



Cleberton Correia Santos
(Organizador)

**Estudos Interdisciplinares
nas Ciências e da Terra
e Engenharias 4**

Cleberton Correia Santos
(Organizador)

Estudos Interdisciplinares nas Ciências
Exatas e da Terra e Engenharias 4

Atena Editora
2019

2019 by Atena Editora
Copyright © Atena Editora
Copyright do Texto © 2019 Os Autores
Copyright da Edição © 2019 Atena Editora
Editora Executiva: Prof^a Dr^a Antonella Carvalho de Oliveira
Diagramação: Natália Sandrini
Edição de Arte: Lorena Prestes
Revisão: Os Autores

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

Prof. Dr. Álvaro Augusto de Borba Barreto – Universidade Federal de Pelotas
Prof. Dr. Antonio Carlos Frasson – Universidade Tecnológica Federal do Paraná
Prof. Dr. Antonio Isidro-Filho – Universidade de Brasília
Prof. Dr. Constantino Ribeiro de Oliveira Junior – Universidade Estadual de Ponta Grossa
Prof^a Dr^a Cristina Gaio – Universidade de Lisboa
Prof. Dr. Deyvison de Lima Oliveira – Universidade Federal de Rondônia
Prof. Dr. Gilmei Fleck – Universidade Estadual do Oeste do Paraná
Prof^a Dr^a Ivone Goulart Lopes – Istituto Internazionele delle Figlie de Maria Ausiliatrice
Prof. Dr. Julio Candido de Meirelles Junior – Universidade Federal Fluminense
Prof^a Dr^a Lina Maria Gonçalves – Universidade Federal do Tocantins
Prof^a Dr^a Natiéli Piovesan – Instituto Federal do Rio Grande do Norte
Prof^a Dr^a Paola Andressa Scortegagna – Universidade Estadual de Ponta Grossa
Prof. Dr. Urandi João Rodrigues Junior – Universidade Federal do Oeste do Pará
Prof^a Dr^a Vanessa Bordin Viera – Universidade Federal de Campina Grande
Prof. Dr. Willian Douglas Guilherme – Universidade Federal do Tocantins

Ciências Agrárias e Multidisciplinar

Prof. Dr. Alan Mario Zuffo – Universidade Federal de Mato Grosso do Sul
Prof. Dr. Alexandre Igor Azevedo Pereira – Instituto Federal Goiano
Prof^a Dr^a Daiane Garabeli Trojan – Universidade Norte do Paraná
Prof. Dr. Darllan Collins da Cunha e Silva – Universidade Estadual Paulista
Prof. Dr. Fábio Steiner – Universidade Estadual de Mato Grosso do Sul
Prof^a Dr^a Girlene Santos de Souza – Universidade Federal do Recôncavo da Bahia
Prof. Dr. Jorge González Aguilera – Universidade Federal de Mato Grosso do Sul
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.^a Dr.^a 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 Natiéli Piovesan – Instituto Federal do Rio Grande do Norte
Profª Drª Raissa Rachel Salustriano da Silva Matos – Universidade Federal do Maranhão
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. Eloi Rufato Junior – Universidade Tecnológica Federal do Paraná
Prof. Dr. Fabrício Menezes Ramos – Instituto Federal do Pará
Profª Drª Natiéli Piovesan – Instituto Federal do Rio Grande do Norte
Prof. Dr. Takeshy Tachizawa – Faculdade de Campo Limpo Paulista

Conselho Técnico Científico

Prof. Msc. Abrãao Carvalho Nogueira – Universidade Federal do Espírito Santo
Prof. Dr. Adaylson Wagner Sousa de Vasconcelos – Ordem dos Advogados do Brasil/Seccional Paraíba
Prof. Msc. André Flávio Gonçalves Silva – Universidade Federal do Maranhão
Prof.ª Drª Andreza Lopes – Instituto de Pesquisa e Desenvolvimento Acadêmico
Prof. Msc. Carlos Antônio dos Santos – Universidade Federal Rural do Rio de Janeiro
Prof. Msc. Daniel da Silva Miranda – Universidade Federal do Pará
Prof. Msc. Eliel Constantino da Silva – Universidade Estadual Paulista
Prof.ª Msc. Jaqueline Oliveira Rezende – Universidade Federal de Uberlândia
Prof. Msc. Leonardo Tullio – Universidade Estadual de Ponta Grossa
Prof.ª Msc. Renata Luciane Polsaque Young Blood – UniSecal
Prof. Dr. Welleson Feitosa Gazel – Universidade Paulista

Dados Internacionais de Catalogação na Publicação (CIP) (eDOC BRASIL, Belo Horizonte/MG)	
E82	<p>Estudos interdisciplinares nas ciências exatas e da terra e engenharias 4 [recurso eletrônico / Organizador Cleberton Correia Santos. – Ponta Grossa, PR: Atena Editora, 2019. – (Estudos Interdisciplinares nas Ciências Exatas e da Terra e Engenharias; v. 4)</p> <p>Formato: PDF Requisitos de sistema: Adobe Acrobat Reader Modo de acesso: World Wide Web Inclui bibliografia ISBN 978-85-7247-622-5 DOI 10.22533/at.ed.225191109</p> <p>1. Ciências exatas e da Terra. 2. Engenharias. 3. Tecnologia. I.Santos, Cleberton Correia. II. Série.</p> <p style="text-align: right;">CDD 016.5</p>
Elaborado por Maurício Amormino Júnior – CRB6/2422	

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

APRESENTAÇÃO

O livro “Estudos Interdisciplinares nas Ciências Exatas e da Terra e Engenharias” de publicação da Atena Editora apresenta em seu 4º volume 37 capítulos com temáticas voltadas à Educação, Agronomia, Arquitetura, Matemática, Geografia, Ciências, Física, Química, Sistemas de Informação e Engenharias.

No âmbito geral, diversas áreas de atuação no mercado necessitam ser elucidadas e articuladas de modo a ampliar sua aplicabilidade aos setores econômicos e sociais por meio de inovações tecnológicas. Neste volume encontram-se estudos com temáticas variadas, dentre elas: estratégias regionais de inovação, aprendizagem significativa, caracterização fitoquímica de plantas medicinais, gestão de riscos, acessibilidade, análises sensoriais e termodinâmicas, redes neurais e computacionais, entre outras, visando agregar informações e conhecimentos para a sociedade.

Os agradecimentos do Organizador e da Atena Editora aos estimados autores que empenharam-se em desenvolver os trabalhos de qualidade e consistência, visando potencializar o progresso da ciência, tecnologia e informação a fim de estabelecer estratégias e técnicas para as dificuldades dos diversos cenários mundiais.

Espera-se com esse livro incentivar alunos de redes do ensino básico, graduação e pós-graduação, bem como outros pesquisadores de instituições de ensino, pesquisa e extensão ao desenvolvimento estudos de casos e inovações científicas, contribuindo na aprendizagem significativa e desenvolvimento socioeconômico rumo à sustentabilidade e avanços tecnológicos.

Cleberton Correia Santos

SUMÁRIO

CAPÍTULO 1	1
GEOPROCESSAMENTO APLICADO AO MAPEAMENTO DAS ÁREAS DE RISCOS DE INUNDAÇÃO PARA O MUNICÍPIO DE PONTE NOVA – MG	
Anderson Nascimento Milagres Gian Fonseca dos Santos Danilo Segall César Yann Freire Marques Costa Klinger Senra Rezende Alixandre Sanquetta Laporti Luppi Adonai Gomes Fineza	
DOI 10.22533/at.ed.2251911091	
CAPÍTULO 2	8
MUTAGÊNESE DA LEVEDURA <i>Candida viswanathii</i> PARA A PRODUÇÃO DE ENZIMAS LIPOLÍTICAS	
Luiz Renato Lima Silva Miranda Nayra Morgana Lima De Oliveira Erika Carolina Vieira Almeida Adriana Augusta Neto Alex Fernando De Almeida	
DOI 10.22533/at.ed.2251911092	
CAPÍTULO 3	19
A RELAÇÃO ENTRE PROGRAMAS DE DESENVOLVIMENTO DE LIDERANÇA E O CAPITAL SOCIAL NAS ORGANIZAÇÕES	
Bruno Henriques Watté Márcio Vieira de Souza	
DOI 10.22533/at.ed.2251911093	
CAPÍTULO 4	34
BRUNIMENTO FLEXÍVEL DE CILINDROS DE BLOCOS DE COMPRESSORES HERMÉTICOS: AVALIAÇÃO DO EFEITO DA GRANULOMETRIA E DO NÚMERO DE GOLPES DA FERRAMENTA NO PARÂMETRO DE RUGOSIDADE R_p	
Guilherme Henrique Caetano Barros Rosenda Valdés Arencibia Luciano José Arantes	
DOI 10.22533/at.ed.2251911094	
CAPÍTULO 5	41
ANÁLISE DA ACELERAÇÃO POR EXTRAPOLAÇÃO DA FONTE DE FISSÃO CONSIDERANDO A TEORIA DE DIFUSÃO DE NEUTRONS EM REATORES NUCLEARES	
Andrey Silva Pontes Henrique Matheus Ferreira da Silva Lenilson Moreira Araújo	
DOI 10.22533/at.ed.2251911095	

CAPÍTULO 6	51
ANÁLISE DE DESEMPENHO E AVALIAÇÃO DOS PROTOCOLOS DE REDES DE SENSORES SEM FIO EM <i>SMART GRIDS</i>	
Álison De Oliveira Alves Felipe Denis Mendonça De Oliveira	
DOI 10.22533/at.ed.2251911096	
CAPÍTULO 7	64
SÍNTESE DE COMPOSTOS HÍBRIDOS PERILIL-DIHDROPIRIMIDINONAS ATRAVÉS DA REAÇÃO DE HUISGEN COM FORMAÇÃO DE ANÉIS 1,2,3-TRIAZÓLICOS	
Vinícius Vendrusculo Dennis Russowsky	
DOI 10.22533/at.ed.2251911097	
CAPÍTULO 8	74
ANÁLISES DOS PARÂMETROS FÍSICO-QUÍMICAS DA CASTANHOLA	
Jonas Soares de Mesquita Davi Pereira Araújo Maria Carolina Martins da Silva	
DOI 10.22533/at.ed.2251911098	
CAPÍTULO 9	81
USO DE CATALISADORES DE NÍQUEL PARA A RESOLUÇÃO CINÉTICA DINÂMICA DE AMINAS PRIMÁRIAS	
Fernanda Amaral de Siqueira Natália Cavallaro Martins de Sousa Sania Maria de Lima	
DOI 10.22533/at.ed.2251911099	
CAPÍTULO 10	92
AVALIANDO EM MATEMÁTICA: UM ESTUDO DE CASO NO CENTRO-OESTE MINEIRO	
Patrícia Milagre de Freitas Leandro Teles Antunes dos Santos	
DOI 10.22533/at.ed.22519110910	
CAPÍTULO 11	102
AVALIAÇÃO DA QUALIDADE DE VIDA NO TRABALHO EM TRABALHADORES DA CONSTRUÇÃO CIVIL	
Andre Luis Martins De Souza Renata Evangelista Alexandre Bueno Ronaldo Marques Serigne Ababacar Felipe Rogério Hudson Luis	
DOI 10.22533/at.ed.22519110911	

CAPÍTULO 12 111

AVALIAÇÃO DO COMPORTAMENTO DE UM SOLO RESIDUAL DE GNAISSE MADURO ESTABILIZADO COM LAMA DE CAL

Danilo Segall César
Yann Freire Marques Costa
Anderson Nascimento Milagres
Gian Fonseca dos Santos
Eduardo Souza Candido
Klinger Senra Rezende
Adonai Gomes Fineza

DOI 10.22533/at.ed.22519110912

CAPÍTULO 13 122

AVALIAÇÃO TOXICOLÓGICA DE RESÍDUOS ELETRÔNICOS: ESTUDO DE CASO COM PILHAS ALCALINAS

Pedro Luiz Dias Barroso
Julia Santos Caetano
Jean Pierre Sayago
Joeci Ricardo Godoi
Rodrigo Souza Banegas
Letícia Flohr

DOI 10.22533/at.ed.22519110913

CAPÍTULO 14 132

CARACTERIZAÇÃO E APLICAÇÃO DE FILMES DE PAADDA/PSS E PDDA/PSS PREPARADOS POR LAYER-BY-LAYER

Samanta Costa Machado Silva
Jorge Amim Júnior
Ana Lucia Shiguihara

DOI 10.22533/at.ed.22519110914

CAPÍTULO 15 144

COMPOSIÇÃO QUÍMICA, FENÓIS TOTAIS E ATIVIDADE ANTIOXIDANTE DAS FOLHAS DE *Simaba ferruginea*

Jessica Sara de Sousa Macêdo Oliveira
Lucivania Rodrigues dos Santos
Adonias Almeida Carvalho
Renato Pinto de Sousa
Gerardo Magela Vieira Júnior
Ruth Raquel Soares de Farias
Mariana Helena Chaves

DOI 10.22533/at.ed.22519110915

CAPÍTULO 16 157

DESENVOLVIMENTO DE MATERIAIS ALCALINAMENTE ATIVADOS PARA MITIGAÇÃO DA REAÇÃO ÁLCALI-AGREGADO: AVALIAÇÃO DAS PROPRIEDADES MECÂNICAS, FÍSICAS E QUÍMICAS

Jocélio Jairo Vieira Filho
Kelly Cristiane Gomes
Williamns Tadeu de Oliveira Lins Belo

DOI 10.22533/at.ed.22519110916

CAPÍTULO 17	183
ESTRUTURA AXIOMÁTICA DO ORIGAMI: UMA ABORDAGEM DOS POLIEDROS REGULARES NA FORMAÇÃO DE PROFESSORES DE MATEMÁTICA	
Anita Lima Pimenta Eliane Scheid Gazire	
DOI 10.22533/at.ed.22519110917	
CAPÍTULO 18	193
ESTUDO DO EFEITO DOS PARÂMETROS DE PROJETO DE BICOS EXTRUSORES EM BIOIMPRESSÃO UTILIZANDO FLUIDODINÂMICA COMPUTACIONAL	
Patrícia Muniz de Oliveira Isabela Poley Estevam Barbosa Las Casas Marina Spyer Las Casas Janaina Dernowsek	
DOI 10.22533/at.ed.22519110918	
CAPÍTULO 19	205
IMPACTO DA RESOLUÇÃO HORIZONTAL NA SIMULAÇÃO DOS JATOS DE BAIXOS NÍVEIS NA AMÉRICA DO SUL USANDO O MODELO GLOBAL DO CPTEC	
Dayana Castilho de Souza Paulo Yoshio Kubota Silvio Nilo Figueroa Enver Manuel Amador Ramirez Gutierrez Caio Augusto dos Santos Coelho	
DOI 10.22533/at.ed.22519110919	
CAPÍTULO 20	218
<i>LESSON STUDY</i> : UMA ADAPTAÇÃO PARA O BRASIL	
Renata Camacho Bezerra Maria Raquel Miotto Morelatti	
DOI 10.22533/at.ed.22519110920	
CAPÍTULO 21	226
MICROSCOPIA DE DESFOCALIZAÇÃO COMO UMA FERRAMENTA DE ESTUDO DE PROPRIEDADES MORFOLÓGICAS E MECÂNICAS DE ERITRÓCITOS	
Paula M. S. Roma Luiza C. Mourão Marcelo P. Bemquerer Erika M. Braga Ubirajara Agero	
DOI 10.22533/at.ed.22519110921	
CAPÍTULO 22	232
PENSAMENTO ALGÉBRICO E SUA APLICAÇÃO EM EQUAÇÕES LINEARES	
Fábio Mendes Ramos Fabricia Gracielle Santos Daniel Martins Nunes	
DOI 10.22533/at.ed.22519110922	

CAPÍTULO 23	243
ENSINO DE QUÍMICA VERSUS TICs: RETRATO DE PUBLICAÇÕES BRASILEIRAS	
Eleonora Celli Carioca Arenare	
DOI 10.22533/at.ed.22519110923	
CAPÍTULO 24	253
PREPARAÇÃO E AVALIAÇÃO DE PROPRIEDADES FÍSICO-QUÍMICAS DE BLENDS DE PHB/PC	
Francielle Schmitz	
Carolina de Andrade	
Ivonete Oliveira Barcellos	
DOI 10.22533/at.ed.22519110924	
CAPÍTULO 25	267
RESINAS DE POLIÉSTER INSATURADO E SUA APLICAÇÃO NA CONSTRUÇÃO DE EMBARCAÇÕES EM FIBERGLASS	
Patricia Reis Pinto	
Sérgio da Silva Feitosa	
Alaíde de Sá Barreto	
DOI 10.22533/at.ed.22519110925	
CAPÍTULO 26	277
APLICAÇÃO DO MÉTODO DA PENALIZAÇÃO ROBUSTA PARA ANÁLISE DE PROBLEMAS DE OTIMIZAÇÃO MULTI-OBJETIVO	
Gustavo Barbosa Libotte	
Fran Sérgio Lobato	
Francisco Duarte Moura Neto	
Gustavo Mendes Platt	
DOI 10.22533/at.ed.22519110926	
CAPÍTULO 27	289
SÍNTESE DE FASE SÓLIDA HÍBRIDA MOLECULARMENTE IMPRESSA PARA EXTRAÇÃO DE CAFEÍNA EM AMOSTRAS ÁGUA SUPERFICIAL	
Fabiana Casarin	
Camila Santos Dourado	
Ana Cristi Basile Dias	
DOI 10.22533/at.ed.22519110927	
CAPÍTULO 28	302
SOLUÇÃO ANALÍTICA DE PROBLEMA BIDIMENSIONAL DE CONDUÇÃO DE CALOR UTILIZANDO FUNÇÕES DE GREEN	
José Aguiar dos Santos Junior	
José Ricardo Ferreira Oliveira	
Eduardo Peixoto de Oliveira	
Guilherme Ramalho Costa	
Jefferson Gomes Do Nascimento	
Alisson Augusto Azevedo Figueiredo	
Gilmar Guimarães	
DOI 10.22533/at.ed.22519110928	

CAPÍTULO 29 310

TAXAS DE FREQUÊNCIA E GRAVIDADE DOS ACIDENTES OCORRIDOS EM UM GRUPO DE PROPRIEDADES CAFEEIRAS CERTIFICADAS

Rafael Augusto Silva Souza
Geraldo Gomes de Oliveira Júnior
Armando Mendes Nogueira
Raphael Nogueira Rezende
Agda Silva Prado Oliveira
Adriano Bortolotti da Silva
Patrícia Ribeiro do Valle Coutinho

DOI 10.22533/at.ed.22519110929

CAPÍTULO 30 315

UM SISTEMA COLABORATIVO DE INCENTIVO A DOAÇÃO DE SANGUE

Alúcio José Pereira
Fábio Abrantes Diniz
Elder Gonçalves Pereira
Francisco Paulo de Freitas Neto
Elissandra Cheu Pereira do Nascimento

DOI 10.22533/at.ed.22519110930

CAPÍTULO 31 329

UMA PROPOSTA DIDÁTICA PARA O ENSINO DE NÚMEROS DECIMAIS NO 5º ANO DO ENSINO FUNDAMENTAL

Cristiana Monique Feltes Sivert
Cassiano Scott Puhl

DOI 10.22533/at.ed.22519110931

CAPÍTULO 32 339

ESTUDO DA VIABILIDADE NO DESENVOLVIMENTO DE UM SISTEMA COMPUTACIONAL DE BAIXO CUSTO PARA MONITORAMENTO DA QUALIDADE DA ÁGUA EM CULTIVOS DE ORGANISMOS AQUÁTICOS: APLICAÇÃO INICIAL EM VIVEIROS ESCAVADOS

Wilmar Borges Leal Junior
Fabiano Medeiros Tavares
Ítalo Cordeiro Silva Lima
Delfim Dias Bonfim
Lucyano Campos Martins
Nailson Martins Dantas Landim
Haryson Huan Arruda da Silva Santos
Douglas Ferreira Chaves

DOI 10.22533/at.ed.22519110932

CAPÍTULO 33 349

REGRESSÃO POLINOMIAL E REDES NEURAS ARTIFICIAIS NA AVALIAÇÃO DE IMÓVEIS

Carlos Augusto Zilli
Luiz Fernando Palin Droubi
Norberto Hochheim

DOI 10.22533/at.ed.22519110933

CAPÍTULO 34 363

ANALISE DE RECALQUES NO CONTORNO RODOVIÁRIO DA GRANDE FLORIANÓPOLIS

Wagner de Sousa Santos
Amanda Morlos

DOI 10.22533/at.ed.22519110934

CAPÍTULO 35	376
SIMULAÇÃO DA ESTABILIDADE DE UM TÚNEL EM MACIÇO ROCHOSO	
Yann Freire Marques Costa	
Danilo Segall César	
Gian Fonseca dos Santos	
Anderson Nascimento Milagres	
Klinger Senra Rezende	
Adonai Gomes Fineza	
DOI 10.22533/at.ed.22519110935	
SOBRE O ORGANIZADOR.....	387
ÍNDICE REMISSIVO	388

REGRESSÃO POLINOMIAL E REDES NEURAIS ARTIFICIAIS NA AVALIAÇÃO DE IMÓVEIS

Carlos Augusto Zilli

Universidade Federal de Santa Catarina
Tubarão - Santa Catarina

Luiz Fernando Palin Droubi

Universidade Federal de Santa Catarina
Florianópolis - Santa Catarina

Norberto Hochheim

Universidade Federal de Santa Catarina
Florianópolis - Santa Catarina

RESUMO: A NBR 14.653-2 prevê o uso de diferentes metodologias para avaliação de um imóvel. Dentre elas, destaca-se o uso de regressão linear e, alternativamente, o uso de redes neurais artificiais. A regressão linear é um método científico bastante difundido entre os engenheiros avaliadores, enquanto a utilização de redes neurais apresenta aplicação limitada, pois, apesar do seu desempenho extraordinário, ainda não está completamente explícito o que ocorre durante a aprendizagem de uma rede neural e porque elas funcionam. Uma alternativa aos modelos de redes neurais artificiais é a modelagem através de regressão polinomial, que nada mais é que um modelo de regressão linear em que são adicionados os termos quadráticos, cúbicos etc, assim como os termos de todas as possíveis interações entre as variáveis. Nesse estudo procura-se fazer

um comparativo acerca da precisão obtida por modelos de regressão polinomial e por redes neurais artificiais em dados imobiliários. Essa precisão é aferida através do cálculo da raiz do erro médio quadrático - RMSE para as duas modelagens. Os resultados obtidos convergem para aqueles obtidos por Matloff *et al.* (2018) em seu artigo “*polynomial regression as an alternative to neural nets*”, que pondera que as redes neurais artificiais, quando utilizadas funções de ativação lineares, são modelos de regressão polinomial em que o grau do polinômio aumenta a medida que aumenta o número de camadas ocultas da rede neural. Constatou-se, ainda, que o RMSE da regressão polinomial foi menor e com menor dispersão que o da respectiva rede neural artificial.

PALAVRAS-CHAVE: Regressão Polinomial, Redes Neurais, Imóveis.

POLYNOMIAL REGRESSION AND ARTIFICIAL NEURAL NETWORKS IN EVALUATION REAL ESTATE

ABSTRACT: NBR 14.653-2 provides the use of different approaches to evaluate a property. Among them, the use of linear regression appears as an important one and, alternatively, the use of artificial neural networks. Linear regression is a widely used scientific approach

among evaluation engineers, while the use of neural networks has limited application, because despite its extraordinary performance, it is not fully understood what happens during the learning of a neural network yet, and why they work. An alternative to artificial neural network models is polynomial regression modeling, which is nothing more than a linear regression model in which quadratic, cubic, and other terms are added, as well as the terms of all possible interactions between the variables. In this study we try to compare the precision obtained by polynomial regression models and by artificial neural networks in real estate data. This precision is measured by calculating the *root-mean-square error* - RMSE for the two models. The results obtained converge to those obtained by Matloff et al. (2018) in his article “polynomial regression as an alternative to neural nets”, which argues that artificial neural networks, when using linear activation functions, are nothing more than polynomial regression models in which the degree of the polynomial increases the measure which increases the number of hidden layers of the neural network. It was also observed that the RMSE of the polynomial regression was smaller and with less dispersion than the respective artificial neural network.

KEYWORDS: Polynomial Regression, Neural Networks, Real Estate.

1 | INTRODUÇÃO

Entre os métodos utilizados para a avaliação de imóveis previstos na NBR 14.653-2 (2011), o mais comum é o método comparativo direto de dados de mercado, utilizando técnicas de regressão que, além de apresentar uma ótima estimativa dos valores econômicos dos bens envolvidos, oferecem também qualidade e transparência ao processo avaliativo do bem.

A metodologia científica, aplicando os conhecimentos de regressão polinomial, é bastante difundida e adotada por grande parte dos engenheiros avaliadores de imóveis, contudo, métodos alternativos podem ser adotados, desde que devidamente justificados do ponto de vista teórico e prático.

Entre esses métodos alternativos está o uso de redes neurais artificiais. Pelli Neto (2006) afirma que as redes neurais artificiais têm sido aplicadas na área de engenharia de avaliações, sendo aceita como metodologia científica pela ABNT. Essa metodologia é prevista pela NBR 14.653-2, que trata da avaliação de imóveis urbanos em seu anexo E.

Contudo, mesmo com a adoção de poderosas ferramentas matemáticas e de inteligência artificial, sabe-se que há ainda muitas dúvidas acerca dos procedimentos de aprendizagem de uma rede neural artificial, bem como inúmeras imprecisões inerentes ao próprio ato de avaliar.

Matloff *et al.* (2018), em seu artigo “polynomial regression as an alternative to neural nets”, afirma que redes neurais são regressões polinomiais e que, para cada camada oculta de uma rede neural, há um modelo de regressão polinomial equivalente, fazendo com que o grau dessa regressão polinomial aumente à medida que aumenta o número de camadas ocultas da rede. Frente a isso, o presente artigo

demonstra que resultados obtidos por regressão polinomial apresentaram precisão igual ou superior àqueles obtidos por redes neurais.

Ademais, busca-se nesse estudo comparar os resultados que se obtêm ao se tratar 50 dados de oferta de imóveis utilizando modelos de regressão polinomial e redes neurais artificiais, com o objetivo de verificar se os resultados convergem para aqueles encontrados por Matloff *et al.* (2018).

2 | REGRESSÃO POLINOMIAL

Em termos formais, a regressão diz respeito ao estudo da dependência de uma variável, a variável dependente, em relação a uma ou mais variáveis, as variáveis explanatórias, visando estimar e/ou prever o valor médio da primeira em termos dos valores conhecidos ou fiados (em amostragens repetidas) das segundas (GUJARATI e PORTER, 2011).

Os modelos de regressão são amplamente usados em diversas aplicações para descrever a relação entre a variável resposta y e uma ou mais variáveis explicativas x_1, x_2, \dots, x_m . É importante salientar, ainda, que o modelo de regressão é linear se a quantidade de interesse é função linear dos parâmetros envolvidos.

2.1 Modelos de regressão linear

O exemplo mais simples de regressão polinomial consiste em ajustar uma reta a um conjunto de pares de observação em que y é a variável dependente, x_i é a variável explanatória ou regressora, e o termo de erro e_i , o indicador da i -ésima observação. A expressão matemática da reta é

$$y_i = f(x_i) = \beta_0 + \beta_1 x_{1i} + e_i \quad (2.1)$$

Em que β_0 é o coeficiente que representa o intercepto com o eixo dos y , e β_1 representa inclinação que a reta forma com o eixo das abscissas. O e é o erro ou resíduo entre o valor ajustado pelo modelo e a observação.

Dizemos que o erro ou resíduo é a discrepância entre o valor verdadeiro e o valor aproximado de y , que pode ser expresso por:

$$e_i = y_i - (\beta_0 + \beta_1 x_{1i}) \quad (2.2)$$

Nesse caso, o melhor ajuste será aquele que busca minimizar a soma dos quadrados dos resíduos entre o y medido e o y calculado com o modelo linear para

todos os dados disponíveis na amostra, definida pela equação

$$S_r = \sum_{i=1}^n e_i^2 = \sum_{i=1}^n (y_i - \beta_0 - \beta_1 x_{1i})^2 \quad (2.3)$$

Na engenharia de avaliações, o mais comum é a utilização de modelos de regressão linear múltipla. Nesse sentido, uma extensão bastante usada de regressão polinomial linear é o caso no qual y é uma função linear de duas ou mais variáveis independentes x_1, x_2, \dots, x_m . Nesse caso teremos:

$$y_i = f(x_1, x_2, \dots, x_m) = \beta_0 + \beta_1 x_{1i} + \beta_2 x_{2i} + \dots + \beta_m x_{mi} + e_i \quad (2.4)$$

Esse modelo é particularmente útil quando desejamos fazer o ajuste de dados experimentais em que a variável explicada é uma função de duas ou mais variáveis explicativas. Nesse caso, a reta de regressão torna-se um plano ou hiperplano, dependendo da quantidade de variáveis explicativas.

Os modelos (2.1) e (2.4) são obtidos pelo critério de mínimos quadrados em que se realiza a regressão linear simples e regressão linear múltipla para se ajustar uma reta ou um plano de m dimensões aos n dados.

2.2 Modelos regressão polinomial

Em problemas de engenharia de avaliações, embora algumas variáveis apresentem padrão semelhante ao de uma reta, existem outras que não seguem esse modelo. Nesses casos uma curva poderia ser adequada e, comumente, realiza-se a transformação dessa variável.

Entretanto, uma alternativa possível é ajustar polinômios aos dados da amostra utilizando regressão polinomial. A técnica dos mínimos quadrados pode ser prontamente estendida para se ajustar dados por um polinômio de grau maior. O modelo polinomial, com uma variável x_1 , é dado

$$y_i = f(x_1) = \beta_0 + \beta_1 x_{1i} + \beta_2 x_{1i}^2 + \dots + \beta_m x_{1i}^m + e_i \quad (2.5)$$

Verifica-se que a equação (2.5) é polinomial $\forall m \geq 2$ com $m \in \mathbb{N}$ ou com $\beta_2 \neq 0$. Para esse modelo, o resíduo é dado pela reorganização de (2.5)

$$e_i = y_i - (\beta_0 + \beta_1 x_{1i} + \beta_2 x_{1i}^2 + \dots + \beta_m x_{1i}^m) \quad (2.6)$$

Assim como no caso anterior, o melhor ajuste é aquele em que os valores dos coeficientes são determinados escrevendo-se a soma dos quadrados dos resíduos, conforme equação (2.6) mostrada abaixo

$$S_r = \sum_{i=1}^n e_i^2 = \sum_{i=1}^n (y_i - \beta_0 - \beta_1 x_{1i} - \beta_2 x_{1i}^2 - \dots - \beta_m x_{1i}^m)^2 \quad (2.7)$$

Faz-se, então, a derivada parcial da equação (2.7) em relação a cada coeficiente desconhecidos do polinômio. As equações obtidas são, dessa forma, igualadas a 0 e organizadas para se determinar esses coeficientes.

Nesse caso, constata-se que o problema de se determinar um polinômio $f(x_1)$, de grau dois, pelo critério dos mínimos quadrados, é equivalente a resolver um sistema de três equações lineares simultâneas.

Para se determinar os coeficientes de um polinômio de uma variável com grau m , deve-se resolver um sistema de $(m + 1)$ equações lineares.

Pode-se também utilizar regressão polinomial quando se tem mais de uma variável explicativa. Além dos termos quadrático, cúbicos, quárticos etc, podemos inserir interação entre as variáveis. Um exemplo possível, envolvendo apenas duas variáveis independentes, é mostrado a seguir:

$$y_i = f(x_1, x_2) = \beta_0 + \beta_1 x_{1i} + \beta_2 x_{2i} + \beta_3 x_{1i}^2 + \beta_4 x_{2i}^2 + \beta_5 x_{1i} x_{2i} + e_i \quad (2.8)$$

Em engenharia de avaliações, a grande maioria dos trabalhos envolve regressões polinomiais com mais de uma variável explicativa. Em geral utiliza-se regressão linear múltipla, com técnicas já consagradas.

3 | REDES NEURAIS ARTIFICIAIS

McCulloch e Pitts propuseram, em 1943, um modelo de neurônio artificial, como uma unidade de processamento simples, cuja proposta não era copiar o neurônio verdadeiro, mas, sim, modelá-lo (BEALE *et al*, 1990).

Nesse modelo, o neurônio possuía dados de entrada da rede ou de saídas de outros neurônios (x_1, x_2, \dots, x_m) , ponderados pelos pesos (w_1, w_2, \dots, w_p) das ligações ou sinapses, sendo estes pesos fixos, não ajustáveis.

Segundo Ferneda (2006), combinando diversos neurônios, forma-se uma rede

neural. As redes neurais são modelos que buscam simular o processamento de informação do cérebro. São compostas por unidades de processamentos simples, os neurônios, que se unem por meio de sinapses.

De lá para cá, houve muita evolução. As redes neurais artificiais (RNA's) continuam tendo o seu funcionamento inspirado na estrutura biológica do cérebro humano e podem ser entendidas como conjuntos bem estruturados de unidades de processamento, interligados por canais de comunicação, cada qual tendo um determinado peso correspondente a um valor numérico. No decorrer do processo de "aprendizagem", os referidos pesos vão se ajustando de forma a atingir o objetivo pretendido (BAPTISTELLA *et al.*, 2007).

Conforme Sobreiro *et al.* (2009), a sistematização das redes neurais artificiais é realizada conforme o padrão de conexão entre camada das redes, o número de neurônios em cada camada, da capacidade da aprendizagem e as funções de ativação, ou seja, uma rede neural é um conjunto de entrelaçamentos, no qual cada conexão apresenta um peso associado, a fim de ajustar os *inputs* (entradas) aos *outputs* (saídas).

3.1 Perceptrons de múltiplas camadas

Dentre todas as possíveis topologias, as redes neurais podem ser classificadas em não recorrentes (feed-forward) e recorrentes (feed-back). As redes neurais não recorrentes são as que não possuem realimentação de suas saídas nas entradas. Essas redes têm sua estrutura organizada em camadas, podendo ser constituídas por uma ou mais camadas (GUARNIERI, 2006).

As redes neurais multicamadas contêm um conjunto de neurônios de entrada, uma camada de saída e uma ou mais camadas intermediárias, chamadas de camadas ocultas. Em geral, a entrada não é considerada camada da rede, pois apenas recebe os dados e os distribui, não realizando ponderação, somatório ou comparação com limiares.

Em geral, as redes neurais não-recorrentes com mais de uma camada são denominadas perceptrons de múltiplas camadas (multilayer perceptron). A Figura 01 traz um perceptron de múltiplas camadas contendo três entradas, duas camadas intermediárias com 4 neurônios cada e uma camada de saída com um neurônio, produzindo uma informação de saída.




Figura 01 - Rede neural de duas camadas ocultas - Fonte: Guarnieri (2006).

Cada neurônio representado por um círculo pintado na rede neural da Figura 01, pode ser visto como modelo para um neurônio genérico k da Figura 02, apresentado de forma simplificada por Haykin (2001, p. 36).




Figura 02 - Modelo não linear de um neurônio - Fonte: Haykin (2001)

O modelo proposto por Haykin (2001) é composto por três elementos básicos: A) um conjunto de m conexões de entrada (x_1, x_2, \dots, x_m), caracterizadas por pesos (w_1, w_2, \dots, w_p); B) um somador (S) para acumular os sinais de entrada; C) uma função de ativação (j) que limita o intervalo permissível de amplitude do sinal de saída (y_k) a um valor fixo, dependendo da função escolhida.

O chamado nível de atividade interna do neurônio (v_k) é obtido pela combinação do somatório das entradas ponderadas com outro valor ajustável, denominado bias (b_k). A saída do neurônio, y_k , é produzida pela aplicação do nível de atividade interna a uma função de ativação (j). O bias tem o efeito de aumentar ou diminuir a entrada líquida da função de ativação, dependendo se ele é positivo ou negativo, respectivamente (Haykin, 2001).

Um neurônio pode ser representado matematicamente pelas expressões:

$$v_k = \sum_{j=1}^n w_{kj} \cdot x_j + b_k \quad (2.9)$$

$$y_k = \varphi(v_k) \quad (2.10)$$

Tem-se que a equação (2.9) determina o valor de v_k que será levado para a função de ativação escolhida. Em razão da necessidade da utilização de sua derivada, é interessante que a função φ seja contínua e diferenciável. A função de ativação define a saída de um neurônio de acordo com o nível de atividade produzida pelas suas entradas. Funções comumente empregadas, segundo Braga *et al.* (2000) e Haykin (2001), são:




Figura 03 - Função (a) degrau, (b) linear, (c) logística, (d) tanh - Fonte: Fiorin *et al* (2011).

3.2 Arquitetura de uma rede neural

As redes neurais artificiais diferenciam-se pela sua arquitetura e pela forma como os pesos associados às conexões são ajustados durante o processo de aprendizado da rede. A arquitetura de uma rede neural restringe o tipo de problema no qual a rede poderá ser utilizada, e é definida pelo número de camadas (camada única ou múltiplas camadas), pelo número de nós em cada camada, pelo tipo de conexão entre os nós (*feed-forward* ou *feed-back*) e por sua topologia (HAYKIN, 2001, p. 46-49).

Segundo Haykin (2001), existem três tipos de arquitetura fundamentalmente diferentes: as redes de camada única alimentadas adiante, redes de múltiplas camadas alimentadas adiante (não recorrentes) e as redes recorrentes.

1) Redes alimentadas adiante ou não recorrentes (*feed-forward*) com camada única: a camada de entrada não é considerada, pois não é feito cálculo algum, logo o termo “camada única” refere-se à camada de saída.

2) Redes alimentadas adiante ou não recorrentes (*feed-forward*) com múltiplas camadas: a camada de entrada continua não sendo considerada, pois não é feito cálculo algum, portanto somente são contadas as camadas chamadas intermediárias e a camada de saída da rede neural.

3) Redes alimentadas adiante com laços de realimentação ou recorrente (*feed-back*): o que diferencia este tipo de rede dos outros dois tipos de rede é o fato de haver pelo menos um laço de realimentação na rede neural.

3.3 Aprendizagem de uma rede neural

Conforme Braga *et al.* (2000), uma das propriedades mais importantes de uma rede neural é a capacidade de aprender por intermédio de exemplos e fazer inferências sobre o que aprendeu, melhorando gradativamente o seu desempenho. As redes neurais utilizam um algoritmo de aprendizagem cuja tarefa é ajustar os pesos de suas conexões.

No processo de aprendizagem, também chamado de treinamento da rede, um conjunto de exemplos é fornecido para a rede, que ajusta os seus pesos sinápticos até que ela retire as características principais que representam as informações inseridas na rede. Na sequência, esses pesos são fixados e usados para buscar novas soluções para novas entradas.

Ademais, os treinamentos podem ser classificados em supervisionados e não-

supervisionados. No treinamento não-supervisionado é fornecido à rede somente valores de entrada que são organizados em diferentes classes de acordo com a semelhança de suas propriedades através do ajuste de seus pesos da rede (FIORIN *et al.*, 2011). No treinamento supervisionado, a cada iteração um vetor de entradas e um vetor alvo (saídas desejadas) são apresentados à rede. A partir das entradas, a rede calcula as saídas e compara-as com os alvos. Os pesos são ajustados de maneira que os valores das saídas aproximem-se dos alvos. (GUARNIERI, 2006).

Segundo Guarnieri (2006), considerando-se um neurônio de saída k em treinamento supervisionado sequencial, a cada iteração t é produzido um sinal de erro $e_k(t)$, obtido pela diferença entre o valor de saída calculado pelo neurônio e o valor alvo ou, saída desejada, $d_k(t)$

$$e_k(t) = d_k(t) - y_k(t) \quad (2.11)$$

Em cada uma das etapas do treinamento da rede, são realizadas alterações nos pesos, provocando uma redução incremental dos erros, de modo que a solução vai convergindo para o valor esperado.

Para Haykin (2001), o encerramento da fase de treinamento ocorre quando o erro atingir um valor mínimo pré-estabelecido ou quando a taxa de variação desse erro atingir um valor definido como critério de parada.

Em algumas situações, mesmo que se tenha obtido um erro mínimo para a rede neural na fase de treinamento, quando aplicado a um novo grupo de dados, o erro eleva-se. Diz-se, então, que a rede neural não adquiriu capacidade de generalização e que ocorreu um problema no treinamento da rede, conhecido como *overfitting* ou excesso de treinamento.

O fenômeno de *overfitting* ocorre, geralmente, quando é empregado um número muito grande de neurônios ocultos na rede, fazendo com que se permita à rede 'decorar' os dados, ao invés de aprender os seus padrões. Com o objetivo de garantir a capacidade de generalizar, métodos foram criados, entre eles a regularização e o treinamento com parada antecipada.

4 | MÉTODO APLICADO

Nesse estudo foram utilizados os 50 (cinquenta) dados de mercado de imóveis encontrados em Hochheim (2015). Na Figura 04, pode-se ver o comportamento da variável dependente em função de cada um dos regressores. Na sequência, vemos a descrição das variáveis consideradas no modelo, encontradas descritas em Hochheim (2015, p. 23):

- **Valor:** Valor total do imóvel. Variável quantitativa contínua. Unidade monetária

em reais (R\$).

- **Area_Total:** Área total do imóvel. Variável quantitativa contínua. Unidade: metros quadrados (m²).

- **Quartos:** Número de quartos, incluindo suítes. Variável quantitativa discreta.

- **Suítes:** Número de suítes do apto. Variável quantitativa discreta.

- **Garagens:** Número de vagas de garagens do apartamento. Variável quantitativa discreta.

- **Dist_Beira_Mar:** Distância em metros ao polo valorizador Beira Mar Norte. Variável quantitativa contínua.

- **Padrao:** Padrão do imóvel. Variável qualitativa tipo código alocado. Representa os três padrões encontrados na amostra. Existem 8 dados de padrão baixo (código alocado = 1), 17 dados de padrão médio (código alocado = 2) e 25 dados de padrão alto (código alocado = 3). (HOCHHEIM, 2015).

Para as simulações foi utilizado o *software* estatístico R na sua versão 3.5.1. Nas figuras abaixo, pode-se acompanhar a representação gráfica da variável dependente *versus* cada variável independente do modelo.




Figura 04: Variável dependente *versus* regressores. Fonte: Autores.

Tanto para o método de regressão polinomial quanto para o método das redes neurais artificiais, foi realizado o seguinte procedimento:

1. Para uma determinada porcentagem p , inicialmente de 20% do número de dados disponíveis n , foram criadas duas partições, uma partição de treinamento, com $p \times n = 10$ dados e uma partição de testes, com $(1 - p) \times n = 40$ dados, em que os dados das partições são escolhidos randomicamente.

2. Com as partições de treinamento assim obtidas, foram ajustados 100 modelos de regressão polinomial de grau 2, ou de redes neurais artificiais com 1 camada oculta.

3. Com os modelos obtidos no passo anterior, foram realizadas estimativas sobre os dados da partição de testes e foi calculado o RMSE para a partição de testes.

4. Iterativamente aumentou-se, de 2 em 2 pontos percentuais o tamanho da partição de treinamento, calculando-se o valor do RMSE para a partição de teste.

5. Finalmente, comparou-se o comportamento dos valores medianos do RMSE com o aumento do número de dados da partição de testes para as duas metodologias, assim como a distribuição final do RMSE com a utilização de 90% dos dados na partição de treinamento.

As redes neurais artificiais foram modeladas com o auxílio do pacote *neuralnet* (FRITSCH, 2016). Para a regressão polinomial, foi adotada a redução dimensional pelo método de análise de componentes principais, já programado internamente no pacote *polyreg* (MATLOFF *et al.*, 2018).

5 | RESULTADOS OBTIDOS

Nos tópicos seguintes serão apresentados os resultados obtidos ao se realizar a modelagem por regressão polinomial e por redes neurais.

5.1 Redes neurais artificiais

Na Figura 05, pode-se ver o comportamento do RMSE mediano para cada tamanho de partição com a aplicação do modelo de redes neurais, onde se observa que à medida que aumenta o tamanho da partição de treinamento, diminui o valor do RMSE mediano, ainda que com alguma instabilidade. Já na Figura 06, mostra-se que a distribuição do RMSE para a partição de treinamento de maior tamanho é relativamente esparsa.




Figura 05 - RMSE mediano com o tamanho da partição de testes - Fonte: Autores.




Figura 06 - Distribuição dos valores de RMSE para partição de treinamento. Fonte: Autores.

5.2 Regressão polinomial

Na Figura 07, pode-se ver o comportamento do RMSE mediano para cada tamanho de partição com a aplicação do modelo de regressão polinomial, onde se observa que à medida que aumenta o tamanho da partição de treinamento, diminui o valor do RMSE mediano, com uma estabilidade muito maior do que a verificada com os modelos de redes neurais artificiais. Já na Figura 07, mostra-se que a distribuição do RMSE para a partição de treinamento de maior tamanho é muito mais compacta do que a obtida na modelagem por redes neurais artificiais.

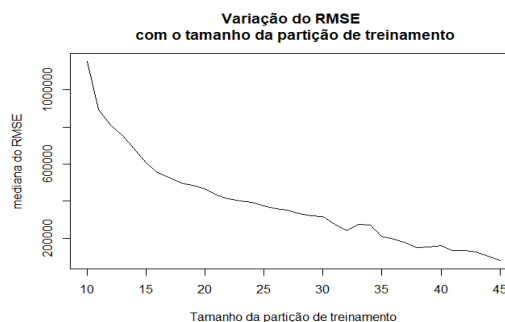


Figura 07 - RMSE mediano com o tamanho da partição de testes - Fonte: Autores.




Figura 08 - Distribuição dos valores de RMSE para partição de treinamento. Fonte: Autores.

6 | CONSIDERAÇÕES FINAIS

Este estudo teve como objetivo comparar os resultados obtidos ao se tratar dados utilizando regressão polinomial e técnicas de redes neurais artificiais. Verificou-se que os resultados da raiz do erro médio quadrático - RMSE para modelos de regressão polinomial foram menores e com menor dispersão quando comparados com os obtidos por redes neurais artificiais.

Conforme os últimos achados na ciência estatística, e de acordo com os resultados apresentados tanto em Matloff (2018) quanto nesse estudo, pondera-se que sejam despendidos maiores esforços em estudos relacionados à utilização da regressão polinomial na Engenharia de Avaliações, haja vista que, como a regressão polinomial nada mais é do que um caso particular de regressão linear, seu método e aplicação já são plenamente conhecidos e estão estabelecidos e normatizados pela NBR 14.653-02, enquanto as redes neurais ainda apresentam comportamento um tanto desconhecido, apesar de sua excelente performance e resultados.

Além disso, como o desempenho dos modelos de regressão polinomial mostrou-se bastante satisfatório, sugere-se, também, que sejam investidos maiores esforços no estudo das particularidades do respectivo método para uma possível posterior normatização dos seus procedimentos.

REFERÊNCIAS

- ABNT. ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 14653-2**: Avaliação de Bens. Parte 2: Imóveis Urbanos. Rio de Janeiro, 2011.
- BAPTISTELLA, Marisa; CUNICO Luiz Homero Bastos; STEINER, Maria Teresinha Arns. **O uso de redes neurais na engenharia de avaliações**: determinação dos valores venais de imóveis urbanos. Revista Ciências Exatas e Naturais. São Paulo, v. 9, n. 2, jul./dez 2007.
- BEALE, R.; JACKSON, T. **Neural computing**: an introduction. Institute of Physics Publishing, 1990.
- BRAGA, A. P.; CARVALHO, A. C. P. L. F.; LUDEMIR, T. B. **Redes neurais artificiais**: teoria e aplicações. Rio de Janeiro: LTC, 2000.

FERNEDA, Edberto. **Redes neurais e sua aplicação em sistemas de recuperação de informação**. Faculdade de Filosofia Ciências e Letras de Ribeirão Preto - USP. jul. 2006.

FIORIN, D. V.; MARTINS, F. R.; SCHUCH, N. J.; PEREIRA, E. B. **Aplicações de redes neurais e previsões de disponibilidade de recursos energéticos solares**. Revista Brasileira Ensino de Física. São Paulo, v. 33, n 11, mar. 2011.

FRITSCH, S.; GUENTHER, F. (2016). **neuralnet: Training of Neural Networks**. R package version 1.33. Disponível em: <<https://CRAN.R-project.org/package=neuralnet>>. Acesso em out. 2018.

GUARNIERI, Ricardo André. **Emprego de redes neurais artificiais e regressão linear múltipla no refinamento das previsões de radiação solar do modelo ETA**. Dissertação (Mestrado em Meteorologia) - Programa de Pós-Graduação em Meteorologia, IMPE, São José dos Campos, 2006.

GUJARATI, D. N; PORTER, D. C. **Econometria básica**. 5. ed. Porto Alegre: AMGH Bookman, 2011.

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

HOCHHEIM, Norberto. **Engenharia de avaliações: módulo básico**. Florianópolis: IBAPE - SC, 2015.

MATLOFF, Norman; CHENG, Xi; KHOMTCHOUK, Bohdan; MOHANTY, Pete. **Polynomial regression as an alternative to neural nets**. 2018. Disponível em: <<https://arxiv.org/abs/1806.06850>>. Acesso em out. 2018.

PELLI NETO, A. **Redes neurais artificiais aplicadas às avaliações em massa: estudo de caso para a cidade de Belo Horizonte**. Dissertação (Mestrado em Engenharia Elétrica) - Programa de Pós-Graduação em Engenharia Elétrica, UFMG, Belo Horizonte, 2006.

SOBREIRO, V. A.; ARAÚJO, P. H. S. L.; NAGANO, M. S. **Precificação do etanol utilizando técnicas de redes neurais artificiais**. Revista de Administração. São Paulo, v. 44, n. 1, p. 46-58, jan./fev./mar. 2009.

SOBRE O ORGANIZADOR

CLEBERTON CORREIA SANTOS- Graduado em Tecnologia em Agroecologia, mestre e doutor em Agronomia (Produção Vegetal). Tem experiência nas seguintes áreas: agricultura familiar, indicadores de sustentabilidade de agroecossistemas, uso e manejo de resíduos orgânicos, propagação de plantas, manejo e tratamentos culturais em horticultura geral, plantas medicinais exóticas e nativas, respostas morfofisiológicas de plantas ao estresse ambiental, nutrição de plantas e planejamento e análises de experimentos agropecuários.

(E-mail: cleber_frs@yahoo.com.br) – ORCID: 0000-0001-6741-2622

ÍNDICE REMISSIVO

A

Acidentes 109, 310, 311, 312, 313, 314

Aminas primárias 81, 84, 85

Atividade antioxidante 144, 146, 151, 152, 153, 155, 156

B

Bioimpressão 193, 194, 195, 196, 199

C

Castanhola 74, 75, 79

Compostos multifuncionais 64, 67

Compressores Herméticos 34, 35, 36, 39, 40

Construção Civil 102, 105, 112, 113, 157, 179, 363

CPTEC 205, 206, 207, 208, 217

E

Equações lineares 45, 233, 236, 237, 238, 239, 240, 353

Estrutura axiomática 183, 186, 189

F

Fonte de fissão 41, 42, 44, 45, 47, 48, 49

G

Geoprocessamento 1, 2

H

Hemocentro 317, 322, 323, 324, 326

Hibridização 64, 65, 67, 68, 69, 71

L

Lesson Study 218, 219, 220, 221, 222, 224, 225

Leveduras 8

M

Mapeamento 1, 2, 3, 4, 6, 7, 181, 280

Mecânicas de eritrócitos 226

Multi-objetivo 277, 278, 279, 281, 282, 283, 284, 287

Mutagênese 8, 10, 11, 12, 13, 15, 16, 17, 18

P

PHB/PC 253, 254, 257, 261, 262, 264

Protocolos de redes 52

R

Redes neurais 349, 350, 351, 354, 356, 358, 359, 360, 361, 362

Risco de inundação 1, 3, 4, 5, 6, 7

S

Smart Grids 51, 52, 53, 61

Agência Brasileira do ISBN
ISBN 978-85-7247-622-5

