



Diocléa Almeida Seabra Silva
(Organizadora)

Agronomia: Elo da Cadeia Produtiva 6



Diocléa Almeida Seabra Silva
(Organizadora)

Agronomia: Elo da Cadeia Produtiva 6

Atena
Editora
Ano 2019

2019 by Atena Editora
Copyright © Atena Editora
Copyright do Texto © 2019 Os Autores
Copyright da Edição © 2019 Atena Editora
Editora Chefe: Profª Drª Antonella Carvalho de Oliveira
Diagramação: Natália Sandrini
Edição de Arte: Lorena Prestes
Revisão: Os Autores



Todo o conteúdo deste livro está licenciado sob uma Licença de Atribuição Creative Commons. Atribuição 4.0 Internacional (CC BY 4.0).

O conteúdo dos artigos e seus dados em sua forma, correção e confiabilidade são de responsabilidade exclusiva dos autores. Permitido o download da obra e o compartilhamento desde que sejam atribuídos créditos aos autores, mas sem a possibilidade de alterá-la de nenhuma forma ou utilizá-la para fins comerciais.

Conselho Editorial

Ciências Humanas e Sociais Aplicadas

Profª Drª Adriana Demite Stephani – Universidade Federal do Tocantins
Prof. Dr. Álvaro Augusto de Borba Barreto – Universidade Federal de Pelotas
Prof. Dr. Alexandre Jose Schumacher – Instituto Federal de Educação, Ciência e Tecnologia de Mato Grosso
Prof. Dr. Antonio Carlos Frasson – Universidade Tecnológica Federal do Paraná
Prof. Dr. Antonio Gasparetto Júnior – Instituto Federal do Sudeste de Minas Gerais
Prof. Dr. Antonio Isidro-Filho – Universidade de Brasília
Prof. Dr. Constantino Ribeiro de Oliveira Junior – Universidade Estadual de Ponta Grossa
Profª Drª Cristina Gaio – Universidade de Lisboa
Prof. Dr. Deyvison de Lima Oliveira – Universidade Federal de Rondônia
Prof. Dr. Edvaldo Antunes de Farias – Universidade Estácio de Sá
Prof. Dr. Eloi Martins Senhora – Universidade Federal de Roraima
Prof. Dr. Fabiano Tadeu Grazioli – Universidade Regional Integrada do Alto Uruguai e das Missões
Prof. Dr. Gilmei Fleck – Universidade Estadual do Oeste do Paraná
Profª Drª Ivone Goulart Lopes – Istituto Internazionele delle Figlie de Maria Ausiliatrice
Prof. Dr. Julio Candido de Meirelles Junior – Universidade Federal Fluminense
Profª Drª Keyla Christina Almeida Portela – Instituto Federal de Educação, Ciência e Tecnologia de Mato Grosso
Profª Drª Lina Maria Gonçalves – Universidade Federal do Tocantins
Profª Drª Natiéli Piovesan – Instituto Federal do Rio Grande do Norte
Prof. Dr. Marcelo Pereira da Silva – Universidade Federal do Maranhão
Profª Drª Miranilde Oliveira Neves – Instituto de Educação, Ciência e Tecnologia do Pará
Profª Drª Paola Andressa Scortegagna – Universidade Estadual de Ponta Grossa
Profª Drª Rita de Cássia da Silva Oliveira – Universidade Estadual de Ponta Grossa
Profª Drª Sandra Regina Gardacho Pietrobon – Universidade Estadual do Centro-Oeste
Profª Drª Sheila Marta Carregosa Rocha – Universidade do Estado da Bahia
Prof. Dr. Rui Maia Diamantino – Universidade Salvador
Prof. Dr. Urandi João Rodrigues Junior – Universidade Federal do Oeste do Pará
Profª Drª Vanessa Bordin Viera – Universidade Federal de Campina Grande
Prof. Dr. Willian Douglas Guilherme – Universidade Federal do Tocantins

Ciências Agrárias e Multidisciplinar

Prof. Dr. Alexandre Igor Azevedo Pereira – Instituto Federal Goiano
Prof. Dr. Antonio Pasqualetto – Pontifícia Universidade Católica de Goiás
Profª Drª Daiane Garabeli Trojan – Universidade Norte do Paraná
Profª Drª Diocléa Almeida Seabra Silva – Universidade Federal Rural da Amazônia
Prof. Dr. Écio Souza Diniz – Universidade Federal de Viçosa
Prof. Dr. Fábio Steiner – Universidade Estadual de Mato Grosso do Sul
Profª Drª Girlene Santos de Souza – Universidade Federal do Recôncavo da Bahia
Prof. Dr. Jorge González Aguilera – Universidade Federal de Mato Grosso do Sul
Prof. Dr. Júlio César Ribeiro – Universidade Federal Rural do Rio de Janeiro
Profª Drª Raissa Rachel Salustriano da Silva Matos – Universidade Federal do Maranhão
Prof. Dr. Ronilson Freitas de Souza – Universidade do Estado do Pará
Prof. Dr. Valdemar Antonio Paffaro Junior – Universidade Federal de Alfenas

Ciências Biológicas e da Saúde

Prof. Dr. Benedito Rodrigues da Silva Neto – Universidade Federal de Goiás
Prof. Dr. Edson da Silva – Universidade Federal dos Vales do Jequitinhonha e Mucuri
Profª Drª Elane Schwinden Prudêncio – Universidade Federal de Santa Catarina
Prof. Dr. Gianfábio Pimentel Franco – Universidade Federal de Santa Maria
Prof. Dr. José Max Barbosa de Oliveira Junior – Universidade Federal do Oeste do Pará
Profª Drª Magnólia de Araújo Campos – Universidade Federal de Campina Grande
Profª Drª Natiéli Piovesan – Instituto Federal do Rio Grande do Norte
Profª Drª Vanessa Lima Gonçalves – Universidade Estadual de Ponta Grossa
Profª Drª Vanessa Bordin Viera – Universidade Federal de Campina Grande

Ciências Exatas e da Terra e Engenharias

Prof. Dr. Adélio Alcino Sampaio Castro Machado – Universidade do Porto
Prof. Dr. Alexandre Leite dos Santos Silva – Universidade Federal do Piauí
Profª Drª Carmen Lúcia Voigt – Universidade Norte do Paraná
Prof. Dr. Eloi Rufato Junior – Universidade Tecnológica Federal do Paraná
Prof. Dr. Fabrício Menezes Ramos – Instituto Federal do Pará
Prof. Dr. Juliano Carlo Rufino de Freitas – Universidade Federal de Campina Grande
Profª Drª Neiva Maria de Almeida – Universidade Federal da Paraíba
Profª Drª Natiéli Piovesan – Instituto Federal do Rio Grande do Norte
Prof. Dr. Takeshy Tachizawa – Faculdade de Campo Limpo Paulista

| Dados Internacionais de Catalogação na Publicação (CIP) (eDOC BRASIL, Belo Horizonte/MG) | |
|---|---|
| A281 | <p>Agronomia [recurso eletrônico] : elo da cadeia produtiva 6 / Organizadora Diocléa Almeida Seabra Silva. – Ponta Grossa, PR: Atena Editora, 2019. – (Agronomia: Elo da Cadeia Produtiva; v. 6)</p> <p>Formato: PDF Requisitos de sistema: Adobe Acrobat Reader Modo de acesso: World Wide Web Inclui bibliografia ISBN 978-85-7247-825-0 DOI 10.22533/at.ed.250190312</p> <p>1. Agricultura – Economia – Brasil. 2. Agronomia – Pesquisa – Brasil. I. Silva, Diocléa Almeida Seabra. II. Série.</p> <p style="text-align: right;">CDD 630.981</p> |
| Elaborado por Maurício Amormino Júnior – CRB6/2422 | |

Atena Editora
Ponta Grossa – Paraná - Brasil
www.atenaeditora.com.br
contato@atenaeditora.com.br

APRESENTAÇÃO

A cadeia produtiva é um termo amplo que define com clareza onde cada segmento tem seu grau de importância seja na produtividade de frutos, venda de semente de capineira, na pesca, na aquicultura, na formação de resíduos para a indústria, no controle determinado de vírus, bactérias, nematóides para a agricultura e até mesmo na comercialização de espécies florestais com potencial madeireiro. Na verdade, o termo cadeia produtiva é um conjunto de ações ou processos que fazem presente em estudos científicos que irá dar imagem para o avanço de um produto final.

A imagem de um produto final se torna possível quando trabalhamos todos os elos da cadeia, como por exemplo: para um produtor chegar a comercializar o feijão, ele precisará antes preparar seu solo, ter maquinários pra isso, além de correr o solo com corretivo, definindo a saturação de base ideal, plantar a semente de boa qualidade, adubar, acompanhar a produção fazendo os tratamentos culturais adequados, controlando pragas, doenças e ervas daninhas, além de encontrar mercados para que o mesmo possa vender sua produção. Esses elos são essenciais em todas as áreas, ao passo que na produção de madeira será necessário técnicas sofisticadas de manejo que começa na germinação de sementes, quebra de dormência para a formação de mudas, e além disso padronizar espaçamento, tratamentos silviculturais para a formação de madeira em tora para exportação.

Na pesca a cadeia produtiva segue a vertente do ganho de peso e da qualidade da carne do pescado, que está vinculada a temperatura, pH da água, oxigenação, alimentação e o ambiente para que haja produção. Também a cadeia se verticaliza na agregação de preço ao subproduto do pescado como o filetagem para as indústrias, mercado de peixe vivo e etc.

Na cadeia cujo foco são os resíduos da indústria açucareira, há mercados para a queima de combustível no maquinário da indústria, através da qualidade deste resíduo, além de mercados promissores para a fabricação de combustíveis, rações e até mesmo resíduo vegetal para incorporação nos solos, com a finalidade de manter ou melhorar as características químicas, físicas e biológicas, além de controlar erosão e elevar os níveis de produtividade nas áreas agrícolas, através da adição de nutrientes.

Contudo, sabemos que todos os elos que compõem a cadeia produtiva são responsáveis por agregar valor e gerar de maneira direta e indireta renda aos produtores e pescadores, possibilitando-os na melhoria da qualidade de vida, além da obtenção de produtos de alta qualidade. No entanto, aqui se faz presente a importância das pesquisas mostradas neste E-Book, v. 6 – Agronomia: Elo da Cadeia Produtiva para que o leitor possa perceber novidades que são contextualizadas, através dos trabalhos aqui publicados.

SUMÁRIO

| | |
|---|-----------|
| CAPÍTULO 1 | 1 |
| CONTROLE DE <i>Meloidogyne javanica</i> EM JILOEIRO (<i>Solanum gilo</i>) COM RESÍDUO DO FRUTO DE PEQUI (<i>Caryocar brasiliense</i>) | |
| Rodrigo Vieira da Silva João Pedro Elias Gondim Fabrício Rodrigues Peixoto Luam Santos Emmerson Rodrigues de Moraes José Humberto Ávila Júnior Luiz Leonardo Ferreira Silvio Luis de Carvalho | |
| DOI 10.22533/at.ed.2501903121 | |
| CAPÍTULO 2 | 12 |
| FUNGOS COMO AGENTES DE CONTROLE BIOLÓGICO DE FITONEMATOIDES | |
| Valéria Ortaça Portela Juliane Schmitt Leticia Moro | |
| DOI 10.22533/at.ed.2501903122 | |
| CAPÍTULO 3 | 22 |
| NEMATOIDES ENTOMOPATOGÊNICOS (NEPs) | |
| Raiana Rocha Pereira Josiane Pacheco de Alfaia Artur Vinícius Ferreira dos Santos Débora Oliveira Gomes Raphael Coelho Pinho Lyssa Martins de Souza Shirlene Cristina Brito da Silva Telma Fátima Vieira Batista | |
| DOI 10.22533/at.ed.2501903123 | |
| CAPÍTULO 4 | 33 |
| ICTIOFAUNA DA PRAIA DE BERLINQUE, ILHA DE ITAPARICA, MUNICÍPIO DE VERA CRUZ - BA | |
| Edilmar Ribeiro Sousa Hortência Ramos Gomes Santos Fabrício Menezes Ramos | |
| DOI 10.22533/at.ed.2501903124 | |
| CAPÍTULO 5 | 44 |
| PESCADORES E SUAS PERCEPÇÕES SOBRE A PESCA EM PEQUENA ESCALA: ESTUDO DE CASO NA VILA DOS PESCADORES, COMUNIDADE COSTEIRA NA AMAZÔNIA (BRAGANÇA-PARÁ) | |
| Maria Eduarda Garcia de Sousa Pereira Thaila Cristina Neves do Rosário Hanna Tereza Garcia de Sousa Moura Elizete Neres Monteiro Francisco José da Silva Santos | |
| DOI 10.22533/at.ed.2501903125 | |

CAPÍTULO 6 57

INFLUÊNCIA DE CULTIVAR E DO PERÍODO DE COLHEITA NA PRODUTIVIDADE E NO PADRÃO DE FRUTOS DE MAMOEIROS, INTRODUZIDOS DO ESTADO DO ESPÍRITO SANTO, EM CONDIÇÕES EDAFOCLIMÁTICAS DO AMAZONAS

Lucio Pereira Santos
Enilson de Barros Silva
Scheilla Marina Bragança

DOI 10.22533/at.ed.2501903126

CAPÍTULO 7 71

MÉTODOS QUÍMICOS NA SUPERAÇÃO DA DORMÊNCIA DE *Brachiaria brizantha* (Hochst ex A. Rich.) Stapf

Tiago de Oliveira Sousa
Mahany Graça Martins
Marcela Carlota Nery
Marcela Azevedo Magalhães
Thaís Silva Sales
Letícia Lopes de Oliveira
Letícia Aparecida Luiz de Azevedo
Bruno de Oliveira Fernandes

DOI 10.22533/at.ed.2501903127

CAPÍTULO 8 79

MICROBIOMA BACTERIANO: EXTRAÇÃO E PREPARAÇÃO DE BIBLIOTECAS METAGENÔMICAS

Juliano Oliveira Santana
Karina Peres Gramacho
Katiúcia Tícila de Souza de Nascimento
Rachel Passos Rezende
Carlos Priminho Pirovani

DOI 10.22533/at.ed.2501903128

CAPÍTULO 9 106

MODELO PARA A MELHORIA DO PROCESSO DE REGULARIZAÇÃO DA AQUICULTURA PRATICADA EM RESERVATÓRIOS DA UNIÃO BRASILEIRA

Sara Monaliza Sousa Nogueira
Marco Aurélio dos Santos
Sandro Alberto Vianna Lordelo
José Rodrigues de Farias Filho

DOI 10.22533/at.ed.2501903129

CAPÍTULO 10 123

NOVA VARIIDADE SEMINAL DE *STEVIA REBAUDIANA*: OBTENÇÃO DE FRAÇÕES COM ALTO POTENCIAL ANTIOXIDANTE DE FOLHAS

Paula Gimenez Milani
Maysa Formigoni
Antonio Sergio Dacome
Livia Benossi
Maria Rosa Trentin Zorzenon
Simone Rocha Ciotta
Cecília Edna Mareze da Costa
Silvio Claudio da Costa

DOI 10.22533/at.ed.25019031210

CAPÍTULO 11 136

OS CENTROS DE TRATAMENTO DE RESÍDUOS E O PRISIONAL: REFLEXIBILIDADE AMBIENTAL E NA SAÚDE

Paulo Barrozo Cassol
Edenilson Perufo frigo
Alberto Manuel Quintana

DOI 10.22533/at.ed.25019031211

CAPÍTULO 12 148

PARÂMETROS DE RESISTÊNCIA PARA CARACTERIZAÇÃO DA FERRUGEM-ASIÁTICA DA SOJA TRATADA COM COMBINAÇÕES QUÍMICAS DE FUNGICIDAS SISTÊMICOS E DE CONTATO

Milton Luiz da Paz Lima
Gleina Costa Silva Alves
Matheus do Carmo Leite
Andressa de Souza Almeida
Rafaela Souza Alves Fonseca
Cleberly Evangelista dos Santos
Marciel José Peixoto
Flavia de Oliveira Biazotto
Lettícia Alvarenga
Justino José Dias Neto
Wesler Luiz Marcelino

DOI 10.22533/at.ed.25019031212

CAPÍTULO 13 166

PRODUÇÃO DA SOJA EM FUNÇÃO DE DIFERENTES ÉPOCAS DE APLICAÇÃO DE BIOESTIMULANTE

Cristiano de Freyn
Alexandre Luis Müller
Dyogo Bortot Brustolin
André Prechtlak Barbosa
Martios Ecco
Vitor Hugo Rosseto Belotto
Luiz Henrique da Costa Figueiredo
Vinícius Fernando Carrasco Gomes
Matheus Henrique de Lima Raposo
Anderson José Pick Benke
Arlon Felipe Pereira
Alan Benincá

DOI 10.22533/at.ed.25019031213

CAPÍTULO 14 174

BIOGAS PRODUCTION FROM SECOND GENERATION ETHANOL VINASSE

Manuella Souza Silverio
Rubens Perez Calegari
Gabriela Maria Ferreira Lima Leite
Bianca Chaves Martins
Eric Alberto da Silva
José Piotrovski Neto
Mario Wilson Cusatis
André Gomig
Antonio Sampaio Baptista

DOI 10.22533/at.ed.25019031214

CAPÍTULO 15 185

PRODUÇÃO DE PEPTÍDEOS ANTIMICROBIANOS EM SISTEMAS VEGETAIS: VÍRUS DE PLANTAS COMO REATORES DE FÁRMACOS

Nicolau Brito da Cunha
Michel Lopes Leite
Kamila Botelho Sampaio
Simoni Campos Dias

DOI 10.22533/at.ed.25019031215

CAPÍTULO 16 219

PROGNOSE DO VOLUME DE MADEIRA EM FLORESTAS EQUIÂNEAS POR MEIO DE MODELOS AGROMETEOROLÓGICOS DE REDES NEURAIS ARTIFICIAIS

Mariana Rodrigues Magalhães Romeiro
Aristides Ribeiro
Leonardo Bonato Felix
Aylen Ramos Freitas
Mayra Luiza Marques da Silva
Aline Edwiges Mazon de Alcântara

DOI 10.22533/at.ed.25019031216

CAPÍTULO 17 232

QUALIDADE FISIOLÓGICA DE SEMENTES DE FEIJÃO AMENDOIM, TRATADAS COM FERTILIZANTE ORGANOMINERAL E SUBMETIDAS AO ESTRESSE SALINO

Thiago Figueiredo Paulucio
Paula Aparecida Muniz de Lima
Rodrigo Sobreira Alexandre
José Carlos Lopes

DOI 10.22533/at.ed.25019031217

CAPÍTULO 18 245

QUALIDADE MORFOLÓGICA E FISIOLÓGICA DE SEMENTES DE FEIJÃO

Manoel Victor Borges Pedrosa
Arêssa de Oliveira Correia
Patrícia Alvarez Cabanez
Allan de Rocha Freitas
Rodrigo Sobreira Alexandre
José Carlos Lopes

DOI 10.22533/at.ed.25019031218

CAPÍTULO 19 256

RELAÇÕES ENTRE A UMIDADE E ALGUMAS CARACTERÍSTICAS FÍSICAS DE *PINUS SP.*, ANGELIM-PEDRA (*HYMENOLOBIMUM PETRAEUM*) E CAIXETA (*TABEBUIA CASSINOIDES*)

Vitor Augusto Cordeiro Milagres
Jessyka Cristina Reis Vieira
Luiz Carlos Couto
Magno Alves Mota

DOI 10.22533/at.ed.25019031219

CAPÍTULO 20 262

TEOR DE NITROGÊNIO ORGÂNICO NAS FOLHAS E DE PROTEÍNA BRUTA NOS GRÃOS DE SOJA FERTILIZADA COM NITROGÊNIO E MOLIBDÊNIO

Lucio Pereira Santos
Clibas Vieira

DOI 10.22533/at.ed.25019031220

| | |
|--|------------|
| CAPÍTULO 21 | 280 |
| TEORES DE MANGANÊS EM <i>Pereskia Grandfolia</i> Haw. | |
| Nelma Ferreira de Paula Vicente | |
| Erica Alves Marques | |
| Michelle Carlota Gonçalves | |
| Abraão José Silva Viana | |
| Adjaci Uchôa Fernandes | |
| Roberta Hilsdorf Piccoli | |
| DOI 10.22533/at.ed.25019031221 | |
| CAPÍTULO 22 | 285 |
| THE HEIGHT OF CROP RESIDUES INFLUENCES INTAKE RATE OF SHEEP IN INTEGRATED CROP-LIVESTOCK SYSTEMS | |
| Delma Fabíola Ferreira da Silva | |
| Carolina Bremm | |
| Vanessa Sehaber | |
| Natália Marcondes dos Santos Gonzales | |
| Breno Menezes de Campos | |
| Anibal de Moraes | |
| Anderson M. S. Bolzan | |
| Alda Lucia Gomes Monteiro | |
| Paulo César de Faccio Carvalho | |
| DOI 10.22533/at.ed.25019031222 | |
| CAPÍTULO 23 | 298 |
| USO DE RESÍDUOS DA INDÚSTRIA DE AÇÚCAR E ÁLCOOL: BENEFÍCIOS E PERDAS | |
| Camila Almeida dos Santos | |
| Leonardo Fernandes Sarkis | |
| Eduardo Carvalho da Silva Neto | |
| Luis Otávio Nunes da Silva | |
| Leonardo Duarte Batista da Silva | |
| DOI 10.22533/at.ed.25019031223 | |
| SOBRE A ORGANIZADORA | 310 |
| ÍNDICE REMISSIVO | 311 |

PROGNOSE DO VOLUME DE MADEIRA EM FLORESTAS EQUIÂNEAS POR MEIO DE MODELOS AGROMETEOROLÓGICOS DE REDES NEURAIS ARTIFICIAIS

Mariana Rodrigues Magalhães Romeiro

Doutora em Engenharia Agrícola - UFV
Belo Horizonte – Minas Gerais

Aristides Ribeiro

Departamento de Engenharia Agrícola – UFV
Viçosa – Minas Gerais

Leonardo Bonato Felix

Departamento de Engenharia Elétrica - UFV
Viçosa – Minas Gerais

Aylen Ramos Freitas

Graduanda em Engenharia Elétrica - UFV
Viçosa – Minas Gerais

Mayra Luiza Marques da Silva

Departamento de Engenharia Florestal - UFSJ
Sete Lagoas – Minas Gerais

Aline Edwiges Mazon de Alcântara

Doutora em Ciência Florestal - UFV
Belo Oriente – Minas Gerais

RESUMO: Diversas ferramentas computacionais e de modelagem matemática têm sido utilizadas com êxito em situações de tomada de decisão no setor florestal, destacando-se as Redes Neurais Artificiais (RNA). Diante do exposto, o trabalho visa elucidar as seguintes questões: i) A redução do número de variáveis por meio de métodos de ordenação pode otimizar a construção de modelos de redes neurais para estimação da prognose do volume de madeira?

ii) Existe diferença significativa entre prognoses realizadas por meio de diferentes métodos? iii) Qual o modelo mais eficiente para a realização da prognose do inventário florestal para a região do leste de Minas Gerais? Utilizou-se 3 metodologias: i) modelos construídos com a ordenação da Correlação de Pearson; ii) modelos construídos com a ordenação do Método de Garson; e iii) Modelo Híbrido. Todos os processamentos foram realizados no software Neuro AgroClimate. Houve diferença significativa entre os três modelos analisado, e a rede que apresentou o menor valor do RMSE do teste (%) foi o modelo 12 da metodologia da Correlação de Pearson. A seleção das variáveis dependentes foi eficaz ao otimizar o tempo de processamento das redes por se conhecer as variáveis do input.

PALAVRAS-CHAVE: Método de Garson; Correlação de Pearson; Neuro AgroClimate.

PROGNOSIS OF WOOD VOLUME IN THE PLANTED FORESTS BY MEANS OF AGROMETEOROLOGICAL MODELS OF ARTIFICIAL NEURAL NETWORKS

ABSTRACT: Several computational tools and mathematical modeling have been used successfully in decision-making situations in the forestry sector, with emphasis on Artificial

Neural Networks (RNA). In view of the above, the paper aims at elucidating the following questions: i) Can the reduction of the number of variables by ordering methods optimize the construction of neural network models to estimate the prognosis of the wood volume? ii) Is there a significant difference between prognoses performed using different methods? iii) What is the most efficient model for the prognosis of the forest inventory for the eastern region of Minas Gerais? For the construction of the agrometeorological models, three methodologies were used: i) models constructed according to the order of the Pearson Correlation; ii) models constructed according to the ordering of the Garson Method; and iii) Hybrid Model. All the processes were performed in the software Neuro AgroClimate. There was a significant difference between the three models analyzed, and the network that presented the lowest RMSE of the test value (%) was model 12 of the Pearson Correlation methodology. The selection of the dependent variables was effective in optimizing the processing time of the networks when knowing the input variables.

KEYWORDS: Garson Method; Pearson Correlation; Neuro AgroClimate.

1 | INTRODUÇÃO

A eucaliptocultura no Brasil é uma das mais avançadas do mundo servindo de referência para outros países como a Austrália que é seu país de origem (Montagu *et al.*, 2003), devido às suas características como crescimento rápido e plasticidade em relação ao estresse hídrico (Brown, 2000).

O manejo florestal sustentável requer estimativas precisas de estoque de crescimento, uma vez que essas informações auxiliam confecção de planos de manejo (Binoti, *et al.*, 2014). Diversas ferramentas computacionais e de modelagem matemática têm sido utilizadas com êxito em situações de tomada de decisão no setor florestal, destacando-se as Redes Neurais Artificiais (RNA) (Leite *et al.*, 2016).

Uma das vantagens das RNAs sobre os métodos convencionais de modelagem é que elas não requerem informação detalhada sobre os processos físicos, químicos ou biológicos do sistema a ser modelado, mas apenas um banco de dados representativo do mesmo (Sudheer *et al.*, 2003).

Diante do exposto, o trabalho visa elucidar as seguintes questões: i) A redução do número de variáveis por meio de métodos de ordenação pode otimizar a construção de modelos de redes neurais para estimação da prognose? ii) Existe diferença significativa entre as prognoses realizadas por meio dos diferentes métodos analisados? iii) Qual o modelo mais eficiente para a realização da prognose do inventário florestal para a região do leste de Minas Gerais?

2 | MATERIAL E MÉTODOS

O estudo foi desenvolvido em áreas pertencentes a uma empresa florestal

situada na região leste do estado de Minas Gerais com altitude entre 527 e 852 metros. Foram analisados 156 talhões divididos em 1882 parcelas.

2.1 Dados do Inventário Florestal Contínuo (IFC)

Os dados utilizados são oriundos de parcelas permanentes de Inventários Florestais Contínuos (IFC) realizados anualmente. O banco de dados é composto por florestas equiâneas cujo plantio foram realizados entre os anos de 1989 e 2011 com áreas das parcelas entre 2,70 a 118,90 ha. As variáveis de inventário trabalhadas foram: área basal (m^2), altura dominante (m), volume atual (m^3/ha), volume futuro (m^3/ha), idade atual (meses) e idade futura (meses). Foram retirados do banco de dados as parcelas que no primeiro IFC apresentaram valores de idade inferior a 9 meses e superior a 15 meses.

2.2 Dados Meteorológicos

Os dados meteorológicos são constituídos por dados diários de 1980 a 2013 (Xavier *et al.*, 2016) e as variáveis utilizadas foram: temperaturas mínima, máxima e média ($^{\circ}C$), umidade relativa do ar (%), radiação solar (MJ/m^2), velocidade do vento (m/s), precipitação (mm) e temperatura do ponto de orvalho ($^{\circ}C$). Foram incluídas ao banco de dados meteorológico o cálculo da soma mensal do número de dias com precipitação acima de 1 e 5 mm, o déficit de pressão de vapor (DPV) (kPa) e o índice ecofisiológico dado pela razão $(DPV \cdot T)/R_g$.

2.3 Organização dos dados para o input do modelo

Para a espacialização dos dados meteorológicos, dividiu-se a regional em 10 subáreas por meio da sobreposição entre as coordenadas das parcelas do Inventário Florestal Contínuo (IFC) e as coordenadas da grade meteorológica.

Os dados meteorológicos foram inseridos ao banco de dados de acordo com os intervalos de mensuração dos IFC. Para o primeiro IFC, as variáveis meteorológicas foram organizadas entre a data de plantio e o primeiro IFC. Já para o segundo IFC, as variáveis foram organizadas entre a data de plantio e o segundo IFC. Os cálculos foram feitos sucessivamente até o último IFC trabalhado.

Para a estruturação do banco de dados, calculou-se a média das variáveis de temperatura ($^{\circ}C$), umidade relativa do ar (%), radiação solar (MJ/m^2), velocidade do vento (m/s), déficit de pressão de vapor (kPa), $(DPV \cdot T)/R_g$. Para as variáveis precipitação (mm) e dias com precipitação acima de 1 e 5 mm, calculou-se a soma.

2.4 Ordenação das variáveis do input

i) Correlação de Pearson: a correlação foi utilizada para ordenar as variáveis de entrada por meio do valor da correlação, do maior para o menor, entre a variável de saída “volume futuro m^3/ha ” e cada variável de entrada. Para a confecção dos modelos foi utilizada apenas a ordem das variáveis (os valores numéricos não foram

utilizados).

ii) Método de Garson: após o processo de treinamento da rede, foram salvos os valores dos pesos sinápticos entre a camada de entrada e a camada intermediária, entre a camada intermediária e a camada de saída, e realizado o método do cálculo da contribuição de cada atributo, conforme feito por Garson (1991) e o resultado desse cálculo é o valor da contribuição relativa de cada atributo.

Para ordenar as variáveis de entrada, foram processadas redes do tipo Multilayer Perceptron (MLP) – Aproximação de Funções, utilizando todas as variáveis dependentes como variáveis de entrada (21 variáveis) e a variável independente “volume futuro” como a variável de saída. O algoritmo de treinamento utilizado foi o Levenberg–Marquardt.

Na camada intermediária, a função de ativação utilizada foi a Tangente Hiperbólica e na camada de saída a função Identidade. As demais configurações utilizadas foram: erro quadrático médio 10^{-4} e verificação da validação (validation checks) igual ao número de iterações; número de repetições igual a 5; taxa de aprendizado igual a 0,5. Para a escolha do número de iterações, testou-se os valores 300, 500 e 1000. O banco de dados foi dividido em três seções: 70% dos dados para o treinamento, 15% para o teste e 15% para a validação.

Os padrões de dados foram extraídos aleatoriamente do arquivo padrão completo e incorporados em cada uma das três seções. Antes de serem apresentados à rede, todos os dados foram normalizados por variável.

De acordo com Silva *et al.*, (2010), no processo de determinação do número de neurônios, deve-se considerar que um número excessivo de neurônios pode acarretar a memorização dos dados de treinamento (overfitting) e por outro lado, um pequeno número de neurônios pode não ser suficiente para a realização da tarefa desejada, fenômeno conhecido como underfitting. O ideal é tentar trabalhar com um valor que fique entre o underfitting e o overfitting.

Utilizou-se os métodos de Kolmogorov e Fletcher-Gloss (Silva *et al.*, 2010) para a escolha do número de neurônios na camada intermediária. Selecionou-se 5 valores dentro da amplitude dos valores possíveis: i) para o número de variáveis de entrada cuja amplitude apresentava o número de neurônios inferior ou igual a 5, utilizou-se todos os valores da amplitude; ii) para o número de variáveis de entrada superior a 5, utilizou-se os valores das duas extremidades (dois valores), o valor médio entre os extremos (um valor), o valor médio entre o extremo inferior e o valor médio entre os extremos, e o valor entre o extremo superior e o valor médio entre os extremos.

O total de redes treinadas para cada modelo foi igual a 75 (5 configurações diferentes de neurônios x 3 iterações diferentes x 5 repetições). Foi escolhida a rede com o menor valor do erro quadrático médio do teste para utilizar a ordenação do Método de Garson.

O processamento foi realizado no software NeuroAgroClimate (BR512016000503-3), desenvolvido para esta tese por Magalhães, *et al.* (2016).

2.5 Construção e seleção dos modelos agrometeorológicos

A estrutura para modelagem dos dados foi organizada de acordo com Binoti *et al.*, (2015): informações dos inventários pareadas, ou seja, o 1º IFC com o 2º IFC, o 2º IFC com o 3º IFC e, assim, sucessivamente.

Os modelos gerados (RNA's) foram estruturados sendo o “volume futuro” da madeira como variável de saída (variável independente - output) e variando o número de variáveis dependentes utilizadas como input.

i) Modelos provenientes da ordenação da Correlação de Pearson: o primeiro modelo foi composto pela variável de saída “volume futuro” e a primeira variável dependente da ordenação da Correlação de Pearson; o segundo modelo foi composto pela variável de saída “volume futuro” e as duas primeiras variáveis dependentes da ordenação da Correlação de Pearson; e assim sucessivamente até o último modelo com 21 variáveis dependentes.

ii) Modelos provenientes da ordenação do Método de Garson: o primeiro modelo foi composto pela variável de saída “volume futuro” e a primeira variável dependente da ordenação do Método de Garson; o segundo modelo foi composto pela variável de saída “volume futuro” e as duas primeiras variáveis dependentes da ordenação do Método de Garson; e assim sucessivamente até o último modelo com 21 variáveis dependentes.

iii) Modelos provenientes do Método Híbrido: o Método Híbrido foi formado fundindo as variáveis dos modelos oriundos da Correlação de Pearson e Método de Garson. O primeiro modelo híbrido foi composto pela variável de saída “volume futuro” e a primeira variável dependente da ordenação da Correlação de Pearson e do Método de Garson, sem repetir as variáveis; o segundo modelo foi composto pela variável de saída “volume futuro” e as duas primeiras variáveis dependentes da ordenação da Correlação de Pearson e do Método de Garson; e assim sucessivamente sem repetição das variáveis, até o último modelo com 21 variáveis dependentes.

Os modelos foram gerados por meio de redes do tipo Multilayer Perceptron (MLP) – Aproximação de Funções, com as configurações: algoritmo de treinamento - Levenberg–Marquardt; função de ativação da camada intermediária - Tangente Hiperbólica; função de ativação da camada de saída - Identidade; erro quadrático médio 10^{-4} e verificação da validação (validation checks) igual ao número de iterações; número de repetições igual a 5; taxa de aprendizado igual a 0,5; número de iterações igual a 300, 500 e 1000. O banco de dados foi dividido em 70% para o treinamento, 15% para a validação e 15% para o teste. Os dados foram normalizados por variável. Utilizou-se os métodos de Kolmogorov e Fletcher-Gloss para a escolha do número de neurônios na camada intermediária.

Foram selecionadas 21 redes (uma por modelo) para as metodologias da Correlação de Pearson e Método de Garson, e 14 redes (uma por modelo) para metodologia do Método Híbrido. A seleção ocorreu por meio do menor valor da raiz

do erro quadrático médio (RMSE) do teste (Mehtätalo *et al.*, 2006).

Para cada metodologia (Correlação de Pearson, Método de Garson e Método Híbrido), o modelo com o menor valor de RMSE foi comparado estatisticamente com os demais por meio do procedimento estatístico proposto por Leite e Oliveira (2002). O modelo com menor número de variáveis dependentes considerado estatisticamente igual ao modelo com menor valor de RMSE selecionado anteriormente, foi considerado o melhor modelo. Posteriormente, os três melhores modelos (um por metodologia), foram comparados estatisticamente.

3 | RESULTADOS E DISCUSSÃO

3.1 Ordenação da importância relativa das variáveis do input

Para o resultado da ordenação pela Correlação de Pearson (Tabela 1), já era esperado que as variáveis de inventário florestal (área basal, altura dominante e idade) apresentassem maior correlação com a variável de saída “volume futuro”. No setor florestal, os dois modelos mais utilizados para o cálculo do volume de madeira são o Modelo de Clutter (Salles *et al.*, 2012) e Modelo de Schumacher e Hall (Silva *et al.*, 2009); ambos utilizam pelo menos duas das variáveis de inventário florestal citadas e estas são diretamente proporcionais à variável de saída.

Do ponto de vista ecofisiológico, o Método de Garson (Tabela 2) apresentou maior coerência na ordenação das variáveis do input (DPV, temperatura e umidade relativa do ar), uma vez que pode ser constatado que as variáveis que apresentaram maior peso estão relacionadas com o controle estomático e conseqüentemente determinam os ganhos/perdas da produção primária bruta da floresta.

A variável que mais se destacou na seleção pelo Método de Garson foi o DPV (Tabela 2). O aumento do DPV ocasiona o fechamento dos estômatos reduzindo a taxa fotossintética (Streck, 2003; Silva, 2007).

No Método de Garson (Tabela 1), era esperado que a variável radiação solar fosse mais representativa, uma vez que ela é uma das principais variáveis que afetam o crescimento das árvores (Souza *et al.*, 2006; Santana *et al.*, 2008). A breve redução na radiação solar incidente sobre uma árvore, provocada pela simples passagem de nuvem, pode acionar a resposta imediata dos estômatos (Rodrigues *et al.*, 2011), alterando a produtividade da planta que está relacionada principalmente à quantidade de energia interceptada e absorvida (Magalhães, 1985).

As variáveis fisiológicas na ordenação pela Correlação de Pearson (Tabela 1) não apresentaram boa colocação, DPV e (DPVxTmed)/Rg ficaram nas posições 14° e 15°, respectivamente. A umidade relativa do ar, variável que interfere diretamente na abertura dos estômatos, ficou na última colocação. A posição dessas variáveis demonstra que na metodologia da Correlação de Pearson não é dada a devida importância para as relações fisiológicas que possuem grande peso no entendimento

da dinâmica de ganho de volume de madeira.

Nas duas ordenações analisadas, a variável “número de dias com precipitação acima de 1 mm” foi mais representativa do que a variável “número de dias com precipitação acima de 5 mm” (tabelas 1 e 2). Esse fato pode estar ligado ao teor de argila encontrado no solo, uma vez que solos com maior teor de argila apresentam menor espaçamento entre suas partículas e conseguem deste modo reter uma quantidade maior de água. Desta forma, mesmo o menor volume precipitado pode fazer diferença para a vegetação local devido ao tempo maior de disponibilidade de água no solo para a absorção das raízes.

A variável altitude não foi representativa em nenhuma das metodologias utilizadas (tabelas 1 e 2). A baixa representatividade da variável em questão pode ser explicada por sua pequena amplitude entre as áreas estudadas, com a altitude entre 527 e 852 metros.

| Correlação de Pearson | |
|------------------------------|--|
| Variáveis dependentes | |
| 1 | Volume (m ³) |
| 2 | Área basal (m ²) |
| 3 | Altura dominante (m) |
| 4 | Idade futura (meses) |
| 5 | Idade (meses) |
| 6 | Dias com precipitação acima de 1 mm |
| 7 | Dias com precipitação acima de 5 mm |
| 8 | Precipitação (mm) |
| 9 | Amplitude térmica (°C) |
| 10 | Espaçamento |
| 11 | Velocidade do vento (m/s) |
| 12 | Temperatura mínima (°C) |
| 13 | Temperatura máxima (°C) |
| 14 | Défice de pressão de vapor - DPV (kPa) |
| 15 | (DPVxTmed)/Rg |
| 16 | Radição (MJ/m ²) |
| 17 | Área (m ²) |
| 18 | Temperatura média (°C) |
| 19 | Temperatura do ponto de orvalho (°C) |
| 20 | Altitude (m) |
| 21 | Umidade relativa do ar (%) |

Tabela 1: Ordenação das variáveis de entrada por meio da Correlação de Pearson.

| Método de Garson | |
|-----------------------|---|
| Variáveis dependentes | |
| 1 | Déficit de pressão de vapor - DPV (kPa) |
| 2 | (DPVxTmed)/Rg |
| 3 | Temperatura média (°C) |
| 4 | Temperatura máxima (°C) |
| 5 | Temperatura mínima (°C) |
| 6 | Umidade relativa do ar (%) |
| 7 | Temperatura do ponto de orvalho (°C) |
| 8 | Dias com precipitação acima de 1 mm |
| 9 | Dias com precipitação acima de 5 mm |
| 10 | Idade futura (meses) |
| 11 | Idade (meses) |
| 12 | Volume (m ³) |
| 13 | Precipitação (mm) |
| 14 | Área basal (m ²) |
| 15 | Velocidade do vento (m/s) |
| 16 | Altura dominante (m) |
| 17 | Radição (MJ/m ²) |
| 18 | Amplitude térmica (°C) |
| 19 | Espaçamento |
| 20 | Área (m ²) |
| 21 | Altitude (m) |

Tabela 2: Ordenação das variáveis de entrada por meio do Método de Garson.

3.2 Seleção dos modelos agrometeorológicos

Ao analisar as tabelas 3, 4 e 5, observa-se que para as três metodologias analisadas, os modelos com um número reduzido de variáveis apresentaram valores maiores de RMSE do teste (%) e que a medida em que as variáveis foram acrescentadas o erro foi reduzindo até um determinado modelo, e posteriormente ocorreu aumento discreto.

Dentre os modelos estruturados com base na metodologia da ordenação da Correlação de Pearson, verificou-se que o modelo 12 com a arquitetura MLP 12-25-1 apresentou o menor valor de RMSE do teste (%) que foi igual a 6,24 (tabela 3); para a metodologia do Método de Garson, o modelo com arquitetura MLP 16-9-1 (tabela 4) apresentou o menor valor de RMSE do teste (%) que foi igual a 6,52; já a metodologia do Modelo Híbrido apresentou o melhor resultado do valor de RMSE do teste (%) igual a 6,61, para o modelo 9 com arquitetura MLP 16-9-1. Segundo Binoti *et al.*, (2015), valores de RMSE concentrados em $\pm 7,5\%$ no treinamento e na validação, em nível de parcela, são considerados altamente satisfatórios.

Em relação à arquitetura, em 71,4 % dos modelos (tabela 3) construídos por meio da ordenação da Correlação de Pearson o número de neurônios na camada intermediária foi superior ao número de variáveis do input dos modelos analisados. Nos modelos da ordenação do Modelo Híbrido e Método de Garson

foram 50% e 47,6%, respectivamente. Ao analisar o número de iterações dos modelos de cada metodologia (tabelas 3 a 5), destacou-se o valor de 300 iterações com 42,8%, 42,8% e 57,1% do número total de modelos da Correlação de Pearson, Método de Garson e Modelo Híbrido.

| | Número de variáveis dependentes | Arquitetura | Critério de Parada | Número de iterações | Tempo de Treinamento (segundos) | RMSE do Treinamento (%) | RMSE do Teste (%) | RMSE do Validação (%) |
|-----------|---------------------------------|-------------|---------------------|---------------------|---------------------------------|-------------------------|-------------------|-----------------------|
| Modelo 1 | 1 | MLP 1-3-1 | Número de iterações | 1000 | 50,5 | 10,29 | 9,56 | 10,58 |
| Modelo 2 | 2 | MLP 2-5-1 | Número de iterações | 300 | 15,9 | 9,95 | 8,68 | 8,80 |
| Modelo 3 | 3 | MLP 3-5-1 | Número de iterações | 1000 | 52,9 | 9,16 | 8,03 | 9,72 |
| Modelo 4 | 4 | MLP 4-5-1 | Número de iterações | 1000 | 48,4 | 8,37 | 7,91 | 9,61 |
| Modelo 5 | 5 | MLP 5-7-1 | Número de iterações | 300 | 14,8 | 8,23 | 7,27 | 7,48 |
| Modelo 6 | 6 | MLP 6-12-1 | Número de iterações | 500 | 28,3 | 7,96 | 7,66 | 8,48 |
| Modelo 7 | 7 | MLP 7-11-1 | Número de iterações | 500 | 28,9 | 7,45 | 7,37 | 8,48 |
| Modelo 8 | 8 | MLP 8-12-1 | Número de iterações | 500 | 31,2 | 7,53 | 7,49 | 7,35 |
| Modelo 9 | 9 | MLP 9-13-1 | Número de iterações | 300 | 20,0 | 7,97 | 6,98 | 7,52 |
| Modelo 10 | 10 | MLP 10-17-1 | Número de iterações | 1000 | 77,6 | 7,08 | 7,11 | 8,17 |
| Modelo 11 | 11 | MLP 11-19-1 | Número de iterações | 500 | 41,9 | 7,61 | 7,30 | 7,55 |
| Modelo 12 | 12 | MLP 12-25-1 | Número de iterações | 500 | 53,8 | 7,07 | 6,24 | 7,69 |
| Modelo 13 | 13 | MLP 13-13-1 | Número de iterações | 300 | 22,0 | 7,11 | 6,87 | 7,34 |
| Modelo 14 | 14 | MLP 14-13-1 | Número de iterações | 300 | 22,9 | 7,36 | 7,08 | 7,47 |
| Modelo 15 | 15 | MLP 15-25-1 | Número de iterações | 500 | 62,3 | 6,88 | 6,82 | 8,49 |
| Modelo 16 | 16 | MLP 16-9-1 | Número de iterações | 300 | 20,2 | 6,83 | 6,78 | 9,12 |
| Modelo 17 | 17 | MLP 17-22-1 | Número de iterações | 300 | 40,5 | 7,26 | 7,53 | 7,22 |
| Modelo 18 | 18 | MLP 18-9-1 | Número de iterações | 300 | 21,1 | 6,48 | 9,92 | 7,68 |
| Modelo 19 | 19 | MLP 19-17-1 | Número de iterações | 500 | 50,6 | 8,09 | 7,60 | 8,62 |
| Modelo 20 | 20 | MLP 20-10-1 | Número de iterações | 1000 | 75,6 | 6,73 | 7,24 | 9,72 |
| Modelo 21 | 21 | MLP 21-18-1 | Número de iterações | 300 | 32,2 | 7,21 | 7,47 | 8,07 |

Tabela 3: Configurações e raiz do erro quadrático médio (RMSE) dos modelos gerados por meio da metodologia da Correlação de Pearson.

| | Número de variáveis dependentes | Arquitetura | Critério de Parada | Número de iterações | Tempo de Treinamento (segundos) | RMSE do Treinamento (%) | RMSE do Teste (%) | RMSE do Validação (%) |
|-----------|---------------------------------|-------------|---------------------|---------------------|---------------------------------|-------------------------|-------------------|-----------------------|
| Modelo 1 | 1 | MLP 1-3-1 | Número de iterações | 1000 | 52,8 | 40,61 | 37,49 | 39,99 |
| Modelo 2 | 2 | MLP 2-4-1 | Número de iterações | 300 | 16,2 | 40,07 | 34,33 | 37,31 |
| Modelo 3 | 3 | MLP 3-6-1 | Número de iterações | 300 | 16,6 | 34,28 | 31,28 | 32,63 |
| Modelo 4 | 4 | MLP 4-8-1 | Número de iterações | 500 | 24,9 | 30,56 | 30,52 | 32,48 |
| Modelo 5 | 5 | MLP 5-11-1 | Número de iterações | 500 | 29,3 | 30,77 | 28,31 | 32,27 |
| Modelo 6 | 6 | MLP 6-13-1 | Número de iterações | 1000 | 60,7 | 28,96 | 27,52 | 30,71 |
| Modelo 7 | 7 | MLP 7-10-1 | Número de iterações | 300 | 18,0 | 29,23 | 26,13 | 27,12 |
| Modelo 8 | 8 | MLP 8-17-1 | Número de iterações | 1000 | 67,5 | 20,13 | 20,19 | 21,17 |
| Modelo 9 | 9 | MLP 9-7-1 | Número de iterações | 300 | 17,4 | 21,98 | 20,20 | 20,69 |
| Modelo 10 | 10 | MLP 10-11-1 | Número de iterações | 500 | 31,9 | 20,83 | 19,03 | 21,13 |
| Modelo 11 | 11 | MLP 11-11-1 | Número de iterações | 500 | 32,6 | 20,76 | 19,09 | 23,21 |
| Modelo 12 | 12 | MLP 12-12-1 | Número de iterações | 500 | 33,8 | 7,34 | 7,20 | 8,27 |
| Modelo 13 | 13 | MLP 13-18-1 | Número de iterações | 300 | 24,7 | 7,26 | 6,71 | 7,48 |
| Modelo 14 | 14 | MLP 14-8-1 | Número de iterações | 1000 | 63,4 | 7,37 | 7,20 | 9,70 |
| Modelo 15 | 15 | MLP 15-15-1 | Número de iterações | 300 | 23,5 | 6,83 | 7,21 | 6,98 |
| Modelo 16 | 16 | MLP 16-9-1 | Número de iterações | 1000 | 63,6 | 7,35 | 6,42 | 8,96 |
| Modelo 17 | 17 | MLP 17-15-1 | Número de iterações | 300 | 24,5 | 7,00 | 6,82 | 8,39 |
| Modelo 18 | 18 | MLP 18-9-1 | Número de iterações | 500 | 34,2 | 7,41 | 7,05 | 7,23 |
| Modelo 19 | 19 | MLP 19-10-1 | Número de iterações | 500 | 35,9 | 6,92 | 6,81 | 7,56 |
| Modelo 20 | 20 | MLP 20-10-1 | Número de iterações | 300 | 22,4 | 7,41 | 6,74 | 7,01 |
| Modelo 21 | 21 | MLP 21-18-1 | Número de iterações | 300 | 32,2 | 7,21 | 7,47 | 8,07 |

Tabela 4: Configurações e raiz do erro quadrático médio (RMSE) dos modelos gerados por meio da metodologia do Método de Garson.

| | Número de variáveis dependentes | Arquitetura | Critério de Parada | Número de iterações | Tempo de Treinamento (segundos) | RMSE do Treinamento (%) | RMSE do Teste (%) | RMSE do Validação (%) |
|-----------|---------------------------------|-------------|---------------------|---------------------|---------------------------------|-------------------------|-------------------|-----------------------|
| Modelo 1 | 2 | MLP 2-5-1 | Número de iterações | 300 | 15,72 | 10,34 | 9,11 | 9,43 |
| Modelo 2 | 4 | MLP 4-8-1 | Número de iterações | 1000 | 63,434 | 9,39 | 8,62 | 9,17 |
| Modelo 3 | 6 | MLP 6-13-1 | Número de iterações | 300 | 19,259 | 8,48 | 7,88 | 8,48 |
| Modelo 4 | 8 | MLP 8-15-1 | Número de iterações | 1000 | 71,058 | 7,71 | 7,09 | 7,85 |
| Modelo 5 | 10 | MLP 10-11-1 | Número de iterações | 1000 | 66,509 | 7,28 | 7,08 | 8,02 |
| Modelo 6 | 12 | MLP 12-21-1 | Número de iterações | 300 | 24,593 | 6,87 | 6,95 | 7,37 |
| Modelo 7 | 14 | MLP 14-13-1 | Número de iterações | 300 | 22,705 | 6,90 | 7,15 | 8,24 |
| Modelo 8 | 15 | MLP 15-9-1 | Número de iterações | 1000 | 68,838 | 7,58 | 7,14 | 7,60 |
| Modelo 9 | 16 | MLP 16-9-1 | Número de iterações | 1000 | 67,289 | 7,17 | 6,61 | 9,13 |
| Modelo 10 | 17 | MLP 17-9-1 | Número de iterações | 300 | 19,827 | 7,46 | 7,34 | 7,81 |
| Modelo 11 | 18 | MLP 18-9-1 | Número de iterações | 500 | 35,569 | 7,29 | 6,89 | 7,12 |
| Modelo 12 | 19 | MLP 19-32-1 | Número de iterações | 300 | 49,143 | 6,24 | 6,73 | 8,61 |
| Modelo 13 | 20 | MLP 20-10-1 | Número de iterações | 300 | 22,159 | 7,41 | 6,74 | 7,01 |
| Modelo 14 | 21 | MLP 21-18-1 | Número de iterações | 300 | 32,192 | 7,21 | 7,47 | 8,07 |

Tabela 5: Configurações e raiz do erro quadrático médio (RMSE) dos modelos gerados por meio por meio da metodologia do Método Híbrido.

Ao analisar o resultado da análise estatística para cada metodologia, observa-se que os modelos diferem entre si (tabelas 6 a 8). Desta forma, os melhores modelos continuam sendo os 12, 16 e 9 para as metodologias da Correlação de Pearson, Método de Garson e Modelo Híbrido, respectivamente.

| Correlação de Pearson | Estatística | | | | |
|-----------------------|-------------|--------------------|---------------------------------|----------------|-----------|
| | F (Ho) | t (e) | $r_{y,\hat{y}} >= 1 - \alpha $ | Erro Médio (e) | Resultado |
| Rede - 1 variável | 87,08* | 1,27 ^{ns} | não | 0,01 | diferente |
| Rede - 2 variáveis | 54,93* | 0,97 ^{ns} | não | 0,00 | diferente |
| Rede - 3 variáveis | 47,33* | 0,57 ^{ns} | não | 0,00 | diferente |
| Rede - 4 variáveis | 38,69* | 3,25* | não | 0,01 | diferente |
| Rede - 5 variáveis | 35,01* | 0,00 ^{ns} | não | 0,00 | diferente |
| Rede - 6 variáveis | 19,29* | 1,12 ^{ns} | sim | -0,02 | diferente |
| Rede - 7 variáveis | 24,72* | 3,79* | sim | 0,01 | diferente |
| Rede - 8 variáveis | 21,37* | 1,87 ^{ns} | não | 0,00 | diferente |
| Rede - 9 variáveis | 12,10* | 1,95 ^{ns} | sim | 0,00 | diferente |
| Rede - 10 variáveis | 20,27* | 2,68* | não | 0,00 | diferente |
| Rede - 11 variáveis | 13,28* | 0,36 ^{ns} | não | 0,00 | diferente |
| Rede - 13 variáveis | 7,96* | 2,78* | sim | 0,01 | diferente |
| Rede - 14 variáveis | 11,85* | 0,11 ^{ns} | não | 0,00 | diferente |
| Rede - 15 variáveis | 20,62* | 0,70 ^{ns} | sim | -0,01 | diferente |
| Rede - 16 variáveis | 39,59* | 0,68 ^{ns} | não | 0,00 | diferente |
| Rede - 17 variáveis | 3,41* | 1,15 ^{ns} | não | 0,01 | diferente |
| Rede - 18 variáveis | 30,24* | 2,25* | sim | 0,01 | diferente |
| Rede - 19 variáveis | 84,48* | 2,24* | sim | 0,01 | diferente |
| Rede - 20 variáveis | 17,92* | 2,26* | sim | 0,01 | diferente |
| Rede - 21 variáveis | 29,63* | 5,18* | sim | 0,01 | diferente |

Tabela 6: Comparativo entre o volume futuro estimado do melhor modelo da Correlação de Pearson (modelo 12) com o volume futuro estimado dos 20 modelos restantes, utilizando o procedimento estatístico proposto por Leite e Oliveira (2002) a $\alpha=5\%$.

Os valores do RMSE do teste (%) entre as três metodologias analisadas foram muito próximos, sendo: 6,24 do modelo 12 da metodologia da Correlação de Pearson; 6,42 do modelo 16 da metodologia do Método de Garson; e 6,61 do modelo 9 da metodologia do Modelo Híbrido.

Os três modelos com os melhores desempenhos, o melhor de cada metodologia, apresentaram diferenças significativas entre eles, confirmada pelo procedimento estatístico proposto por Leite e Oliveira (2002), mesmo com valores de RMSE do teste (%) muito próximos (tabela 9). Desta forma, a rede que apresentou o menor valor do RMSE do teste (%) foi o modelo 12 da metodologia da Correlação de Pearson.

| Método de Garson | Estatística | | | | | Resultado |
|---------------------|--------------------|--------------------|------------------------------------|----------------|-----------|-----------|
| | F (Ho) | t (e) | $r_{y,\hat{y}} \geq 1 - \hat{e} $ | Erro Médio (e) | | |
| Rede - 1 variável | 25743,18* | 25,14* | não | 0,30 | diferente | |
| Rede - 2 variáveis | 13898,66* | 23,15* | não | 0,28 | diferente | |
| Rede - 3 variáveis | 3378,34* | 18,31* | não | 0,20 | diferente | |
| Rede - 4 variáveis | 2247,86* | 18,19* | não | 0,19 | diferente | |
| Rede - 5 variáveis | 2055,52* | 15,79* | não | 0,17 | diferente | |
| Rede - 6 variáveis | 1425,78* | 14,74* | não | 0,15 | diferente | |
| Rede - 7 variáveis | 1440,60* | 12,22* | não | 0,14 | diferente | |
| Rede - 8 variáveis | 465,61* | 4,71* | não | 0,05 | diferente | |
| Rede - 9 variáveis | 621,46* | 5,34* | não | 0,05 | diferente | |
| Rede - 10 variáveis | 506,54* | 4,86* | não | 0,05 | diferente | |
| Rede - 11 variáveis | 561,73* | 4,12* | não | 0,04 | diferente | |
| Rede - 12 variáveis | 10,27* | 0,66 ^{ns} | não | 0,00 | diferente | |
| Rede - 13 variáveis | 0,57 ^{ns} | 0,51 ^{ns} | não | 0,00 | diferente | |
| Rede - 14 variáveis | 18,96* | 0,81 ^{ns} | não | 0,00 | diferente | |
| Rede - 15 variáveis | 0,26 ^{ns} | 0,73 ^{ns} | não | 0,00 | diferente | |
| Rede - 17 variáveis | 2,64 ^{ns} | 4,22* | sim | 0,00 | diferente | |
| Rede - 18 variáveis | 6,68* | 3,40* | não | 0,00 | diferente | |
| Rede - 19 variáveis | 3,73* | 0,78 ^{ns} | não | 0,00 | diferente | |
| Rede - 20 variáveis | 0,72 ^{ns} | 3,61* | não | 0,00 | diferente | |
| Rede - 21 variáveis | 10,10* | 1,80 ^{ns} | não | 0,00 | diferente | |

Tabela 7: Comparativo entre o volume futuro estimado do melhor modelo do Método de Garson (modelo 16) com o volume futuro estimado dos 20 modelos restantes, utilizando o procedimento estatístico proposto por Leite e Oliveira (2002) a $\alpha=5\%$.

Ao analisar a ordenação das variáveis e o valor do RMSE do teste (%) das metodologias da Correlação de Pearson e Método de Garson, o modelo 16 do Método de Garson é o mais indicado quando o foco do estudo for o crescimento tendo como base as variáveis físicas e fisiológicas.

Do ponto de vista empresarial, o modelo 12 da metodologia da Correlação de Pearson atende melhor por apresentar o menor valor de RMSE do teste (%) dentre os modelos analisados e uma redução de 9 variáveis (42,8%) em relação ao número total de variáveis disponíveis.

| Método Híbrido | Estatística | | | | | Resultado |
|---------------------|--------------------|--------------------|------------------------------------|----------------|-----------|-----------|
| | F (Ho) | t (e) | $r_{y,\hat{y}} \geq 1 - \hat{e} $ | Erro Médio (e) | | |
| Rede - 1 variável | 38,97* | 0,41* | não | 0,00 | diferente | |
| Rede - 2 variáveis | 23,03* | 0,11* | não | 0,00 | diferente | |
| Rede - 3 variáveis | 18,45* | 0,92* | não | 0,00 | diferente | |
| Rede - 4 variáveis | 8,82* | 3,25* | não | 0,00 | diferente | |
| Rede - 5 variáveis | 2,57 ^{ns} | 1,64 ^{ns} | não | 0,00 | diferente | |
| Rede - 6 variáveis | 0,72 ^{ns} | 1,47 ^{ns} | não | 0,00 | diferente | |
| Rede - 7 variáveis | 5,48* | 0,18 ^{ns} | não | 0,00 | diferente | |
| Rede - 8 variáveis | 44,70* | 5,32* | sim | 0,00 | diferente | |
| Rede - 10 variáveis | 4,90* | 0,56 ^{ns} | não | 0,00 | diferente | |
| Rede - 11 variáveis | 6,26* | 5,93* | sim | 0,00 | diferente | |
| Rede - 12 variáveis | 0,93 ^{ns} | 1,20 ^{ns} | não | 0,00 | diferente | |
| Rede - 13 variáveis | 0,11 ^{ns} | 2,12* | não | 0,00 | diferente | |
| Rede - 14 variáveis | 16,08* | 3,63* | não | 0,00 | diferente | |

Tabela 8: Comparativo entre o volume futuro estimado do melhor modelo do Método Híbrido

(modelo 9) com o volume futuro estimado dos 13 modelos restantes, utilizando o procedimento estatístico proposto por Leite e Oliveira (2002) a $\alpha=5\%$.

| | Estatística | | | | Resultado |
|--|--------------------|--------------------|------------------------------|----------------|-----------|
| | F (Ho) | t (e) | $r_{x,y} \geq 1 - \bar{p} $ | Erro Médio (e) | |
| Correlação de Pearson X Método de Garson | 1,87* | 2,34* | não | 0,00 | diferente |
| Correlação de Pearson X Método Híbrido | 1,41 ^{ns} | 0,38 ^{ns} | não | 0,00 | diferente |
| Método Híbrido X Método de Garson | 3,69* | 0,78 ^{ns} | não | 0,00 | diferente |

Tabela 9: Comparativo entre os volumes estimados dos melhores modelos de cada metodologia utilizada, segundo o procedimento estatístico proposto por Leite e Oliveira (2002) a $\alpha=5\%$.

4 | CONSIDERAÇÕES FINAIS

A redução do número de variáveis otimizou 23,8% e 42,8% do total no número de variáveis utilizadas na construção de modelos por meio das metodologias do Método de Garson e Correlação de Pearson, respectivamente.

Os três modelos com os melhores desempenhos, o melhor de cada metodologia (Correlação de Pearson, Método de Garson e Modelo Híbrido), apresentaram diferenças significativas entre eles.

O modelo mais eficiente para a realização da prognose do inventário florestal para a região do leste do estado de Minas Gerais foi o modelo 12 da metodologia da Correlação de Pearson com uma redução de 9 variáveis (42,8%) em relação ao número total de variáveis disponíveis.

REFERÊNCIAS

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

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

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

BROWN, C. **The global outlook for future wood supply from forest plantation.** N° GFPOS/WP/03. Rome, FAO. Working Papers, 1-45, 2000.

GARSON, G.D. **Interpreting neural-network connection weights.** Artificial Intelligence Expert 6 (7), 47-51. 1991.

LEITE, H.G.; OLIVEIRA, F.H.T. **Statistical procedure to test the identity of analytical methods.** Communications in Soil Science and Plant Analysis, New York, v. 33, p. 1105-1118, 2002.

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

- MAGALHÃES, A.C.N. **Fotossíntese**. In. FERRI, M.G. Fisiologia vegetal. São Paulo: EDUSP, 350p. 1985.
- MAGALHÃES, M.R.; FREITAS, A.R.; RIBEIRO, A.; FELIX, L.B.; BRANDAO, A.S. **Neuro AgroClimate**. Programa de Computador. BR512016000503-3. INPI - Instituto Nacional da Propriedade Industrial. Depositante: Universidade Federal de Viçosa. 02 mai. 2016.
- MEHTÄTALO, L.; MALTAMO, M.; KANGAS, A. **The use of quantile trees in the prediction of the diameter distribution of a stand**. Silva Fennica, v.40, n.3, p.501-516, 2006.
- MONTAGU, K. D.; KEARNEY, D. E.; SMITH, R. G. B. **The biology and silviculture of pruning planted eucalypts for clear wood production: a review**. Forest Ecology and Management, v.179, n.1, p.1-13, 2003.
- RODRIGUES, H. J. B.; COSTA, R. F.; RIBEIRO, J. B. M.; SOUZA FILHO, J. D. C.; RUIVO, M. L. P.; SILVA JÚNIOR, J. A. **Variabilidade sazonal da condutância estomática em um ecossistema de manguezal amazônico e suas relações com variáveis meteorológicas**. Revista Brasileira de Meteorologia, v.26, n.2, 189 - 196, 2011.
- SANTANA, R. C.; BARROS, N. F.; LEITE, H. G.; COMERFORD, N. B.; NOVAIS, R. F. **Estimativa da biomassa em plantios de eucalipto no Brasil**. Revista Árvore, v.32, n.4, p.697-706, 2008.
- SILVA, I.N.; SPATTI, D.H.; FLAUZINO, R.A. **Redes neurais artificiais para engenharia e ciências aplicadas**. São Paulo: Artliber, 399p. 2010.
- SILVA, M.L.M.; BINOTI, D.H.B.; GLERIANI, J.M.; LEITE, H.G. **Ajuste do modelo de Schumacher e Hall e aplicação de redes neurais artificiais para estimar volume de árvores de eucalipto**. R. Árvore, Viçosa-MG, v.33, n.6, p.1133-1139, 2009.
- SILVA, W.C.M. **Modelagem dos balanços de radiação e de água e simulação do crescimento do eucalipto na Bacia do Rio Doce-MG**. Viçosa, MG: UFV. 122f. Tese (Doutorado em Meteorologia Agrícola) – Universidade Federal de Viçosa, Viçosa. 2007.
- SOUZA, M.J.H.; RIBEIRO, A.; LEITE, H.G.; LEITE, F.P.; MINUZZI, R.B. **Disponibilidade hídrica do solo e produtividade do eucalipto em três regiões da Bacia do Rio Doce**. Revista Árvore, v.30, p.399-410, 2006.
- STRECK, N.A. **Stomatal response to water vapor pressure deficit: an unsolved issue**. R. Bras. Agrobiologia, v. 9, n. 4, p. 317-322, 2003.
- SUDHEER, K. P.; GOSAIN, A. K.; RAMASASTRI, K. S. **Estimating actual evapotranspiration from limited climatic data using neural computing technique**. Journal of Irrigation and Drainage Engineering, v.129, n.3, p.214-218. 2003.
- XAVIER, A.C.; KINGB, A.W.; SCANLON, B.R. **Daily gridded meteorological variables in Brazil (1980–2013)**. International Journal of Climatology, 36: 2644–2659. DOI: 10.1002/joc. 2016.
- SALLES, T.T.; LEITE, H.G.; OLIVEIRA NETO, S.N.; SOARES, CARLOS P.B.; PAIVA, H.N.; SANTOS, F.L. **Modelo de Clutter na modelagem de crescimento e produção de eucalipto em sistemas de integração lavoura-pecuária-floresta**. Pesq. agropec. bras., Brasília, v.47, n.2, p.253-260, fev. 2012.

SOBRE A ORGANIZADORA

DIOCLÉA ALMEIDA SEABRA SILVA - Possui Graduação em Agronomia pela Faculdade de Ciências Agrárias do Pará, atualmente Universidade Federal Rural da Amazônia (1998), especialização em agricultura familiar e desenvolvimento sustentável pela Universidade Federal do Pará – UFPA (2001); mestrado em Solos e Nutrição de Plantas (2007) e doutorado em Ciências Agrárias pela Universidade Federal Rural da Amazônia (2014). Atualmente é professora da Universidade Federal Rural da Amazônia, no Campus de Capanema - PA. Tem experiência agricultura familiar e desenvolvimento sustentável, solos e nutrição de plantas, cultivos amazônicos e manejo e produção florestal, além de armazenamento de grãos. Atua na área de ensino de nos cursos de licenciatura em biologia, bacharelado em biologia e agronomia. Atualmente faz mestrado e especialização em educação, na área de tutoria à distância.

ÍNDICE REMISSIVO

A

Adaptabilidade 57, 150
Água de lavagem 298, 300
Ambiente rural 136, 138
Anaerobic digestion 174, 175, 176, 177, 181, 182, 183, 184
Anisotropia 256, 257, 259, 260
Autonomia 50
Azoxystrobina 149

B

Bactéria 25, 28, 79, 86, 87, 205
Benzimidazol 149, 156
Biogás 175
Bradyrhizobium japonicum 262, 263, 265

C

Carica papaya 57, 58
Cessão de uso 109, 110, 113, 115, 116, 117, 118
Composição mineral 14, 281
Compostos bioativos 123, 124
Compostos fenólicos 123, 124, 201
Comunidade pesqueira 44, 55, 56
Conhecimento ecológico local 44, 46
Controle alternativo 1, 2, 8, 11
Correlação de pearson 219, 221, 223, 224, 225, 226, 227, 228, 229, 230

E

Eficácia 15, 27, 149, 159, 160, 161, 162
Expressão transiente de genes 185, 193

F

Fertirrigação 298, 301, 304, 305, 306, 307, 309
Folhas 3, 5, 9, 74, 79, 80, 81, 83, 84, 85, 86, 88, 89, 90, 91, 123, 124, 134, 153, 154, 155, 185, 187, 190, 192, 193, 195, 201, 202, 203, 206, 207, 208, 212, 247, 262, 264, 265, 266, 268, 270, 271, 273, 274, 275, 276, 277, 278, 280, 281, 282, 283, 302
Fosfito de cu 153, 154

G

Gases de efeito estufa 298, 304, 306, 307, 309

Germinação 66, 71, 74, 75, 76, 77, 78, 232, 235, 236, 237, 238, 239, 243, 245, 246, 247, 248, 249, 250, 251, 252, 253, 254

Glicosídeos 123, 124

Glycine max 85, 150, 167, 262, 263, 278, 286

Grounded theory 107

H

Heterorhabditis 22, 23, 26, 30

Hormônios vegetais 166, 167, 170

Hortaliça não convencional 280, 281, 283

L

Licenciamento ambiental 109, 111, 113, 114, 116, 117, 118, 120, 121

M

Magnifection 185, 186, 214

Mancozeb 149, 150, 152, 154, 156, 157, 158, 162, 164

Maturidade fisiológica 246, 249

Meio ambiente 18, 46, 53, 82, 107, 111, 114, 115, 136, 137, 138, 140, 141, 145, 147, 298, 299, 300, 309

Método de garson 219, 222, 223, 224, 226, 227, 228, 229, 230

Microbioma 79, 81, 83, 85, 86, 89, 90, 91, 96

Mistura 16, 29, 68, 149, 158, 159, 168, 210, 265, 303

N

Nicotiana benthamiana 185, 186, 193, 204

Nitrogenase 262, 263, 267, 268, 275

Nova cultura de célula 124

O

Oro-pro-nobis 281

P

Peptídeos antimicrobianos 185, 186, 212

Percepção 48, 53, 56, 136, 138, 139, 142, 251

Pesquisa qualitativa 106, 108, 117, 136

Phaseolus vulgaris L 232, 233, 242, 243, 245, 246, 263, 278

Protioconazol 149, 153, 154, 156, 157, 158, 159, 160, 161

Q

Qualidade 10, 19, 20, 51, 57, 59, 91, 93, 104, 114, 115, 116, 117, 121, 137, 140, 142, 145, 146,

147, 151, 192, 204, 232, 233, 234, 235, 237, 238, 242, 243, 244, 245, 246, 247, 248, 249, 250,
251, 252, 253, 254, 255, 256, 259, 308

Qualidade da madeira 256, 259

R

Redutase do nitrato 262, 276

S

Saúde 10, 107, 115, 136, 137, 138, 139, 140, 141, 142, 144, 145, 146, 147, 186, 212, 281, 283

Sementes 3, 10, 71, 72, 73, 74, 75, 76, 77, 78, 88, 152, 173, 192, 197, 201, 203, 232, 233, 234,
235, 236, 237, 238, 239, 240, 241, 242, 243, 244, 245, 246, 247, 248, 249, 250, 251, 252, 253,
254, 255, 262, 264, 265, 266, 267, 268, 269, 270, 271, 272, 273, 274, 275, 276, 277, 278, 281

Simbiose 23

Sistemas integrados 286

Steinernema parasita 23

Stimulate® 166, 167, 168, 169, 170, 171, 172

U

Umidade da madeira 256

V

Variabilidade genética 18, 57

Vigor 63, 69, 77, 232, 233, 237, 238, 239, 240, 243, 245, 246, 247, 248, 249, 250, 251, 252,
253, 254, 255

Vinhaça 175, 298, 300, 301, 303, 304, 305, 306, 307, 308, 309

Z

Zona costeira amazônica 44

Agência Brasileira do ISBN
ISBN 978-85-7247-825-0



9 788572 478250