358, 90–97. 2015.

KUMAR, V., SACHDEVA, J., GUPTA, I., KHANDELWAL, N., AHUJA, C.K., **Classification of brain tumors using PCA-ANN**, in: *2011 World Congress on Information and Communication Technologies*. IEEE, pp. 1079–1083. 2011.

LECUN, Y., DENKER, J.S., SOLLA, S.A., **Optimal brain damage**, in: *Advances in Neural Information Processing Systems*. pp. 598–605. 1990.

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* 130, 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* 90, 39–52. 1996.

LEK, S., GUÉGAN, J.-F., **Artificial neural networks as a tool in ecological modelling, an introduction**. *Ecological modelling* 120, 65–73. 1999.

LI, X.-L., HE, Y., QIU, Z.J., **Application PCA-ANN method to fast discrimination of tea varieties using visible/near infrared spectroscopy**. *Guang pu xue yu guang pu fen xi* = *Guang pu* 27, 279–282. 2007.

LIVNI, R., SHALEV-SHWARTZ, S., SHAMIR, O., **On the computational efficiency of training neural networks**, in: *Advances in Neural Information Processing Systems*. pp. 855–863. 2014

MAESTRI, R., SANQUETTA, C.R., SCOLFORO, J.R., DO AMARAL MACHADO, S., DALLA CORTE, A.P., **Modelagem do crescimento florestal considerando variáveis do ambiente: Revisão**. *Scientia Agraria* 14. 2013.

MAIER, H.R., DANDY, G.C., **Neural networks for the prediction and forecasting of water resources variables: a review of modelling issues and applications**. *Environmental modelling & software* 15, 101–124. 2000.

MARTINKOSKI, L., VOGEL, G.F., JADOSKI, S.O., **Influência do clima no crescimento diamétrico de *Araucária angustifolia* : revisão bibliográfica**. *Brazilian Journal of Applied Technology for Agricultural Science* 2, 104–111. 2015.

MAZON DE ALCANTARA, A.E., DE ALBUQUERQUE SANTOS, A., MARQUES DA SILVA MAYRA, L., BINOTI, D., BOECHAT SOARES CARLOS, P., GLERIANI, J., LEITE, H., **Use of artificial neural networks to assess yield projection and average production of eucalyptus stands**. *AJAR* 13, 2285–2297. 2018.

MEDLYN, B.E., DUURSMA, R.A., ZEPPEL, M.J.B., **Forest productivity under climate change: a checklist for evaluating model studies**. *Wiley Interdisciplinary Reviews: Climate Change* 2, 332–355. 2011.

MOHAMAD-SALEH, J., HOYLE, B.S., **Improved neural network performance using principal component analysis on Matlab**. *International journal of the computer, the internet and Management* 16, 1–8. 2008.

MØLLER, M.F., **A scaled conjugate gradient algorithm for fast supervised learning**. *Neural networks* 6, 525–533. 1993.

- MONSERUD, R.A., **Evaluating forest models in a sustainable forest management context.** *Forest Biometry, Modelling and Information Sciences* 1, 35–47. 2003.
- MORGAN, P., CURRY, B., BEYNON, M., **Pruning neural networks by minimization of the estimated variance.** *European Journal of Economic and Social Systems* 14, 1–16. 2000.
- MOZER, M.C., SMOLENSKY, P., **Skeletonization: A technique for trimming the fat from a network via relevance assessment,** in: *Advances in Neural Information Processing Systems*. pp. 107–115. 1989.
- NOORI, R., KARBASSI, A., SABAHI, M.S., **Evaluation of PCA and Gamma test techniques on ANN operation for weekly solid waste prediction.** *Journal of Environmental Management* 91, 767–771. 2010.
- OLIVEIRA, M.L.R. DE, LEITE, H.G., NOGUEIRA, G.S., CAMPOS, J.C.C., **Modelagem e prognose em povoamentos não desbastados de clones de eucalipto.** *Revista Árvore* 33, 841–852. 2009.
- OTTO, M.S.G., VERGANI, A.R., GONÇALVES, A.N., VRECHI, A., SILVA, S.R., STAPE, J.L., **Fotossíntese, condutância estomática e produtividade de clones de Eucalyptus sob diferentes condições edafoclimáticas.** *Revista Árvore* 37, 431–439. 2013b.
- ÖZÇELİK, R., DIAMANTOPOULOU, M.J., BROOKS, J.R., WIANT JR, H.V., **Estimating tree bole volume using artificial neural network models for four species in Turkey.** *Journal of environmental management* 91, 742–753. 2010.
- PAVEL, M., NELSON, J.D., JONATHAN FANNIN, R., **An analysis of landslide susceptibility zonation using a subjective geomorphic mapping and existing landslides.** *Computers & Geosciences* 37, 554–566. 2011.
- PEREIRA, A.R., ANGELOCCI, L.R., SENTELHAS, P.C., **Agrometeorologia: fundamentos e aplicações práticas.** 2002.
- PRETZSCH, H., **Forest dynamics, growth and yield.** Springer, Berlin Germany. Reed, R., 1993. **Pruning algorithms-a survey.** *IEEE transactions on Neural Networks* 4, 740–747. 2009.
- RENCHER, A.C., **Methods of Multivariate Analysis.** John Wiley and Sons, New York NY USA. 2002.
- 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* 380, 50–58. 2016.
- RESENDE, R.T., SOARES, A.A., FORRESTER, D.I., MARCATTI, G.E., DOS SANTOS, A.R., TAKAHASHI, E.K., E SILVA, F.F., GRATTAPAGLIA, D., RESENDE,

M.D.V., LEITE, H.G., **Environmental uniformity, site quality and tree competition interact to determine stand productivity of clonal Eucalyptus**. *Forest Ecology and Management* 410, 76–83. 2018.

RIEDMILLER, M., BRAUN, H., **A direct adaptive method for faster backpropagation learning: The RPROP algorithm**, in: *Proceedings of the IEEE International Conference on Neural Networks*. San Francisco, pp. 586–591. 1993.

SAFI, Y., BOUROUMI, A., **Prediction of forest fires using artificial neural networks**. *Applied Mathematical Sciences* 7, 271–286. 2013.

SANTI, E., PALOSCIA, S., PETTINATO, S., FONTANELLI, G., MURA, M., ZOLLI, C., MASELLI, F., CHIESI, M., BOTTAI, L., CHIRICI, G., **The potential of multifrequency SAR images for estimating forest biomass in Mediterranean areas**. *Remote sensing of environment* 200, 63–73. 2017.

SAS Institute, . **SAS**. SAS Institute, Cary NC, USA. 2017

SCHMIDHUBER, J., **Deep learning in neural networks: An overview**. *Neural networks* 61, 85–117. 2015.

SIETSMA, J., DOW, R.J., **Creating artificial neural networks that generalize**. *Neural networks* 4, 67–79. 1991.

SILVA, I. DA, SPATTI, D.H., FLAUZINO, R.A., **Redes neurais artificiais para engenharia e ciências aplicadas**. São Paulo: Artliber 23, 33–111. 2010.

SOARES, C.P.B., LEITE, H.G., **Predição da produção de madeira de eucalipto em região com alta variabilidade pluviométrica**. *Scientia forestalis* 58, 41–48. 2000.

SOARES, F.A.A., FLÔRES, E.L., CABACINHA, C.D., CARRIJO, G.A., VEIGA, A.C.P., **Recursive diameter prediction and volume calculation of eucalyptus trees using Multilayer Perceptron Networks**. *Computers and electronics in agriculture* 78, 19–27. 2011.

SPROTT, J.C., **Chaos and time-series analysis**. Oxford University Press, Oxford. 2003.

STAPE, J.L., BINKLEY, D., RYAN, M.G., GOMES, A.D.N., **Water use, water limitation, and water use efficiency in a Eucalyptus plantation**. *Bosque* 25, 35–41. 2004.

STRIMBU, B.M., AMARIOAREI, A., PAUN, M., **A parsimonious approach for modeling uncertainty within complex nonlinear relationships**. *Ecosphere*. 2017.

STRIMBU, B.M., BURKHART, H.E., **Complex Forest Ecosystems: From Tree to Landscape**. *Forest Science* 61, 409–410. 2015.

TABACHNICK, B.G., FIDELL, L.S., **Using multivariate statistics**. Allyn and Bacon, Needham Heights. 2001.

TABE, H., SIMONS, S.J.R., SAVERY, J., WEST, R.M., WILLIAMS, R.A., **Modelling of multiphase processes using tomographic data for optimisation and control**, in: Proc. 1st World Congress on Industrial Process Tomography, Buxton, UK. pp. 84–89. 1999.

TAN, S., HAIDER, A., **A comparative study of polarimetric and non-polarimetric lidar in deciduous-coniferous tree classification**, in: 2010 IEEE International Geoscience and Remote Sensing Symposium. Presented at the 2010 IEEE International Geoscience and Remote Sensing Symposium, pp. 1178–1181. 2010.

TAVARES JÚNIOR, I. DA S., ROCHA, J.E.C. DA, EBLING, Â.A., CHAVES, A. DE S., ZANUNCIO, J.C., FARIAS, A.A., LEITE, H.G., **Artificial Neural Networks and Linear Regression Reduce Sample Intensity to Predict the Commercial Volume of Eucalyptus Clones**. Forests 10, 268. 2019.

THORNTHWAITE, C.W., MATHER, J.R., **Publications in climatology**. The water balance 8, 1–104. 1955.

TOUFIQ, R., ISLAM, M.R., **Face recognition system using PCA-ANN technique with feature fusion method**, in: 2014 International Conference on Electrical Engineering and Information & Communication Technology. IEEE, pp. 1–5. 2014.

TU, J.V., **Advantages and disadvantages of using artificial neural networks versus logistic regression for predicting medical outcomes**. Journal of clinical epidemiology 49, 1225–1231. 1996.

TURK, M., PENTLAND, A., **Eigenfaces for recognition**. Journal of cognitive neuroscience 3, 71–86. 1991

VANCLAY, J.K., **Modelling forest growth and yield: applications to mixed tropical forests**. CAB International, Wallingford, U.K. 1994.

VENEGAS-GONZÁLEZ, A., CHAGAS, M.P., ANHOLETTO JÚNIOR, C.R., ALVARES, C.A., ROIG, F.A., TOMAZELLO FILHO, M., **Sensitivity of tree ring growth to local and large-scale climate variability in a region of Southeastern Brazil**. Theor Appl Climatol 123, 233–245. <https://doi.org/10.1007/s00704-014-1351-4> 2016

VIEIRA, G.C., DE MENDONÇA, A.R., DA SILVA, G.F., ZANETTI, S.S., DA SILVA, M.M., DOS SANTOS, A.R., **Prognoses of diameter and height of trees of eucalyptus using artificial intelligence**. Science of the Total Environment 619, 1473–1481. 2018.

VINÍCIUS OLIVEIRA CASTRO, R., BOECHAT SOARES, C.P., LEITE, H.G., LOPES DE SOUZA, A., SARAIVA NOGUEIRA, G., BOLZAN MARTINS, F., **Individual growth model for Eucalyptus stands in Brazil using artificial neural network**. ISRN Forestry 2013.

- VOGL, T.P., MANGIS, J.K., RIGLER, A.K., ZINK, W.T., ALKON, D.L., **Accelerating the convergence of the back-propagation method**. *Biological cybernetics* 59, 257–263. 1988.
- WEISKITTEL, A.R., HANN, D.W., KERSHAW, J.A., VANCLAY, J.K., **Forest Growth and Yield Modeling**. Wiley-Blackwell, Chichester UK. 2011.
- WERBOS, P.J., **Backpropagation: Past and future**, in: *Proceedings of the Second International Conference on Neural Network*. IEEE, pp. 343–353. 1988.
- WILLIAMS, G.P., **Chaos theory tamed**. Joseph Henry Press, Washington, D.C. 1997.
- Wu, C.L., Chau, K.W., **Rainfall–runoff modeling using artificial neural network coupled with singular spectrum analysis**. *Journal of Hydrology* 399, 394–409. 2011.
- YANG, Y., WATANABE, M., LI, F., ZHANG, J., ZHANG, W., ZHAI, J., **Factors affecting forest growth and possible effects of climate change in the Taihang Mountains, northern China**. *Forestry (Lond)* 79, 135–147. 2006.
- YOUNGER, A.S., HOCHREITER, S., CONWELL, P.R., **Meta-learning with backpropagation, in: IJCNN'01. International Joint Conference on Neural Networks**. Proceedings (Cat. No. 01CH37222). IEEE. 2001.
- ZELL, A., MACHE, N., HUEBNER, R., MAMIER, G., VOGT, M., SCHMALZL, M., HERRMANN, K.-U., **SNNS (stuttgart neural network simulator)**, in: *Neural Network Simulation Environments*. Springer, pp. 165–186. 1994.
- ZHANG, Q.-B., HEBDA, R.J., ZHANG, Q.-J., ALFARO, R.I., **Modeling tree-ring growth responses to climatic variables using artificial neural networks**. *Forest Science* 46, 229–239.
- ZHANG, Y., LI, H., HOU, A., HAVEL, J., 2006. **Artificial neural networks based on principal component analysis input selection for quantification in overlapped capillary electrophoresis peaks**. *Chemometrics and Intelligent Laboratory Systems* 82, 165–175. 2000.



CAPÍTULO 3: INVERSÃO DE REDES NEURAS ARTIFICIAIS PARA  
DIMENSIONAR FATORES DETERMINANTES DA PRODUTIVIDADE DE  
POVOAMENTOS DE EUCALIPTO

## RESUMO

Para um bom gerenciamento dos plantios florestais, é imprescindível analisar todos os fatores que interferem no seu crescimento e produção, já que toda tomada de decisão é feita a partir da estimativa da produção futura utilizando informações históricas e correntes. Vários fatores se correlacionam e influenciam o crescimento da floresta, sendo divididos em climáticos, edáficos, fisiográficos e bióticos e diversas técnicas vem sendo utilizadas para modelar essa correlação, entre elas Redes Neurais Artificiais (RNA), na qual os fatores ecofisiológicos e silviculturais se relacionam com a produtividade esperada. A inversão de uma RNA é feita quando queremos as diversas possibilidades de valores das variáveis de entrada com uma saída fixa. A utilização de Simulated Annealing (SA) favorecem ana inversão da rede na obtenção do grupo de respostas oriundas da inversão (*one-to-many*) visto que são obtidas mais de uma resposta para uma produtividade desejada, sendo uma ferramenta eficiente na identificação dos limitantes da produtividade de plantios de eucalipto no Brasil. O presente trabalho realizou a inversão de uma RNA utilizando SA com dados edafoclimáticos e silviculturais de plantios de eucalipto em MG dos 3 aos 7 anos de idade, correlacionando com a sua produtividade aos 6 anos, a idade de corte. O *Simulated Annealing* consegue realizar a inversão da RNA com eficiência, encontrando mais de uma solução local para o problema. Comparando os resultados obtidos com estudos correlatos, verifica-se a importância de variáveis categóricas como material genético e espaçamento como também a relação dessas variáveis com os níveis de adubação ótima para uma maior produtividade levando em consideração as condições climáticas e edáficas da região.

**Palavras chaves:** Redes Neurais Artificiais, Simulated Annealing, Inversão de Rede, Produtividade Florestal.

## ABSTRACT

For an optimized forest plantation management, it is essential to analyze all the factors that interfere in their growth and production, since all decision-making is made from the estimate of future production using historical and current information. Several factors correlate and influence the growth of the forest, which are divided into climatic, edaphic, physiographic and biotic and several techniques have been used to model this correlation, including Artificial Neural Networks (ANN), in which ecophysiological and silvicultural factors are relate to expected productivity. The inversion of an ANN is done when we want the different possible values of the input variables with a fixed output. The use of Simulated Annealing (SA) favors the inversion of the network favors obtaining the group of responses from the inversion (one-to-many) since more than one response is obtained for a desired productivity, being efficient in the identification of the constraints of the productivity of eucalyptus plantations in Brazil. The present work carried out the inversion of an ANN using SA with edaphoclimatic and silvicultural data of eucalyptus plantations in MG from 2 to 6 years of age, correlating the harvest age with its productivity at 6 years of age. Simulated Annealing is able to perform the ANN inversion efficiently, finding more than one local solution to the problem. Comparing the results obtained with related studies, the importance of categorical variables such as genetic material and spacing is verified, as well as the relationship of these variables with the levels of optimal fertilization for greater productivity, taking into account the climatic and edaphic conditions of the region.

**Keywords:** Artificial Neural Networks, Simulated Annealing, Network Inversion, Forest Productivity.

## 1 INTRODUÇÃO

Para um gerenciamento de plantios florestais otimizado é necessário compreender os processos de crescimento e de produção, uma vez que as decisões a serem tomadas serão baseadas na predição da produção futura a partir de informações correntes (Cosenza *et al.*, 2015). A capacidade produtiva de um lugar pode ser definida como o potencial de produção de madeira desse lugar para uma espécie particular ou tipo florestal (Oliveira *et al.*, 2009). Para tal, são utilizados modelos estatísticos para fazer essas previsões utilizando informações atuais dos plantios florestais. Essas previsões são utilizadas no processo de planejamento, sendo a base do manejo florestal, com a prognose da produção, prescrição de tratamentos silviculturais e a classificação de terras, com este último sendo considerado um dos principais (Campos e Leite, 2006).

Os fatores que afetam o crescimento das plantas podem ser classificados em: climáticos, edáficos, fisiográficos e bióticos. A interação entre esses fatores e seu efeito no processo crescimento da árvore é complexa e de difícil entendimento (Campos, 1970). O território nacional tem condições edáficas, climáticas e fisiográficas altamente favoráveis ao desenvolvimento de povoamentos equiâneos de rápido crescimento, como os de eucalipto e de pinus. Nota-se diferença considerável de produtividade tanto de coníferas quanto de folhosas entre as florestas brasileiras e de países com economias de base florestal, tais como é o caso da Suécia, além de outros países como Portugal, África do Sul, Estados Unidos, Canadá e Chile (ABRAF, 2010).

A partir dos anos 80, em função do aumento da conscientização pela proteção e preservação de florestas inequiâneas, juntamente com demanda cada vez maior por madeira, o setor florestal adotou inovações tecnológicas para utilizar, de forma mais eficaz, as florestas equiâneas, investindo constantemente em pesquisa e desenvolvimento florestal (ABRAF, 2010). Utilizando técnicas, como a clonagem de árvores com características desejáveis, houve um aumento na produtividade florestal e mitigações das condições adversas decorrentes do uso intensivo da terra, entre elas a possível perda em fertilidade (nutrientes), pragas, doenças e outros (Celulose online, 2015).

O método mais comumente utilizado para determinar e classificar a capacidade produtiva de povoamentos florestais é com o emprego de índices de sítio

estabelecidos com base na altura de árvores dominantes (Campos e Leite, 2017). Outras abordagens e métodos envolvem, também, variáveis edáficas, climáticas e fisiográficas (Consensa, 2017 e Medeiros, 2017). Quanto maior o número de variáveis e interações, maior a necessidade de modelos estatísticos mais robustos e de técnicas multivariadas e de inteligência artificial (Lappi E Bailey, 1988, Consensa, 2017 e Medeiros, 2017).

Uma alternativa de modelagem que tem sido cada vez mais utilizada na engenharia florestal é o emprego de técnicas de inteligência computacional (IC), como as redes neurais artificiais (RNA). Algumas características importantes das RNA, segundo Binoti (2010) são: mapeamento de entrada e saída, tolerância a falhas e ruídos (*outliers*), adaptabilidade dos pesos das conexões às modificações do ambiente (retreinamento), aprendizagem a partir de exemplos e generalização para dados desconhecidos.

São muitas as aplicações das RNA. Elas podem ser utilizadas em estudos sobre reconhecimento de padrões e interpretação de imagens (Rai et al., 2020; Lu et al., 2017), mineração de dados (Jiao e Li, 2021; Sahu et al., 2020), análises financeiras (Zuxing e Dian, 2020), monitoramento de incêndios florestais (Al-Kahlout et al., 2020), modelagem de crescimento em diferentes níveis (Binoti *et al.*, 2013, 2015; Ferraz *et al.* Binoti, Binoti e Leite, 2013; Castro *et al.*, 2013; Diamantopoulou e Milios, 2010; Gordon, 1999; Gorgens *et al.*, 2009; Guan e Gertner, 1991), estimação da altura (Dantas et al., 2020), volume e afilamento do fuste de árvores (Leite et al., 2020; Socha et al., 2020; de Azevedo et al., 2020), estudos de mortalidade (Syvain, 2019; da Rocha et al. 2018), estimação de estoques de carbono em povoamentos equiâneos e inequiâneos (Dantas et al., 2021; Acheampong e Boateng, 2019; Dolácio et al., 2019) e predição da capacidade produtiva (Dolácio et al., 2020; Araújo et al., 2019; Cosenza et al., 2017).

O treinamento de uma RNA envolve a determinação dos pesos das conexões, com base nos dados de treinamento. Após isto, todos esses pesos são fixados e a rede pode ser considerada como um mapeamento não linear do espaço de variáveis de entrada com o de saída (Lu, et al., 1999). Os fatores que afetam o crescimento das plantas são utilizados como variáveis de entrada para obter como saída a capacidade produtiva de povoamentos florestais, a produtividade média ou o crescimento.

A investigação dos fatores determinantes da produtividade dos plantios de eucalipto é frequente. Em algumas regiões vem se notando a estabilização dos

ganhos de produtividade do eucalipto, e em alguns casos, por queda da produtividade (Ibá, 2019; Investiagro, 2016). Estudos de consultora Pöyry, revelaram uma queda média de 6% entre 2010 e 2015 (Investiagro, 2016; Portal do Agronegócio, 2016). Uma das causas desse efeito são as mudanças climáticas, as reduções de investimento no setor pós crise de 2008, o processo de exaustão do solo das florestas, a seleção precoce de clones e da busca por áreas mais baratas para expansão do plantio sem o conhecimento prévio da produtividade (Investiagro, 2016).

Já no relatório de 2019 do Ibá (2019), feita pela consultora Pöyry houve um aumento de 0,5% na produtividade dos plantios de eucalipto, devido principalmente aos investimentos em pesquisa e melhoramento genético e a busca pelos melhores métodos silviculturais que as empresas do setor fizeram, mostrando a importância na criação de modelos capazes de identificar fatores que favorecem a produtividade, e que podem ser manejadas, mas que também levam em conta o impacto das alterações climáticas, principalmente o desequilíbrio do regime de chuvas que vem ocorrendo no Brasil (Ibá, 2019).

Alguns fatores que podem estar sendo decisivos na queda ou estabilização da produtividade média de povoamentos de eucalipto são: mudanças climáticas, ocorrência de pragas, problemas com as operações florestais, excesso de talhadas com menor produtividade média ao longo da rotação, fertilização inadequada, espaçamentos e genótipos mal adaptados.

Alguns desses fatores não podem ser modificados ou adequados diretamente, por exemplo, disponibilidade hídrica, temperatura e radiação solar. Porém, há vários outros que podem ser modificados e adequados caso necessário ou indicado. Mas antes de avaliar e decidir sobre esta adequação, é importante identificar os fatores mais limitantes, ou seja, dentre aqueles que podem ser modificados, quais devem ser priorizados em termos de otimização. Portanto, é necessário identificar os fatores mais influentes e, dentre eles, definir aqueles que podem ser modificados e que tipo de modificação é necessária para se obter determinada produtividade. Tal identificação não é uma tarefa simples e requer uma modelagem matemática abrangente, eficiente e apropriada, além de uma ampla base de dados históricos. Esses dados devem compreender o cadastro das operações florestais, os históricos de produção e informações edáficas, climáticas e fisiográficas de diferentes regiões. A inversão de uma RNA permite verificar a importância das variáveis de entrada sobre a variável de saída (Davis *et al.*, 1993).

A inversão de uma rede neural artificial é utilizada para verificar a importância de cada variável de entrada  $x$  na obtenção de determinado resultado  $y$ . Ou seja, encontrar combinações de valores de  $x$  que possam dar a resposta  $y$  desejada. A inversão é importante no sentido de orientar quais variáveis de entrada, quando modificadas, podem realmente melhorar a resposta do problema em que ela foi treinada. São utilizadas na regulação de sensores, para aumentar a precisão das informações do objeto alvo, levando em consideração aspectos ambientais, dos sensores e do próprio alvo (Davis *et al.*, 1993).

Davis *et al.* (1993), Hwang *et al.* (1990) e Jensen *et al.* (1999), utilizam a inversão de RNA para determinar a calibração ótima de sensores utilizados na neve e água. Podem ser utilizados também na identificação de padrões (Linden e Kindermann, 1989), na cinética robótica, na detecção de caracteres de imagens (Linden e Kindermann, 1989). No entanto, devido a característica *many-to-one* das RNA (um grupo de variáveis de entrada  $x$  podem dar origem a saída  $y$ ), sua inversão direta causa o chamado *one-to-many*, onde não há somente uma solução global para o problema (Lu *et al.*, 1999), tornando assim, a resposta da inversão direta inconclusiva. Problemas como esse, aparentemente simples normalmente exigem bastante esforço computacional em sua resolução, quer devido à grande complexidade dimensional do espaço de resposta, à complexidade do algoritmo a ser utilizado, à quantidade de dados ou aos recursos computacionais existentes (Menon, 2005).

Diversas abordagens foram criadas para a realização da inversão de uma RNA e a heurística é uma delas. VIANA (1998) define heurística, como qualquer método ou técnica criada, ou desenvolvida para resolver um determinado problema. São considerados métodos aproximativos, desenvolvidos para resolução de determinado problema, no entanto, não garantindo a otimalidade das soluções, mas muitas vezes devido ao esforço computacional, são mais eficientes em relação à técnicas de otimização convencionais, como programação linear (Viana, 1998).

Uma das heurísticas mais utilizadas é o Simulated Annealing (SA), que, mesmo apresentando poucos parâmetros para configuração, ainda assim consegue obter resultados satisfatórios em um tempo reduzido de processamento (Menon, 2005).

SA é uma técnica heurística de otimização que tem o objetivo de minimizar a função inspirada nos processos de resfriamento de metais (Černý, 1985). Foi originada em 1953, na tentativa de simulação de processos de mudança de fase de

cristais (recozimento), na qual são submetidos a altas temperaturas e reduzidas gradativamente até serem obtidos maiores consistência. Em outras palavras, sob altas temperaturas as partículas ficam desorganizadas, o que pode ser comparado com uma configuração aleatorizada de um problema de otimização que, após o recozimento, fornecerá variações na energia interna do material, o que equivale a alterações no valor da função objetivo (Menon, 2005).

SA são pertencentes à classe de algoritmos de busca local, no qual sua performance depende do método de busca local (Borges et al., 2014; Dong et al., 2015) e dos parâmetros de controle de temperatura, como temperatura inicial, final e decaimento (Connolly, 1990). Por apresentarem poucos parâmetros de ajuste, são de fácil aplicação e apresentam bons resultados.

Uma característica importante do SA é a capacidade de aceitar movimentos que não melhoram a função objetivo, permitindo com isto sair de ótimos locais. Ou seja, a partir de uma solução inicial, o SA procura obter uma solução melhor do que a atual, dentre as suas soluções vizinhas. A diferença fundamental entre a técnica SA e as demais técnicas heurísticas de busca em vizinhança é que, de maneira probabilística, a solução atual pode ser substituída por outra com desempenho inferior quanto à função objetivo adotada, permitindo-lhe escapar de ótimos locais (Menon, 2005).

A utilização de SA na inversão da rede favorece a obtenção do grupo de respostas oriundas da inversão (*one-to-many*) visto que são obtidas mais de uma resposta para uma produtividade desejada. Esta abordagem pode ser eficiente na identificação dos limitantes da produtividade de plantios de eucalipto no Brasil, além de permitir não apenas uma resposta, mas um conjunto delas com definições do nível de cada fator para que seja atingida uma definida produtividade potencial. Estudo dessa ordem é fundamental para que se tenha efetivos ganhos de produtividades nos próximos plantios, contribuindo muito para a sustentabilidade florestal, com um impacto ainda maior, em consequência das grandes variações climáticas que vem ocorrendo, inclusive com frequências cada vez maiores. Esta foi uma motivação para a condução do presente estudo, com o objetivo de utilizar o SA para obter os principais fatores que podem ser gerenciados para se atingir uma produtividade desejada, mas mantendo fixos os fatores climáticos da região potencial.



## 2 MATERIAIS E MÉTODOS

### 2.1 Dados

O presente estudo utiliza dados de 507 parcelas de plantios de *Eucalyptus* localizada em Minas Gerais, Brasil (Figura 8). Os plantios possuem observações em idade de 3 a 7 anos, com áreas variando de 3 ha a 79 ha e produtividade aos 6 anos esperada 16.43 to 50.99 m<sup>3</sup>/ha/ano.

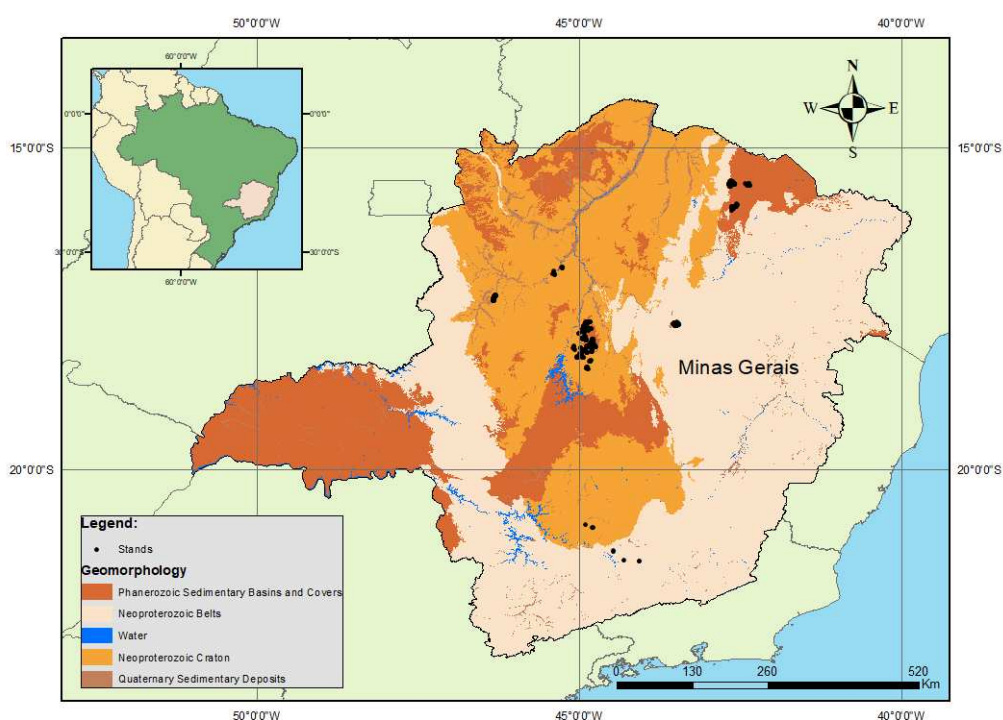


Figura 8 - Localização dos plantios de estudo. As cores do mapa fornecem informação de geomorfologia de acordo com o IBGE (2014).

Os dados possuem mensuradas 105 variáveis obtidas de três fontes: inventário florestal contínuo, medições de solo e estações meteorológicas. O inventário florestal contínuo forneceu o genótipo e espaçamento, que serviram como variáveis categóricas de entrada e o incremento do volume anual de madeira no sexto ano, que é a variável prevista. As medições do solo foram focadas nas propriedades físicas e químicas no primeiro e terceiro ano, bem como nas fertilizações durante toda a rotação. Um total de 735 estações meteorológicas e 3635 pluviômetros foram usados para estimar as variáveis por interpolação. O balanço hídrico foi calculado pelo método de Thornthwaite e Mather (Thornthwaite e Mather, 1955), assumindo uma

capacidade máxima de armazenamento de 300 mm, conforme sugerido por (Pereira, Angelocci e Sentelhas, 2002). A Tabela 9 mostra as variáveis contínuas utilizadas neste estudo:

Tabela 9 - Variáveis contínuas.

Continuous Input	Unit	Min	Max
Total Sand (0-20 cm)	%	8.78	87.7
Clay (0-20 cm)	%	6	76
Silt (0-20 cm)	%	1.9	36.69
Al saturation (m)	%	0.72	93.9
Base saturation (V)	%	0.81	49.17
P available (P)	mg dm <sup>-3</sup>	0.47	16.86
K available (K)	mg dm <sup>-3</sup>	2.52	239.08
pH (H <sub>2</sub> O)	-	3.99	6.14
pH (CaCl <sub>2</sub> )	-	3.8	5.1
CTC	cmol <sub>c</sub> dm <sup>-3</sup>	2.19	17.16
H+Al	cmol <sub>c</sub> dm <sup>-3</sup>	1.82	16.83
Al saturation (m)	cmol <sub>c</sub> dm <sup>-3</sup>	0.02	2.76
Mg	cmol <sub>c</sub> dm <sup>-3</sup>	0.01	0.92
Ca	cmol <sub>c</sub> dm <sup>-3</sup>	0.01	1.87
Organic Matter	dag kg <sup>-1</sup>	0.7	8.17
P-remain	mg L <sup>-1</sup>	2.01	47.93
Rain 5th year	mm year <sup>-1</sup>	732.92	1946.25
Rain 4th year	mm year <sup>-1</sup>	620.68	2037.49
Rain 3th year	mm year <sup>-1</sup>	620.68	2137.08
Rain 2th year	mm year <sup>-1</sup>	620.68	1878.03
Rain 1st year	mm year <sup>-1</sup>	557.37	2137.08
Rain year 0	mm year <sup>-1</sup>	677.52	1741.4
Rain year -1	mm year <sup>-1</sup>	647.24	1915.64
Rain year -2	mm year <sup>-1</sup>	647.24	1682.24
Temperature year 0	°C	14.34	31.47
Temperature year 1	°C	14.45	31.47
Temperature year 2	°C	15.02	31.3

<b>Continuous Input</b>	<b>Unit</b>	<b>Min</b>	<b>Max</b>
Temperature year 3	°C	13.75	31.31
Temperature year 4	°C	14.17	31.31
Temperature year 5	°C	14.57	31.38
Wind Speed year 0	m s <sup>-1</sup>	0.97	1.83
Wind Speed year 1	m s <sup>-1</sup>	0.97	1.7
Wind Speed year 2	m s <sup>-1</sup>	1.1	1.65
Wind Speed year 3	m s <sup>-1</sup>	1.1	1.86
Wind Speed year 4	m s <sup>-1</sup>	1.02	1.74
Wind Speed year 5	m s <sup>-1</sup>	1.03	1.62
Potential Evapotranspiration year 0	mm year <sup>-1</sup>	1190.73	1631.69
Potential Evapotranspiration year 1	mm year <sup>-1</sup>	1225.17	1649.48
Potential Evapotranspiration year 2	mm year <sup>-1</sup>	1133.52	1679.51
Potential Evapotranspiration year 3	mm year <sup>-1</sup>	1154.58	1712.15
Potential Evapotranspiration year 4	mm year <sup>-1</sup>	1258	1712
Potential Evapotranspiration year 5	mm year <sup>-1</sup>	1188	1671
Air Humidity year 0	%	62.55	79.25
Air Humidity year 1	%	62	77.98
Air Humidity year 2	%	60.69	81.07
Air Humidity year 3	%	59.97	78.82
Air Humidity year 4	%	59.97	75.28
Air Humidity year 5	%	61.72	77.73
Radiation year 0	MJ m <sup>-2</sup>	16.41	20.7
Radiation year 1	MJ m <sup>-2</sup>	17.1	20.86
Radiation year 2	MJ m <sup>-2</sup>	15.54	20.86
Radiation year 3	MJ m <sup>-2</sup>	15.88	20.58
Radiation year 4	MJ m <sup>-2</sup>	17.01	20.96
Radiation year 5	MJ m <sup>-2</sup>	16.17	20.96
Hidrological Deficit year 5	mm year <sup>-1</sup>	185.2	857.42
Hidrological Deficit year 4	mm year <sup>-1</sup>	146.5	1000.66
Hidrological Deficit year 3	mm year <sup>-1</sup>	76.62	1000.66
Hidrological Deficit year 2	mm year <sup>-1</sup>	122.66	100.66
Hidrological Deficit year 1	mm year <sup>-1</sup>	184.67	869.22

<b>Continuous Input</b>	<b>Unit</b>	<b>Min</b>	<b>Max</b>
Hidrological Deficit year 0	mm year <sup>-1</sup>	146.88	915.52
Hidrological Deficit year -1	mm year <sup>-1</sup>	65.39	915.52
Hidrological Deficit year -2	mm year <sup>-1</sup>	78.49	838.73
Rain median (1980 - 2013)	mm year <sup>-1</sup>	812.63	1513.39
Max Temp median (1980 - 2013)	°C	25.87	30.75
Med Temp median (1980 - 2013)	°C	14.66	18.99
MinTemp median (1980 - 2013)	°C	20.32	24.87
Wind Speed median (1980 - 2013)	m s <sup>-1</sup>	1.18	1.44
Potential Evapotranspiration (1980 - 2013)	mm year <sup>-1</sup>	1182.81	1582.27
Air Humidity median (1980 - 2013)	%	63.84	78.02
Hidrological deficit median (1980 - 2013)	mm year <sup>-1</sup>	111	799
Radiation median (1980 - 2013)	MJ m <sup>-2</sup>	16.26	19.26
N Fertilization	kg ha <sup>-1</sup>	0	60.93
P <sub>2</sub> O <sub>5</sub> Fertilization	kg ha <sup>-1</sup>	0	325.81
K <sub>2</sub> O Fertilization	kg ha <sup>-1</sup>	53.71	512.14
CaO Fertilization	kg ha <sup>-1</sup>	0	1100.78
MgO Fertilization	kg ha <sup>-1</sup>	0	255.45
S Fertilization	kg ha <sup>-1</sup>	0	45.92
B Fertilization	kg ha <sup>-1</sup>	0	9.26
Cu Fertilization	kg ha <sup>-1</sup>	0	5.75
Zn Fertilization	kg ha <sup>-1</sup>	0	7.72

Para garantir a compatibilidade da variável em termos de magnitude, o que pode levar a erros de cálculo (Rencher, 2002; Tabachnick e Fidell, 2001), todas as variáveis contínuas foram padronizadas para atingir valores entre 0 e 1.

## 2.2 Análise de Componentes Principais - PCA

Para reduzir a dimensão do espaço de variáveis de entrada enquanto diminui o tempo de treinamento e preserva ou mesmo melhora a precisão do modelo de RNA (Zekić-Sušac, Šarlija e Pfeifer, 2013), as variáveis foram pré-processadas com Análise de componentes principais (PCA). Cada componente principal é um

produto linear entre a variável observada padronizada e sua contribuição para esse componente principal. Foram selecionados 12 componentes principais que explicam 90% da variação dos dados (Tabela 10) e utilizados como entrada para a RNA.

Tabela 10 - Componentes principais fornecendo > 90% de toda a variação, seus autovalores e contribuição relativa [%].

Principal Component	Eigenvalue	Variance (%)	Cumulative Variance [%]
1	37.52	39.91	39.91
2	14.88	15.83	55.74
3	8.24	8.77	64.51
4	5.66	6.02	70.54
5	4.66	4.95	75.49
6	3.11	3.31	78.80
7	2.75	2.93	81.73
8	2.10	2.23	83.96
9	1.74	1.85	85.81
10	1.43	1.52	87.33
11	1.33	1.41	88.74
12	1.19	1.26	90.01

### 2.3 Redes Neurais Artificiais

No segundo capítulo, foram testadas as configuração de RNA e métodos de redução da dimensão das variáveis mais eficientes para estimar a produtividade do eucalipto a partir de dados geomorfológicos, climáticos e de inventário florestal contínuo. Dados os mesmos recursos de hardware, avaliamos a eficiência de uma RNA Multilayer Perceptron com a combinação do tempo de processamento para fornecer uma solução e a precisão dos resultados.

Aumentamos a eficiência da rede em duas etapas: uma no pré processamento da RNA, através da Análise de Componentes Principais (PCA), e uma no processamento da RNA, através de métodos de poda dedicados. Foram testadas

as combinações de número de neurônios nas camadas ocultas, os algoritmos de treinamento e os diferentes métodos de poda da RNA. Cada RNA foi treinada cinco vezes para avaliar o impacto dos pesos iniciais nos resultados, o que levou a um experimento fatorial com 90.000 combinações.

Comparamos o desempenho das RNAs usando cinco métricas: tempo de processamento, viés, erro absoluto médio, raiz do erro quadrático médio e coeficiente de correlação de Pearson. O resultado mais preciso foi fornecido em aproximadamente 38,81 segundos por uma RNA usando os dados do PCA, treinados com o algoritmo Scaled Conjugate Gradient com quatro neurônios na camada oculta e método de poda Magnitude Based Pruning. No entanto, uma perda de precisão de menos de 1% (ou seja, o segundo resultado mais preciso) foi obtida em 1,7 segundos da mesma configuração de ANN, exceto sem poda.

## 2.4 Simulated Annealing

Abaixo (Figura 9) é apresentado o pseudocódigo do Simulated annealing segundo Hosseinabadi (2017): partir de um estado  $s_0$  (uma solução inicial gerada aleatoriamente), com uma temperatura geralmente alta (ou um alto valor de aleatoriedade da solução), para permitir uma busca em uma área ampla. A cada passo, a nova temperatura (e conseqüentemente uma nova solução) é gerada de acordo com uma função objetivo (como o erro médio quadrático entre o valor observado e estimado), sendo essa temperatura menor que anterior (a aleatoriedade da solução vai diminuindo), até que o algoritmo convirja para uma solução ótima, necessariamente local.

Foram testadas diferentes configurações de temperatura inicial e final, como também o decaimento e número de interações. Sendo que a configuração final, levando em consideração o tempo de processamento foi: temperatura inicial de 0,001, temperatura final de 1, decaimento 0,00001 e número de interações de 10 milhões.

```

Initialize parameters;
S=generate initial solution ();
 $T = T_0$ ;
While ( $T < T_{final}$ )
{
  Until ( $N \leq I - Iter$ )
  {
    Generate solution  $S'$  in the neighborhood of  $S$ 
    if  $f(S') < f(S)$ 
       $S \leftarrow S'$ 
    else
       $\Delta = f(S') - f(S)$ 
       $r = random()$ ;
      if ( $r < \exp(-\Delta / k * T)$ )
         $S \leftarrow S'$ 
  }
   $T = a * T$ ;
}
Return the best solution found;

```

Figura 9 - Pseudocódigo Simulated Annealling. (Hosseinabadi et al., 2017)

Em cada ciclo foi fixado o valor de produtividade desejado (IMA 6), variando de 19 a 35m<sup>3</sup>/ha.ano<sup>1</sup>.. As variáveis edáficas e climáticas foram fixadas nos valores médios dos dados utilizados para o treinamento da RNA, restando somente as variáveis silviculturais para serem preditas. Foram salvos apenas resultados com um erro quadrático de 0,001 (valor de produtividade observada x predita pelo SA). Na sequência, com as variáveis passíveis de modificação, foram obtidos os gráficos de dispersão entre elas.

### 3 RESULTADOS E DISCUSSÃO

Ao final, foram obtidas 311 soluções, com o menor número de soluções para o IMA de 26m<sup>3</sup>/ha.ano<sup>1</sup>, com apenas 4 soluções, e o maior número de soluções para o IMA de 35 m<sup>3</sup>/ha.ano<sup>1</sup>, com 91 soluções (Tabela 11).

Tabela 11 - Saídas encontradas pela Simulated Annealing.

<b>IMA 6</b>	<b>N</b>	<b>Erro quadrático médio</b>	<b>Desvio padrão</b>
19	12	0,00056	0,00033
20	14	0,00020	0,00019
21	19	0,00026	0,00030
22	13	0,00018	0,00022
23	12	0,00031	0,00020
24	6	0,00038	0,00021
25	10	0,00030	0,00023
26	4	0,00040	0,00039
27	12	0,00026	0,00027
28	11	0,00030	0,00026
29	10	0,00051	0,00031
30	9	0,00046	0,00034
31	4	0,00062	0,00023
32	14	0,00030	0,00026
33	13	0,00031	0,00029
34	57	0,00030	0,00030
35	91	0,00036	0,00030

### 3.1 Adubação X Ima6

Quando analisamos a adubação (Figura 10), podemos verificar que a maioria dos macronutrientes possui grande plasticidade na quantidade aplicada para cada produtividade, não sendo possível verificar sua correlação com a produtividade se analisada isoladamente.

De modo geral, pode se observar nas respostas que doses médias mais altas de nitrogênio, magnésio, zinco e enxofre produzem maiores produtividades. Já doses de potássio possuem maior plasticidade, observando uma alta variação das doses médias na mesma produtividade desejada.



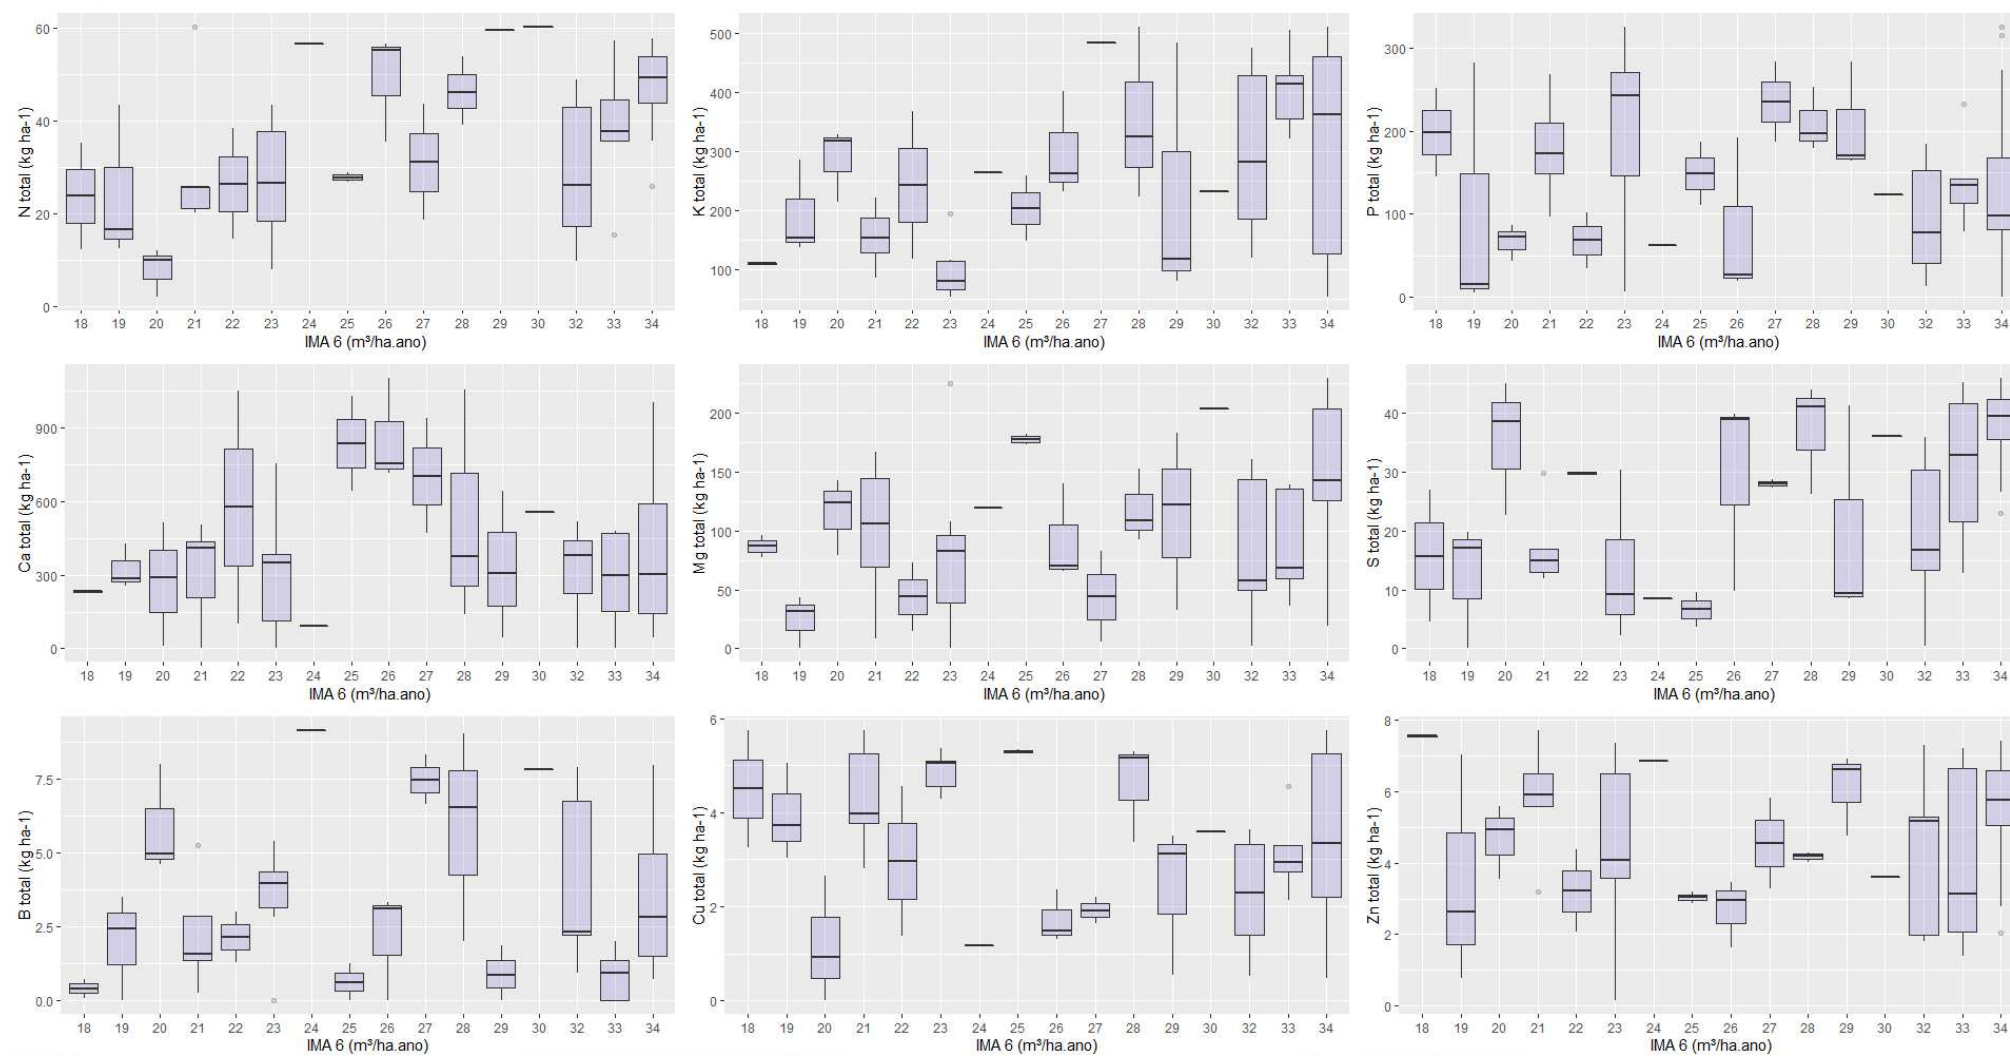


Figura 10 - Dispersão entre nutrientes e produtividade ao ano 6 (IMA 6).

### 3.2 Genótipo X Ima 6

Com relação ao genótipo (Figura 11), o de número 6 foi o que apresentou menor amplitude de produtividade, mesmo com as maiores produtividades, sendo também o que teve menor número de respostas, indicando que é o que possui a menor plasticidade de resposta na sua produtividade em relação aos fatores silviculturais de entrada. O genótipo 2 também apresentou pouca amplitude, mas com uma produtividade menor que o 6. Dos que tiveram grande variabilidade, o 1 foi o que apresentou menor média de produtividade.




Figura 11 - Dispersão entre os materiais genéticos e produtividade ano 6 (IMA 6).

### 3.3 Espaçamento X Ima 6

Quando comparado os espaçamentos em função da produtividade (Figura 12), quanto maior o espaçamento na linha de plantio, menor a produtividade. Nos resultados, o espaçamento 2 e 3 (3,5 x 2,5 m e 3 x 3 m respectivamente) apresentaram as maiores médias, enquanto o espaçamento 6 (4 x 2 m) foi o que gerou a menor média.

O espaçamento 1 (3,5 x 2 m) foi o mais plástico, apresentando grande variabilidade na resposta da produtividade, e o 2 o menor.




Figura 12 - Dispersão entre espaçamento e produtividade no ano 6 (IMA 6).

### 3.4 Espaçamento X Genótipo X Ima 6

Na relação dos dois fatores (Figura 13), as respostas que obtiveram menor produtividade foram o material 2 nos espaçamentos 3,5m x 2,5m e 3,0m x 3,0 m e o material 5 no espaçamento 4,0 x 2,0 m.




Figura 13 - Heatmap entre material genético, espaçamento e produtividade no ano 6.

### 3.5 Npk X Genótipo X Ima 6

Comparando o genótipo com os macro nutrientes NPK (Figura 14), verifica se que o material 1 é o mais plástico, respondendo aos 3 nutrientes com uma amplitude maior de dose. Enquanto os materiais 3, 4 e 6 foram os que menos responderam aos nutrientes.




Figura 14 - Heatmap correlacionando macro nutrientes NPK, material genético e produtividade no ano 6.

### 3.6 Npk X Espaçamento X Ima 6

Quanto a interação dos macronutrientes e o espaçamento (Figura 15), não foi encontrado uma correlação direta entre eles. Nos resultados obtidos, os mais plásticos foram os espaçamentos 1, 3 e 4 (3,5 x 2,0 m ; 3,0 x 3,0 m e 3,0 x 2,5 m) por aceitarem uma maior variação das doses dos macro nutrientes e conseqüentemente relação com a produtividade. O espaçamento 2 (3,5 x 2,5 m) foi o que apresentou menos respostas e menor amplitude nas doses dos nutrientes.




Figura 15 - Heatmap correlacionando macronutrientes NPK, espaçamento e produtividade no ano 6.

#### 4 DISCUSSÃO

Os resultados do Simulated Annealing foi eficiente para contornar a característica da inversão da rede, o *one-to-many*, que faz com que não haja somente uma solução global para o problema (Lu et al., 1999) . Um grupo de soluções foram criadas para cada IMA 6 desejado, mostrando que o SA percorreu diversas possibilidades para a solução, mesmo com a complexidade dimensional do problema (106 entradas).

Diversos estudos tem sido feitos para analisar os fatores que interferem a produtividade nos plantios florestais e suas interações (Binkley *et al.*, 2010; Braga *et al.*, 1999; Burkhart e Tomé, 2012; Campoe *et al.*, 2013; Goncalves *et al.*, 2014; Jesus, de *et al.*, 2015; Kim et al., 2015; Mazon de Alcantara *et al.*, 2018; Otto *et al.*, 2013; Resende *et al.*, 2016, 2018; Rocha, da *et al.*, 2015; da Silva *et al.*, 2016; Stape *et al.*, 2004). E nesses estudos, as variáveis climáticas possuem um grande potencial para que os plantios tenham o aproveitamento máximo dos recursos. No entanto podem ser de difícil utilização por essas variáveis terem alta correlação entre as variáveis independente do modelo (Soares e Leite, 2000).

Os processos que influenciam a eficiência no uso dos nutrientes são relacionados com características morfológicas (sistema radicular eficiente, alta relação raiz-parte aérea e sistema radicular extensivo) e fisiológicas (taxa fotossintética e a capacidade de manter o metabolismo normal com baixo teor de nutrientes nos tecidos) (Novais et al., 2007).

O espaçamento determina o tempo e intensidade da competição de recursos entre plantas vizinhas (Harrington et al., 2009). Para Scolforo (1997) essa competição afeta

a quantidade e a qualidade da produção florestal. Conforme Rocha (2011), menores espaçamentos resultam em menores diâmetros, maior área basal por hectare, maior volume total por hectare e menor porcentagem de sobrevivência.

Na interação do espaçamento com produtividade, trabalhos como de Rocha (2011) indicam que espaçamentos mais adensados favorecem a produtividade de plantios visando a produção para a energia. No entanto deve-se analisar outras variáveis como o custo para que abrangem a produção florestal. O espaçamento 1, o mais adensado, foi o que apresentou saídas com maior variação de produtividade, relacionada com altas doses de fósforo (P). Já para Bruno (2012), não houve grande variação da eficiência de uso dos nutrientes, e conseqüentemente a produtividade, entre os espaçamentos mais adensados ou não.

Nos estudos de Freitas (2017), houve um aumento na correlação e menor diferença entre os valores observados e estimados de IMA6 com a utilização de variáveis categóricas, como espaçamento e material genético, sendo importantes para obter estimativas mais precisas. Essa autora também citou o trabalho de Binoti et al. (2015), em que essas variáveis foram selecionadas em todas as redes preditoras de volume pelos algoritmos de otimização.

Conforme Silva (2011), as espécie arbóreas de rápido crescimento dependem dos nutrientes disponíveis no solo e, para se obter uma melhor produtividade e um aumento da resistencia a pragas e doenças, são necessárias aplicações de fertilizantes. No entanto, conforme Stape (2008), outros fatores podem se tornar um fator limitante ao crescimento da população antes dos nutrientes, como a disponibilidade de água no solo. A resposta à fertilização também tende a ser menores quando há o fechamento das copas, devido a otimização do ciclo biogênico da florestal (Silva, 2011).

Mas com o aquecimento global e o aumento de CO<sub>2</sub> na atmosfera, as plantações florestais poderão aumentar sua produtividade desde que os fatores limitantes sejam eliminados, como a disponibilidade de água e nutrientes (Silva, 2011), sendo assim necessária a utilização de maiores doses de fertilizante. Outro ponto é a análise econômica desses nutrientes com a capacidade de utilização da floresta, para que haja otimização dos recursos.

Doses médias maiores de nitrogênio e magnésio estão correlacionadas com maiores produtividades. Resultados similares foram encontrados em Silva (da Silva et al., 2016). Conforme citado por Freitas (2017), nos trabalhos de Gava e Gonçalves

(2008) foram avaliados o efeito de atributos físicos e químicos do solo na produtividade e qualidade da madeira de Eucalyptus e concluí-se que o teor de argila, diretamente relacionado à quantidade de água e nutrientes disponíveis, foi o mais relevante, não encontrando relação entre a produtividade e teores de P, Ca e K.

Sugere-se nos próximos estudos a realização de análise econômicas nas variáveis de adubação, para a otimização da melhor resposta obtida da inversão da RNA.

## 5 CONCLUSÕES

O Simulated Annealing consegue realizar a inversão da RNA com eficiência, encontrando mais de uma solução global para o problema. Comparando os resultados obtidos com estudos correlatos, verifica-se a importância de variáveis categóricas como material genético e espaçamento como também a relação dessas variáveis com os níveis de adubação ótima para uma maior produtividade levando em consideração as condições climáticas e edáficas da região.

## REFERÊNCIAS

- ABRAF. **Anuário estatístico da ABRAF 2010 ano base 2009/ ABRAF**. – Brasília, 2010. 140p, 2010.
- ACHEAMPONG, A. O., & BOATENG, E. B. **Modelling carbon emission intensity: Application of artificial neural network**. *Journal of Cleaner Production*, 225, 833-856, 2019.
- AERTSEN, W.; KINT, V.; *et al.* **Comparison and ranking of different modelling techniques for prediction of site index in Mediterranean mountain forests**. *Ecological modelling*, v. 221, n. 8, p. 1119–1130, 2010.
- AL-KAHLOUT, M. M., GHALY, A. M. A., MUDAWAH, D. Z., & ABU-NASER, S. S.. **Neural Network Approach to Predict Forest Fires using Meteorological Data**. *International Journal of Academic Engineering Research (IJAER)*, 4(9), 2020.
- ARAÚJO, C. A., SOUZA, P. D. D., ASSIS, A. L. D., CABACINHA, C. D., LEITE, H. G., SOARES, C. P. B., ... & CASTRO, R. V. O. **Artificial neural networks, quantile regression, and linear regression for site index prediction in the presence of outliers**. *Pesquisa Agropecuária Brasileira*, 54, 2019.
- ARAÚJO, A. C. S. C.; SILVA, P. V.; MARTINS, E. R.; BINOTI, D. H. B.; BINOTI, M. L. M. S.; LEITE, H. G.; BERNARDI, M. **Inventário de sobrevivência a partir da classificação supervisionada de imagens digitais**. *Atualidades em Mensuração Florestal [livro eletrônico]*. Ed. Ana Paula Dalla Corte... [et al.]. – 1. ed. – Curitiba, 2014. 407 p.
- ARAÚJO, L. A., MIRANDA, E. N., DE SOUZA ABREU, V., DE SOUZA GOMES, V., ALMEIDA, B. C., GONÇALVES, A. F. A., ... & GOMIDE, L. R. **Aplicação de técnicas de regressão linear e aprendizagem de máquinas na predição da altura total de árvores de Eucalyptus spp**. *Notas de aula*. Disponível em: < <https://downloads.editoracientifica.org/articles/201102132.pdf>>. Acesso em 31 de outubro de 2021.
- BARROS, N.F.; MOURA FILHO, W.; VALE, A.B. & OLIVEIRA, L.M. **Contribuição ao relacionamento de características pedológicas e topográficas com altura de Eucalyptus alba, na região de Santa Bárbara, MG**. *R. Ceres*, 23:109-128, 1976.
- BINKLEY, D.; STAPE, J. L.; *et al.* **Explaining growth of individual trees: light interception and efficiency of light use by Eucalyptus at four sites in Brazil**. *Forest Ecology and Management*, v. 259, n. 9, p. 1704–1713, 2010.
- BINOTI, D. H. B.; BINOTI, M. L. M. DA S.; *et al.* **Modelagem da distribuição de diâmetros utilizando autômatos celulares e redes neurais artificiais**. *Cerne*, v. 19, p. 677–685, 2013.
- BINOTI, MAYRA LUIZA MARQUES DA SILVA. **Artificial neural networks for prognosis of yield of nonthinned stands of eucalyptus**. 2010. 64 f. *Dissertação*



(Mestrado em Manejo Florestal; Meio Ambiente e Conservação da Natureza; Silvicultura; Tecnologia e Utilização de) - Universidade Federal de Viçosa, Viçosa, 2010.

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

**BINOTI, M. L. M. DA S.; LEITE, H. G.; et al. Prognose Em Nível De Povoamento De Clones De Eucalipto Empregando Redes Neurais Artificiais.** CERNE, v. 21, n. 1, p. 97–105, mar. 2015.

**BISHOP, C. M. Neural networks for pattern recognition.** Oxford university press, 1995.

**BRAGA, A. de P.; CARVALHO, A. P. de L. F de; LUDEMIR, T. B. Redes Neurais Artificiais: Teoria e Aplicações.** Rio de Janeiro, RJ. Editora LTC, 262 p. 200, 2007.

**BRAGA, F. DE A.; BARROS, N.; et al. Características ambientais determinantes da capacidade produtiva de sítios cultivados com eucalipto.** Revista brasileira de ciência do solo, v. 23, n. 2, p. 291–298, 1999.

**BULLINARIA, J. A. Introduction to Neural Computation.** Notas de aula. Disponível em: <<http://www.cs.bham.ac.uk/~jbx.inc.html>.2009 > Acesso em 31 de outubro de 2021.

**BURKHART, H. E.; TOMÉ, M. Modeling forest trees and stands.** [s.l.] Springer Science & Business Media, 2012.

**CAMPOE, O. C.; STAPE, J. L.; et al. 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. Principais fatores do meio que afetam o crescimento das árvores.** Floresta, v. 2, n. 3, 1970.

**CAMPOS, J. C. C.; LEITE, H. G. Mensuração florestal: perguntas e respostas.** [s.l.] UFV, 2006.

**CASTRO, R. V. O.; SOARES, C. P. B.; et al. Crescimento e produção de plantios comerciais de eucalipto estimados por duas categorias de modelos.** Pesquisa Agropecuária Brasileira, v. 48, p. 287–295, 2013.

**CAMPOS, J.C.C., LEITE, H.G., LELIS, V.G. Classificação da capacidade produtiva de Eucalyptus camaldulensis na região de João Pinheiro,** em Minas Gerais. Viçosa, MG: SIF, 1991.

CARMO, D.N.; RESENDE, M. & SILVA, T.C.A. **Avaliação da aptidão das terras para eucalipto**. In: BARROS, N.F. & NOVAIS, R.F., eds. *Relação solo-eucalipto*. Viçosa. Folha de Viçosa, 1990.

Celulose on line. **Setor florestal brasileiro cresce produtividade em 30 anos. Clonagem do eucalipto se destaca**. Disponível em: <<http://celuloseonline.com.br/setor-florestal-brasileiro-cresce-produtividade-em-30-anos-clonagem-eucalipto-se-destaca/>>. Acesso em 17 de setembro de 2019.

ČERNÝ, V. **Thermodynamical approach to the traveling salesman problem: An efficient simulation algorithm**. *Journal of optimization theory and applications*, v. 45, n. 1, p. 41–51, 1985.

COSENZA, D. N., SOARES, A. A. V., DE ALCÂNTARA, A. E. M., DA SILVA, A. A. L., RODE, R., SOARES, V. P., & LEITE, H. G.. **Classificação de sítio para povoamentos de eucalipto utilizando redes neurais artificiais baseada em variáveis ambientais e de manejo**. *Cerne*, 23(3), 310-320, 2017.

COSENZA, D. N.; LEITE, H. G.; *et al.* **Classificação da capacidade produtiva de sítios florestais utilizando máquina de vetor de suporte e rede neural artificial**. *Scientia Forestalis*, v. 43, n. 108, p. 955–963, 2015.

DANTAS, D., RODRIGUES PINTO, L. O., DE CASTRO NUNES SANTOS TERRA, M., CALEGARIO, N., DE OLIVEIRA, R., & LELES, M.. **Reduction of sampling intensity in forest inventories to estimate the total height of eucalyptus trees**. *Bosque (Valdivia)*, 41(3), 353-364, 2020.

DANTAS, D., TERRA, M. D. C. N. S., SCHORR, L. P. B., & CALEGARIO, N. **Machine learning for carbon stock prediction in a tropical forest in Southeastern Brazil**. *BOSQUE*, 42(1), 131-140, 2021.

DA ROCHA, S. J. S. S., TORRES, C. M. M. E., JACOVINE, L. A. G., LEITE, H. G., GELCER, E. M., NEVES, K. M., ... & ZANUNCIO, J. C.. **Artificial neural networks: Modeling tree survival and mortality in the Atlantic Forest biome in Brazil**. *Science of the total environment*, 645, 655-661, 2018.

DAVIS, D. T.; CHEN, Z.; *et al.* Retrieval of snow parameters by iterative inversion of a neural network. *IEEE Transactions on Geoscience and Remote Sensing*, v. 31, n. 4, p. 842–852, 1993.

DE AZEVEDO, G. B., TOMIAZZI, H. V., AZEVEDO, G. T. D. O. S., TEODORO, L. P. R., TEODORO, P. E., DE SOUZA, M. T. P., ... & GUERRA, S. P. S.. **Multi-volume modeling of Eucalyptus trees using regression and artificial neural networks**. *Plos one*, 15(9), e0238703, 2020.

DIAMANTOPOULOU, M. J.; MILIOS, E. **Modelling total volume of dominant pine trees in reforestations via multivariate analysis and artificial neural network models**. *Biosystems Engineering*, v. 105, n. 3, p. 306–315, 1 mar. 2010.

DOLÁCIO, C. J. F., OLIVEIRA, R. S., NAKAJIMA, N. Y., JÚNIOR, I. D. S. T., DA ROCHA, J. E. C., EBLING, Â. A., & GAMA, M. A. P.. **Integration of principal component analysis and artificial neural network to modeling productive capacity of eucalypt stands from biophysical attributes**. *Forest Ecology and Management*, 460, 117862, 2020.

DOLÁCIO, C. J. F., OLIVEIRA, R. S., NAKAJIMA, N. Y., DA SILVA, D. A., EBLING, Â. A., & DA ROCHA, J. E. C.. **Modeling of stored carbon in the trunk of Eucalyptus trees with linear models and artificial neural network**. *Advances in Forestry Science*, 6(2), 665-671, 2019.

FERRAZ, A. S.; SOARES, V. P.; *et al.* **Estimativa do estoque de biomassa em um fragmento florestal usando imagens orbitais**. *Floresta e Ambiente*, v. 21, p. 286–296, 2014.

FREITAS, ELIANE CRISTINA SAMPAIO DE. **Modelagem da produtividade de eucalipto por meio de redes neuronais artificiais**. 2017. 113 f. Tese (Doutorado em Ciência Florestal) - Universidade Federal de Viçosa, Viçosa. 2017.

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

GONCALVES, J. DE M.; ALVARES, C. A.; *et al.* **Produtividade de plantações de eucalipto manejadas nos sistemas de alto fuste e talhadia, em função de fatores edafoclimáticos**. Embrapa Agrossilvipastoril-Artigo em periódico indexado (ALICE), 2014.

GORDON, C. **Artificial neural network modeling of forest tree growth**. arXiv preprint physics/9906012, 1999.

GORGENS, E. B.; LEITE, H. G.; *et al.* **Estimação do volume de árvores utilizando redes neurais artificiais**. *Revista Árvore*, v. 33, p. 1141–1147, 2009.

GUAN, B. T.; GERTNER, G. **Modeling red pine tree survival with an artificial neural network**. *Forest Science*, v. 37, n. 5, p. 1429–1440, 1991.

GREY, D.C. **Site classification of forestry land**. *South Afr. For. J.*, 138:54-57, 1985.

GUAN, B. T.; GERTNER G. **Modeling individual tree survival probability with a random optimization procedure: An artificial neural network approach**. *AI Application*, v. 9, n.1, p. 39-52, 1995.

HARRINGTON, T. B.; HARRINGTON, C. A.; DEBELL, D. S. **Effects of planting spacing and site quality on 25-year growth and mortality relationships of Douglas-fir (*Pseudotsuga menziesii* var. *menziesii*)**. *Forest Ecology and Management*, v. 258, n. 1, p. 18–25, 2009.

HOSSEINABADI, A. A. R.; ALAVIPOUR, F.; *et al.* **A novel meta-heuristic combinatory method for solving capacitated vehicle location-routing problem with hard time windows.** *In: Information Technology and Intelligent Transportation Systems.* [s.l.] Springer, p. 707–728., 2017.

HUSCH, B.; MILLER, C.I.; BEERS, T.W. **Forest mensuration.** New York: Wiley & Sons, 1982. 398 p.

HWANG, J.-N.; CHAN, C.-H.; RJ, I. **Frequency selective surface design based on iterative inversion of neural networks** 1990 IJCNN International Joint Conference on Neural Networks. Anais...IEEE, 1990.

IBÁ. **Relatório 2019.** Disponível em: <<https://iba.org/datafiles/publicacoes/relatorios/iba-relatorioanual2019.pdf>>. Acesso em 31 de outubro de 2021.

INVESTIAGRO. **Setor Florestal batalha para elevar produtividade mas clima atrapalha.** Disponível em: <<http://www.investagro.com.br/setor-de-florestas-batalha-para-elevar-produtividade-mas-clima-atrapalha>>. Acesso em 17 de setembro de 2016.

JIAO, G., & LI, W.. **Neural Network Data Mining Clustering Optimization Algorithm.** IETE Journal of Research, 1-11.2021.

JENSEN, C. A.; REED, R. D.; *et al.* **Inversion of feedforward neural networks: Algorithms and applications.** Proceedings of the IEEE, v. 87, n. 9, p. 1536–1549, 1999.

JESUS, G. L. DE; SILVA, I. R.; *et al.* **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. 1190–1203, 2015.

KIM, T. J.; BULLOCK, B. P.; STAPE, J. L. **Effects of silvicultural treatments on temporal variations of spatial autocorrelation in Eucalyptus plantations in Brazil.** Forest Ecology and Management, v. 358, p. 90–97, 2015.

LAFETÁ, BRUNO OLIVEIRA. **Eficiência nutricional, área foliar e produtividade de plantações de eucalipto em diferentes espaçamentos estimados com redes neurais artificiais.** 2012. 76 p. Dissertação (Mestrado) – Programa de Pós-Graduação em Ciência Florestal, Universidade Federal dos Vales do Jequitinhonha e Mucuri, Diamantina, 2012.

LAPPI, JUHA; BAILEY, ROBERT L. **A height prediction model with random stand and tree parameters: an alternative to traditional site index methods.** Forest Science, v. 34, n. 4, p. 907-927, 1988.

LEITE, R. V., AMARAL, C. H. D., PIRES, R. D. P., SILVA, C. A., SOARES, C. P. B., MACEDO, R. P., ... & LEITE, H. G.. **Estimating stem volume in eucalyptus**

**plantations using airborne LiDAR: A comparison of area-and individual tree-based approaches.** Remote Sensing, 12(9), 1513, 2020.

LINDEN, A.; KINDERMANN, J. **Inversion of multilayer nets** Proc. Int. Joint Conf. Neural Networks. Anais...1989.

LU, B.-L.; KITA, H.; NISHIKAWA, Y. **Inverting feedforward neural networks using linear and nonlinear programming.** IEEE Transactions on Neural networks, v. 10, n. 6, p. 1271–1290, 1999.

LU, L., ZHENG, Y., CARNEIRO, G., & YANG, L.. **Deep learning and convolutional neural networks for medical image computing.** Advances in computer vision and pattern recognition, 10, 978-3. 2017.

MARTINS, E. R.; ARAÚJO, A. C. S. C.; SILVA, P. V.; BINOTI, M. L. M. S.; BINOTI, D. H. B.; LEITE, H. G. **Parametrização de redes neurais artificiais para estimação da altura total de árvores de povoamentos de eucalipto.** Atualidades em Mensuração Florestal [livro eletrônico]. Ed. Ana Paula Dalla Corte... [et al.]. – 1. ed. – Curitiba, 2014. 407 p.

MAZON DE ALCANTARA, A. E.; ALBUQUERQUE SANTOS, A. DE; *et al.* **Use of artificial neural networks to assess yield projection and average production of eucalyptus stands.** African Journal of Agricultural Research, v. 13, p. 2285–2297, 18 out. 2018.

MENON, M. U. **Meta-heurísticas na otimização do sortimento florestal.** 2005. Tese (doutorado) - Universidade Federal do Paraná, Setor de Ciências Agrárias, Programa de Pós-Graduação em Engenharia Florestal. Defesa: Curitiba, 2005.

OLIVEIRA, M. L. R. DE; LEITE, H. G.; *et al.* **Modelagem e prognose em povoamentos não desbastados de clones de eucalipto.** Revista Árvore, v. 33, n. 5, p. 841–852, 2009.

NOVAIS, R. F.; ALVAREZ, V. H.; BARROS, N; F.; FONTES, R. L. F.; CANTARUTTI, R. B.; NEVES, J. C. L. **Fertilidade do solo.** 1 ed. Viçosa: Sociedade Brasileira de Ciência do Solo, 2007. 1017 p.

OTTO, M. S. G.; VERGANI, A. R.; *et al.* **Fotossíntese, condutância estomática e produtividade de clones de Eucalyptus sob diferentes condições edafoclimáticas.** Revista Árvore, v. 37, n. 3, p. 431–439, 2013.

PAN, H., BADAWI, D., ZHANG, X., & CETIN, A. E.. **Additive neural network for forest fire detection.** Signal, Image and Video Processing, 14(4), 675-682, 2020.

PEREIRA, A. R.; ANGELOCCI, L. R.; SENTELHAS, P. C. **Agrometeorologia: fundamentos e aplicações práticas.** Guaíba.: Livraria e Editora Agropecuária, 2002. 478 p, 2002.

PORTAL DO AGRONEGÓCIO. **Setor florestal na batalha para elevar produtividade** . Disponível em: <http://www.portaldoagronegocio.com.br/noticia/setor->

[de-florestas-batalha-para-elevar-productividade-mas-clima-atrapalha-142435](#). Acesso em 17 de setembro de 2016.

PÖYRY. **Reinventando a produção florestal**. Disponível em: <[http://www.poyry.com.br/sites/www.poyry.com.br/files/media/related\\_material/14dez17a-reinventando\\_a\\_producao\\_florestal\\_-\\_final.pdf](http://www.poyry.com.br/sites/www.poyry.com.br/files/media/related_material/14dez17a-reinventando_a_producao_florestal_-_final.pdf)>. Acesso em 17 de setembro de 2016.

RAI, A. K., MANDAL, N., SINGH, A., & SINGH, K. K.. **Landsat 8 OLI Satellite Image Classification using Convolutional Neural Network**. Procedia Computer Science, 167, 987-993, 2020.

RENCHE, A. C. **Methods of Multivariate Analysis**. Computational Statistics, 12(4), 422-422, 2002.

RESENDE, R. T.; MARCATTI, G. E.; *et al.* **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.

RESENDE, R. T.; SOARES, A. A.; *et al.* **Environmental uniformity, site quality and tree competition interact to determine stand productivity of clonal Eucalyptus**. Forest Ecology and Management, v. 410, p. 76–83, 2018.

ROCHA, MARIA FERNANDA VIEIRA. **Influence of spacing and age on the productivity and properties of the Eucalyptus grandis x Eucalyptus camaldulensis wood for energy**. 2011. 86 f. Dissertação (Mestrado em Manejo Florestal; Meio Ambiente e Conservação da Natureza; Silvicultura; Tecnologia e Utilização de) - Universidade Federal de Viçosa, Viçosa, 2011.

DA ROCHA, S. P., PREVEDELLO, J., REINERT, D. J., FLEIG, F. D., VOGELMANN, E. S., SOARES, J. C. W., & HEINZ, B. B.. **Soil physical properties and eucalyptus growth planted after different tillage methods**. Scientia Forestalis, 43(108), 965-977, 2015.

SAHU, A., HARSHVARDHAN, G. M., & GOURISARIA, M. K.. **A Dual Approach for Credit Card Fraud Detection using Neural Network and Data Mining Techniques**. In 2020 IEEE 17th India Council International Conference (INDICON) (pp. 1-7). IEEE, 2020.

SILVA, M. L. M. DA; BINOTI, D. H. B.; *et al.* **Ajuste do modelo de Schumacher e Hall e aplicação de redes neurais artificiais para estimar volume de árvores de eucalipto**. Revista Árvore, v. 33, n. 6, p. 1133–1139, 2009.

SILVA, PAULO HENRIQUE MÜLLER DA. **Impactos das doses e do parcelamento da fertilização na produtividade, lixiviação e ciclagem de nutrientes em plantações de eucalipto**. 2011. Tese (Doutorado em Recursos Florestais) - Escola Superior de Agricultura Luiz de Queiroz, University of São Paulo, Piracicaba, 2011. doi:10.11606/T.11.2011.tde-14022012-102542. Acesso em: 2021-10-31.

SILVA, R. DA; HAKAMADA, R.; *et al.* **Fertilization response, light use, and growth efficiency in Eucalyptus plantations across soil and climate gradients in Brazil.** *Forests*, v. 7, n. 6, p. 117, 2016.

SILVA, P. V.; ARAÚJO, A. C. S. C.; MARTINS, E. R.; BINOTI, M. L. M. S.; BINOTI, D. H. B.; LEITE, H. G. **Estimação do volume de árvores de eucalipto utilizando redes neurais artificiais.** *Atualidades em Mensuração Florestal* [livro eletrônico]. Ed. Ana Paula Dalla Corte. [et al.]. – 1. ed. – Curitiba, 2014. 407 p.

SOARES, C. P. B.; LEITE, H. G. **Predição da produção de madeira de eucalipto em região com alta variabilidade pluviométrica.** *Scientia forestalis*, v. 58, n. 103, p. 41–48, 2000.

SOCHA, J., NETZEL, P., & CYWICKA, D.. **Stem taper approximation by artificial neural network and a regression set models.** *Forests*, 11(1), 79, 2020.

STAPE, J. L.; BINKLEY, D.; *et al.* **Water use, water limitation, and water use efficiency in a Eucalyptus plantation.** *Bosque*, v. 25, n. 2, p. 35–41, 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, n. 3–4, p. 920–930, 2008.

SYLVAIN, J. D., DROLET, G., & BROWN, N.. **Mapping dead forest cover using a deep convolutional neural network and digital aerial photography.** *ISPRS Journal of Photogrammetry and Remote Sensing*, 156, 14-26, 2019.

TABACHNICK, BARBARA G.; FIDELL, LINDA S.; ULLMAN, JODIE B. **Using multivariate statistics.** Boston, MA: Pearson, 2007.

THORNTHWAITE, C. W.; MATHER, J. R. **The water balance.** *Publications in climatology.*, v. 8, p. 1–104, 1955.

VIANA, G. V. R. **Meta-heurísticas e programação paralela em otimização combinatória.** Fortaleza: UFC, 250 p.,1998.

WILLIAMS, R. J.. **Inverting a connectionist network mapping by backpropagation of error,** in *Proc. 8th Annu. Conf. Cognitive Sci. Soc.*. Hillsdale, NJ: Lawrence Erlbaum, pp. 859–865,1986.

ZEKIĆ-SUŠAC, M.; ŠARLIJA, N.; PFEIFER, S. **Combining PCA analysis and artificial neural networks in modelling entrepreneurial intentions of students.** *Croatian Operational Research Review*, v. 4, n. 1, p. 306–317, 2013.

ZUXING, C., & DIAN, W.. **A prediction model of forest preliminary precision fertilization based on improved GRA-PSO-BP neural network.** *Mathematical Problems in Engineering*, 2020.