



Cleberton Correia Santos
(Organizador)

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

Atena
Editora
Ano 2019

Cleberton Correia Santos
(Organizador)

Estudos Interdisciplinares nas Ciências Exatas e da Terra e Engenharias

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	Estudos interdisciplinares nas ciências exatas e da terra e engenharias 1 [recurso eletrônico / Organizador Cleberton Correia Santos. – Ponta Grossa, PR: Atena Editora, 2019. – (Estudos Interdisciplinares nas Ciências Exatas e da Terra e Engenharias; v. 1) Formato: PDF Requisitos de sistema: Adobe Acrobat Reader Modo de acesso: World Wide Web Inclui bibliografia ISBN 978-85-7247-621-8 DOI 10.22533/at.ed.218191109 1. Ciências exatas e da Terra. 2. Engenharias. 3. Tecnologia. I.Santos, Cleberton Correia. II. Série. CDD 016.5
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 primeiro volume 35 capítulos relacionados temáticas de área multidisciplinar associadas 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 pesquisadores de instituições de ensino, pesquisa e extensão ao desenvolvimento estudos de casos e inovações científicas, contribuindo então na aprendizagem significativa e desenvolvimento socioeconômico rumo à sustentabilidade e avanços tecnológicos.

Cleberton Correia Santos

SUMÁRIO

CAPÍTULO 1	1
CHÁ DE BOLDO: O SABER POPULAR FAZENDO-SE SABER CIENTÍFICO NO ENSINO DE QUÍMICA	
Andressa da Silva Muniz	
Monique Gonçalves	
DOI 10.22533/at.ed.2181911091	
CAPÍTULO 2	13
A ESTRATÉGIA REGIONAL DE INOVAÇÃO DA UNIÃO EUROPEIA PARA IMPLEMENTAÇÃO DE SRIs NA AMÉRICA LATINA	
Guilherme Paraol de Matos	
Clarissa Stefani Teixeira	
Paulo Cesar Leites Esteves	
Solange Maria da Silva	
DOI 10.22533/at.ed.2181911092	
CAPÍTULO 3	26
ENSINO DE TÉCNICAS LABORATORIAIS PELA ELABORAÇÃO DE SORVETE COM A FRUTA BERIBÁ/BIRIBÁ (<i>Annona hypoglauca</i>)	
Minelly Azevedo da Silva	
Alice Menezes Gomes	
Amanda Carolilna Cândido Silva	
Iasmim Moreira Linhares	
João Vitor Hermenegildo Bastos	
Mel Naomi da Silva Borges	
Rebeca da Costa Rodrigues	
Nilton Fagner de Oliveira Araújo	
Elza Paula Silva Rocha	
Cleber do Amaral Barros	
Jamilé Mariano Macedo	
DOI 10.22533/at.ed.2181911093	
CAPÍTULO 4	37
A ETNOMATEMÁTICA COMO RECURSO METODOLÓGICO NO CONTEXTO DA EDUCAÇÃO A DISTÂNCIA: UMA INVESTIGAÇÃO NO CURSO DE LICENCIATURA EM MATEMÁTICA DA UNICESUMAR	
Eliane da Rocha Rodrigues	
Ivna Gurniski de Oliveira	
DOI 10.22533/at.ed.2181911094	
CAPÍTULO 5	52
USO DE GEOTECNOLOGIAS PARA MAPEAMENTO EM ÁREAS AGRICULTÁVEIS	
Ana Paula Brasil Viana	
Railton Reis Arouche	
Pedro Henrique da Silva Sousa	
Edvan Carlos de Abreu	
Dheime Ribeiro de Miranda	
Lineardo Ferreira de Sampaio Melo	
DOI 10.22533/at.ed.2181911095	

CAPÍTULO 6 58

O USO DA CASCA DA BANANA COMO ADSORVENTE RENOVÁVEL DE ÍONS METÁLICOS TÓXICOS

Adriana O. Santos
Danielle P. Freitas
Fabiane A. Carvalho
Fernando S. Melo
Juliana F. C. Eller
Stéphanie Calazans Domingues
Boutros Sarrouh
Willian A. Saliba

DOI 10.22533/at.ed.2181911096

CAPÍTULO 7 76

STATIC MAGNETIC TREATMENT OF IRRIGATION WATER ON DIFFERENTS PLANTS CULTURES IMPROVING DEVELOPMENT

Yilan Fung Boix
Albys Ferrer Dubois
Elizabeth Isaac Alemán
Cristiane Pimentel Victório
Rosani do Carmo de Oliveira Arruda
Ann Cuyppers
Natalie Beenaerts
Jorge González Aguilera
Alan Mario Zuffo

DOI 10.22533/at.ed.2181911097

CAPÍTULO 8 85

ANÁLISE DE ARQUITETURAS DE *DEEP LEARNING* APLICADO A UM BENCHMARK DE CLASSIFICAÇÃO

Henrique Matheus Ferreira da Silva
Max Tatsuhiko Mitsuya
Clayton André Maia dos Santos
Anderson Alvarenga de Moura Meneses

DOI 10.22533/at.ed.2181911098

CAPÍTULO 9 96

ANÁLISE DE VITAMINA C USANDO TÉCNICAS DE FLUORIMETRIA, CROMATOGRAFIA E ELETROFORESE

Luana Gabriela Marmitt
Sabrina Grando Cordeiro
Verônica Vanessa Brandt
Lucélia Hoehne

DOI 10.22533/at.ed.2181911099

CAPÍTULO 10 106

RESOLUÇÃO DE PROBLEMAS DE MATEMÁTICA NO CURSO TÉCNICO EM AGROPECUÁRIA DO IFC – *CAMPUS SANTA ROSA DO SUL*

Julian da Silva Lima
Cassiano Scott Puhl
Neiva Ignês Grando

DOI 10.22533/at.ed.21819110910

CAPÍTULO 11 116

A VISÃO DOS PROFESSORES DE CIÊNCIAS DE ARAPIRACA-AL SOBRE O ENSINO DE ASTROBIOLOGIA

Janaína Kívia Alves Lima
Elielma Lucindo da Silva
Lilian Nunes Bezerra
Janice Gomes Cavalcante
Luis Carlos Soares da Silva
José Edson Cavalcante da Silva
Jhonatan David Santos das Neves
Daniella de Souza Santos

DOI 10.22533/at.ed.21819110911

CAPÍTULO 12 125

APLICAÇÃO DA GESTÃO DO CONHECIMENTO PARA MELHORIA DO PROCESSO DE ELABORAÇÃO DE PROPOSTAS DE EXTENSÃO UNIVERSITÁRIA

André Felipe de Almeida Batista
Ricardo André Cavalcante de Souza

DOI 10.22533/at.ed.21819110912

CAPÍTULO 13 138

PRECIPITATION VARIABILITY ON THE STATE OF PARAÍBA IN ATMOSPHERIC CONDITIONS UNDER THE INFLUENCE OF UPPER LEVEL CYCLONIC VORTICES

André Gomes Penaforte
Maria Marle Bandeira
Magaly de Fatima Correia
Tiago Rocha Almeida
Flaviano Fernandes Ferreira

DOI 10.22533/at.ed.21819110913

CAPÍTULO 14 148

AS CONTRIBUIÇÕES DO PLANETÁRIO E CASA DA CIÊNCIA DE ARAPIRACA PARA O ENSINO DE GEOGRAFIA E CIÊNCIAS NATURAIS

Luis Carlos Soares da Silva
Janaína Kívia Alves Lima
Janice Gomes Cavalcante
Jhonatan David Santos das Neves
Lilian Nunes Bezerra
Daniella de Souza Santos
José Edson Cavalcante da Silva
Elielma Lucindo da Silva

DOI 10.22533/at.ed.21819110914

CAPÍTULO 15 157

POLÍMERO SULFONADO UTILIZADO COMO CATALISADOR HETEROGÊNEO NA REAÇÃO DE ESTERIFICAÇÃO

Victória Maria Ribeiro Lima
Rayanne Oliveira de Araújo
Jamal da Silva Chaar
Luiz Kleber Carvalho de Souza

DOI 10.22533/at.ed.21819110915

CAPÍTULO 16 167

ATIVIDADE CRIATIVA (AC): UM MODO ALTERNATIVO PARA MINISTRAR O CONTEÚDO DE UMA DISCIPLINA DO CURSO NOTURNO DE FARMÁCIA DA UFRJ

Aline Guerra Manssour Fraga
Viviane de Oliveira Freitas Lione

DOI 10.22533/at.ed.21819110916

CAPÍTULO 17 180

AVALIAÇÃO DE DESEMPENHO DE MATERIAIS MULTIEXTUSADOS: SIMULAÇÃO DO REPROCESSAMENTO DO POLIETILENO DE ALTA DENSIDADE (PEAD)

Fernando A. E Tremoço
Ricardo S. Souza
Valéria G. Costa

DOI 10.22533/at.ed.21819110917

CAPÍTULO 18 186

CARACTERIZAÇÃO ESTRUTURAL DE ARGILAS BENTONÍTICAS PARA O DESENVOLVIMENTO DE NANOCOMPÓSITOS POLIMÉRICOS

Carlos Ivan Ribeiro de Oliveira
Nancy Isabel Alvarez Acevedo
Marisa Cristina Guimarães Rocha
Joaquim Teixeira de Assis
Alexei Kuznetsov
Luiz Carlos Bertolino

DOI 10.22533/at.ed.21819110918

CAPÍTULO 19 197

AVALIAÇÃO PELA MODA, MÉDIA OU MEDIANA?

Luiz Fernando Palin Droubi
Norberto Hochheim
Willian Zonato

DOI 10.22533/at.ed.21819110919

CAPÍTULO 20 221

COMPARAÇÃO ENTRE O MÉTODO DAS SOLUÇÕES FUNDAMENTAIS E O MÉTODO DOS VOLUMES FINITOS APLICADOS A UM PROBLEMA BIDIMENSIONAL DE DIFUSÃO DE CALOR

Bruno Henrique Marques Margotto
Carlos Eduardo Polatschek Kopperschmidt
Wellington Betencurte da Silva
Júlio Cesar Sampaio Dutra
Luiz Alberto da Silva Abreu

DOI 10.22533/at.ed.21819110920

CAPÍTULO 21 230

SINERGISMO DE MISTURAS DE COMPLEXOS ENZIMÁTICOS UTILIZADAS NA HIDRÓLISE DA CELULOSE EXTRAÍDA DO BAGAÇO DE CANA-DE-AÇÚCAR PRÉ-TRATADO COM H_2SO_4/H_2O_2 , EM MEIO ALCALINO

Leila Maria Aguilera Campos
Luciene Santos de Carvalho
Luiz Antônio Magalhães Pontes
Samira Maria Nonato de Assumpção
Maria Luiza Andrade da Silva
Heloise Oliveira Medeiros de Araújo Moura
Anne Beatriz Figueira Câmara

DOI 10.22533/at.ed.21819110921

CAPÍTULO 22	238
CONCEPÇÕES DE LINGUAGEM E SUAS IMPLICAÇÕES PARA O ENSINO E A APRENDIZAGEM DA LINGUAGEM MATEMÁTICA	
Cíntia Maria Cardoso	
DOI 10.22533/at.ed.21819110922	
CAPÍTULO 23	248
DESENVOLVIMENTO E VALIDAÇÃO DE SOFTWARE INTERATIVO PARA PROJETOS CONCEITUAIS DE AERONAVES	
Carlos Antonio Vilela de Souza Filho	
Giuliano Gardolinski Venson	
Jefferson Gomes do Nascimento	
DOI 10.22533/at.ed.21819110923	
CAPÍTULO 24	260
ESTÁGIO CURRICULAR SUPERVISIONADO: UM OLHAR PARA O PROCESSO FORMATIVO POSSIBILITADO POR OBSERVAÇÕES DE AULA	
Mariele Josiane Fuchs	
Cláudia Maria Costa Nunes	
Elizangela Weber	
Lucilaine Goin Abitante	
DOI 10.22533/at.ed.21819110924	
CAPÍTULO 25	269
OTIMIZAÇÃO DOS CUSTOS FINANCEIROS DE UMA MADEIREIRA UTILIZANDO PROGRAMAÇÃO LINEAR	
Brenno Souza de Oliveira	
Edson Patrício Barreto de Almeida	
Vitor Miranda Sousa Brito	
DOI 10.22533/at.ed.21819110925	
CAPÍTULO 26	280
ESTUDO ATUALIZADO E ABRANGENTE DAS APLICAÇÕES PRÁTICAS DE GEOPROSPECÇÃO ELÉTRICA	
Pedro Henrique Martins	
Antonio Marcelino da Silva Filho	
Kaiisson Teodoro de Souza	
Márcio Augusto Tamashiro	
Humberto Rodrigues Macedo	
DOI 10.22533/at.ed.21819110926	
CAPÍTULO 27	292
FIQUE SABENDO: PLATAFORMA ACADÊMICA DE COMUNICAÇÃO	
Marco Antônio Castro Martins	
Lúcio Flávio de Jesus Silva	
George Miler Gomes Farias	
Diego Lisboa Pires	
DOI 10.22533/at.ed.21819110927	

CAPÍTULO 28 300

INVESTIGAÇÃO ESTRUTURAL, MORFOLÓGICA E FOTOCATALÍTICA DE MICROCRISTAIS DE β -(Ag_{2-2x}Zn_x)MoO₄

Fabiana de Sousa Cunha
Francisco Henrique Pereira Lopes
Amanda Carolina Soares Jucá
Lara Kelly Ribeiro da Silva
Keyla Raquel Batista da Silva Costa
Júlio César Sczancoski
Francisco Eroni Paz dos Santos
Elson Longo
Laécio Santos Cavalcante
Gustavo Oliveira de Meira Gusmão

DOI 10.22533/at.ed.21819110928

CAPÍTULO 29 325

PRODUTOS QUÍMICOS PERIGOSOS: EDUCAÇÃO AMBIENTAL E ENSINO DE QUÍMICA ATRAVÉS DA TEMÁTICA SANEANTES

Egle Katarinne Souza da Silva
Luislândia Vieira de Figueredo
Felícia Maria Fernandes de Oliveira
Luiz Antonio Alves Fernandes
Edilson Leite da Silva

DOI 10.22533/at.ed.21819110929

CAPÍTULO 30 339

INFLUÊNCIA DO SnCl₂ NA COPOLIMERIZAÇÃO DE NORBORNENO E ÁCIDO 5-NORBORNENO-2-CARBOXÍLICO VIA ROMCP CATALISADO POR RuCl₂(PCy₃)₂CHR

Sâmia Dantas Braga
Aline Aparecida Carvalho França
Vanessa Borges Vieira
Talita Teixeira da Silva
Aline Estefany Brandão Lima
Ravane Costa e Silva
Luís Fernando Guimarães Nolêto
Nouga Cardoso Batista
José Milton Elias de Matos
Benedito dos Santos Lima Neto
José Luiz Silva Sá
Geraldo Eduardo da Luz Júnior

DOI 10.22533/at.ed.21819110930

CAPÍTULO 31 347

MONITORAMENTO DE DESEMPENHO DO SISTEMA FOTOVOLTAICO CONECTADO À REDE ELÉTRICA DO INSTITUTO FEDERAL DO RIO GRANDE DO NORTE CAMPUS PAU DOS FERROS

José Henrique Maciel de Queiroz
José Flávio Timoteo Júnior
Rogério de Jesus Santos

DOI 10.22533/at.ed.21819110931

CAPÍTULO 32 357

REDE FEDERAL EM SANTA CATARINA: ORIGEM, TRAJETÓRIA E ASPECTOS GERENCIAIS

Sônia Regina Lamego Lino

DOI 10.22533/at.ed.21819110932

CAPÍTULO 33	371
SISTEMA DE EDUCAÇÃO CORPORATIVA: EXPERIÊNCIAS BRASILEIRAS E CHINESAS PARA A INOVAÇÃO	
Regina Wundrack do Amaral Aires	
Cleunisse Aparecida Rauen De Luca Canto	
Patricia de Sá Freire	
DOI 10.22533/at.ed.21819110933	
CAPÍTULO 34	385
VARIABILIDADE TEMPORAL DE COMPOSTOS FENÓLICOS EM FOLHAS DE <i>Eucalyptus microcorys</i>	
Gilmara Aparecida Corrêa Fortes	
Pedro Henrique Ferri	
Suzana da Costa Santos	
DOI 10.22533/at.ed.21819110934	
CAPÍTULO 35	397
OXIDAÇÃO SELETIVA DO METANOL A FORMALDEÍDO ASSISTIDA POR N ₂ O SOBRE CATALISADOR Co,Ce DERIVADOS DE HIDRÓXIDOS DUPLOS LAMELARES	
Oséas Silva Santos	
Giulyane Felix de Oliveira	
Artur José Santos Mascarenhas	
Heloyza Martins. Carvalho Andrade	
DOI 10.22533/at.ed.21819110935	
SOBRE O ORGANIZADOR	408
ÍNDICE REMISSIVO	409

ANÁLISE DE ARQUITETURAS DE *DEEP LEARNING* APLICADO A UM BENCHMARK DE CLASSIFICAÇÃO

Henrique Matheus Ferreira da Silva

Láboratorio Nacional de Computação Científica
Petrópolis- Rio de Janeiro

Max Tatsuhiko Mitsuya

Universidade Federal do Oeste do Pará
Santarém – Pará

Clayton André Maia dos Santos

Universidade Federal do Oeste do Pará
Santarém – Pará

Anderson Alvarenga de Moura Meneses

Universidade Federal do Oeste do Pará,
Programa de Pós Graduação em Recursos
Naturais da Amazônia-Santarém, PA, Brasil

RESUMO: O Aprendizado Profundo (Deep Learning) é uma subárea de Aprendizado de Máquina (Machine Learning), que investiga técnicas para simular o comportamento do cérebro humano. No presente trabalho apresenta-se uma análise de arquiteturas de Deep Learning na solução de um problema de Classificação. Para tanto, utilizou-se a base de dados wine quality dataset (Cortez et al., 2009). Foram analisadas 9 arquiteturas de Deep Learning, com variações no número de neurônios e camadas ocultas, de forma a comparar seus desempenhos usando as métricas: Acurácia, Precisão, Recall e F1 Score. Posteriormente foi utilizado o teste de Kruskal-Wallis para avaliar se há diferença estatisticamente significativa

entre as arquiteturas com a finalidade de reduzir o custo computacional para futuras aplicações. Verificou-se que a diferença entre os desempenhos não é estatisticamente significativa (com $\alpha = 5\%$) para nenhuma das métricas utilizadas para este conjunto de dados, sendo assim possível usar a arquitetura menos complexa sem comprometer os resultados obtidos, reduzindo o custo computacional.

PALAVRAS-CHAVE: Deep Learning, Inteligência Artificial, Aprendizado Supervisionado, Redes Neurais

DEEP LEARNING ARCHITECTURE

ANALYSIS APPLIED TO A BENCHMARK OF CLASSIFICATION

ABSTRACT: Deep Learning is a Machine Learning subarea that investigates techniques for simulating the behavior of the human brain. In the present work we present an analysis of architectures of Deep Learning in the solution of a Classification problem. For this purpose, the wine quality dataset database was used (Cortez et al., 2009). We analyzed 9 architectures of Deep Learning, with variations in the number of neurons and hidden layers, in order to compare their performances using the metrics: Accuracy, Accuracy, Recall and F1 Score. Subsequently, the Kruskal-Wallis test was used to evaluate if

there is a statistically significant difference between the architectures in order to reduce the computational cost for future applications. It was verified that the difference between the performances is not statistically significant (with $\alpha = 5\%$) for none of the metrics used for this dataset, so it is possible to use the less complex architecture without compromising the results obtained, reducing the computational cost.

KEYWORDS: Wine dataset, Deep Learning, artificial intelligence, metrics machine Learning and Kruskal Wallis

1 | INTRODUÇÃO

Os avanços nas tecnologias da informação tornaram possível coletar, armazenar e processar conjuntos de dados massivos e complexos. Todos esses dados contêm informações valiosas, como tendências e padrões, que podem ser usados para melhorar a tomada de decisão.

Na literatura, é possível observar o uso de diferentes técnicas de Aprendizado de Máquina (do inglês Machine Learning), tais como Redes Neurais Artificiais - RNAs (Sun et al., 1997), e Máquinas de Vetores de Suporte - SVM do inglês Support Vector Machines (Beltran & Vicencio, 2008) (Cortez et al., 2009).

O Aprendizado Profundo (do inglês, Deep Learning) (LeCun et al, 2015) é uma subárea de Machine Learning que investiga técnicas para simular o comportamento do cérebro humano em tarefas como reconhecimento de padrões, reconhecimento visual e processamento de linguagem natural usando redes neurais com a adição da ferramenta CUDA da Nvidia.

Neste trabalho é proposta uma análise de arquiteturas de Deep Learning – para predição de benchmarks de machine Learning. Para tanto foi utilizada a base de dados Wine Quality Data Set, disponível no website Machine Learning Repository, da Universidade da Califórnia em Irvine (<https://archive.ics.uci.edu/ml/datasets/wine+quality>).

A predição do wine quality consiste na determinação do tipo de vinho, se ele é branco (White) ou tinto (Red) a partir de propriedades físico-químicas (12 propriedades) deliberado pelo autor (Cortez et al., 2009), a base de dados é amplamente utilizada como benchmark para algoritmos de aprendizado supervisionado, tendo a sua importância no fato de ser um conjunto de dados advindo do mundo real.

Serão implementadas diferentes arquiteturas de Deep Learning Multilayer Perceptron com o intuito de saber quais são as melhores configurações da rede, a fim de verificar se existe uma diferença estatística significativa para futuras aplicações. A rede foi implementada em Python, usando a Integrated Development Environment (IDE) Spyder. O diferencial do trabalho está nas avaliações das arquiteturas, usando o cálculo das métricas precisão (precision), recall, f1-score e acurácia (accuracy) em detrimento da simples análise da acurácia somente. Foi usado o teste estatístico de Kruskal Wallis para verificar se há diferença estatística entre as arquiteturas.

O restante do trabalho está organizado da seguinte forma: a seção 2 apresenta o referencial teórico, destacando os modelos de Machine Learning aplicados para resolução do problema. Na seção 3 é apresentada a metodologia e o desenho experimental. Os resultados experimentais e análises são discutidos na seção 4. Por fim, a seção 5 discute a conclusão do trabalho.

2 | REFERENCIAL TEÓRICO

Esta Seção apresenta considerações de ordem geral sobre *Machine Learning*, RNAs e arquiteturas de *Deep Learning*.

2.1 *Machine Learning*

Entidades inteligentes destacam-se pela capacidade de adequação a novos ambientes e de resolução de novos problemas. Um computador pode ser orientado a interpretar informações recebidas de uma forma que melhore gradualmente seu desempenho (Rich & Knight, 1991). Essa é a base na qual a área de pesquisa em Machine Learning, subárea da inteligência artificial, está fundamentada, isto é, Machine Learning estuda métodos computacionais capazes de obter um determinado conhecimento específico através de experiências.

Os algoritmos de Machine Learning possuem normalmente foco em métodos estatísticos e sua aplicação prática inclui tarefas de reconhecimento de padrões diversos, tais como pesquisas na web, filtragem de conteúdo em redes sociais, recomendações de websites de comércio eletrônico, e está cada vez mais presente em produtos de consumo como câmeras e smartphones. Portanto, esses algoritmos podem “aprender” a definir padrões das classes envolvidas em um problema, a partir de exemplos reais obtidos do ambiente (Lecun, 2015).

Machine Learning pode ser dividida em aprendizado supervisionado e não-supervisionado (Haykin, 2008). No primeiro, o conhecimento é representado por um conjunto de exemplos de pares de entrada-saída que são transmitidos em uma sequência de instruções que o computador seguirá para alcançar o efeito desejado. Enquanto que, no Aprendizado não-supervisionado, não há exemplos rotulados da função a ser aprendida. Por este motivo, problemas de aprendizado supervisionado são denominados de Problemas de Classificação e problemas de aprendizado não-supervisionado são chamados de Problemas de Agrupamento.

Dada a necessidade de maior poder de processamento para grande volume de dados, as técnicas convencionais de aprendizado de máquina tornaram-se limitadas em sua capacidade de processar dados naturais em sua forma bruta. Cada vez mais, essas aplicações fazem uso de um conjunto de técnicas chamada Deep Learning, que serão tratados na Seção 2.3.

2.2 Redes Neurais Artificiais

Uma RNA (Haykin, 2008) é representada na forma de um grafo direcionado, onde os *nodos* são neurônios que representam as unidades de processamento, os arcos representam as conexões e as setas dos arcos indicam a direção normal do fluxo do sinal. Os neurônios são organizados em camadas, de modo que cada neurônio na camada i se conecta a cada neurônio na camada $i + 1$. As conexões são ponderadas e é através da modificação desses pesos que as RNAs aprendem. As RNAs possuem uma camada de entrada e uma camada de saída. Quaisquer camadas entre elas são chamadas de camadas ocultas. O *forward pass* de uma RNA é onde a informação sai da camada de entrada, através de quaisquer camadas ocultas, até a saída. O aprendizado (atualização os pesos) acontece durante o *backwards pass*. A Figura 1 apresenta um exemplo de uma rede com quatro camadas possuindo duas camadas ocultas (HLs – do inglês *Hidden Layers*). Essas redes de camadas múltiplas são chamados de *Perceptrons* Multicamadas (*Multilayer Perceptrons - MLPs*)




Figura 1- Estrutura de uma RNA do tipo MLP. Adaptado de Nielsen (2015).

2.3 Deep Learning

Deep Learning é uma forma de *Machine Learning* que permite que os computadores aprendam com a experiência e compreendam o mundo em termos de uma hierarquia de conceitos. Tendo sua base fundamentada no conceito de RNA ou sistemas computacionais que imitam a maneira como o cérebro humano funciona (Goodfellow et al., 2016). O *Deep Learning* tem sido responsável por avanços recentes em visão computacional, reconhecimento de fala, processamento de linguagem natural e reconhecimento de áudio.

O processo de aprendizado ocorre a partir das camadas de neurônios utilizadas para processamento dos dados. A informação é passada através de cada camada, com a saída da camada anterior fornecendo entrada para a próxima camada. A primeira camada em uma rede é chamada de camada de entrada, enquanto a última

é chamada de camada de saída. Todas as camadas entre as duas são referidas como HLs. Cada camada é tipicamente um algoritmo simples e uniforme contendo um tipo de função de ativação. A Figura 2 apresenta uma breve diferença entre a arquitetura simples de rede neural e uma arquitetura de *Deep Learning*.

Atualmente, o processamento de *Big Data* e a evolução da Inteligência podem atuar em conjunto com o *Deep Learning*. Neste sentido, redes neurais baseadas no conceito de *Deep Learning* (Redes Neurais Profundas) podem receber quantidades continuamente crescentes de dados para aumentar a eficiência dos processos de treinamento. Quanto maior o volume de dados, mais eficiente é esse processo.




Figura 2 – Estrutura de RNA Simples e *Deep Learning*. Adaptado de Edwards (2018).

Neste trabalho, serão utilizadas redes do tipo *Deep Feed Forward* (DFF). A maioria dos resultados experimentais recentes com arquitetura profunda é obtida com modelos que podem ser transformados em RNAs supervisionadas profundas, mas com esquemas de inicialização ou treinamento diferentes das RNAs clássicas de *Feed Forward* (Glorot & Bengio, 2010).

3 | PROCEDIMENTO METODOLÓGICO

Esta Seção apresentará informações sobre a classificação do *dataset* escolhido, as arquiteturas utilizadas, as métricas usadas e as análises estatísticas.

3.1 Base de dados *wine quality*

Neste trabalho foi utilizado a base de dados *wine quality* (Cortez et al., 2009). Esta base de dados é composta por dois conjuntos de dados relacionados às características físico-químicas de vinhos branco (*white*) e tinto (*red*). O conjunto de dados é formado por 1599 amostras de vinho tinto e 4898 de vinho branco, possuindo variáveis de entrada representadas pelas características físico-químico dos respectivos vinhos, e como variável de saída a a predição do vinho.

Neste trabalho, foram combinados os dois conjuntos de dados de vinhos de forma aleatória, totalizando 6497 instâncias. Neste sentido, temos uma base de dados na qual as entradas são representadas pelas variáveis físico-químicas e como saída temos a classificação do vinho em tinto (1) ou branco (0), tornando-se um problema de classificação binária.

Para implementação das redes *Deep Learning*, o conjunto de dados utilizado foi dividido em 80% para treinamento e 20% para teste, dados divididos de forma aleatória. Os resultados das métricas apresentadas no presente trabalho foram avaliadas com o conjunto de teste.

3.2 Arquiteturas das Redes *Deep Learning*

Para o desenvolvimento deste trabalho foram elaboradas diferentes arquiteturas de redes *Deep Learning* no intuito de avaliar a performance das mesmas. As arquiteturas possuem funções de ativação do tipo ReLU – do inglês *Rectified Linear Unit* nas HLs, e do tipo *Sigmoid* na camada de saída. Para todas as arquiteturas o treinamento se deu em 200 épocas.

Elas diferem quanto ao número de neurônios na HL, bem como em relação à quantidade destas camadas, conforme Tabela 1.

Arquitetura	Nº Neurônios na HL 1	Nº Neurônios na HL 2	Nº Neurônios na HL 3
ARQ 1	20	-	-
ARQ 2	20	20	-
ARQ 3	20	20	20
ARQ 4	40	-	-
ARQ 5	40	40	-
ARQ 6	40	40	40
ARQ 7	60	-	-
ARQ 8	60	60	-
ARQ 9	60	60	60

Tabela 1. Arquiteturas das redes implementadas.

3.3 Métricas de desempenho

Foram realizados 10 testes para cada arquitetura implementada. Para quantificar a performance de predição da cada arquitetura testada, foram utilizados quatro métricas, sendo elas: *Acurácia* (A_{cc}), *Precisão* (P), *Recall* e *F1 Score*. Tais métricas podem ser obtidas calculando

$$A_{cc} = \frac{VP_i + VN_i}{N_i} \quad (1)$$

$$P = \frac{VP_i}{VP_i+FP_i} \quad (2)$$

$$Recall = \frac{VP_i}{VP_i+FN_i} \quad (3)$$

$$F1\ Score = \frac{2 \times P \times Recall}{P + Recall} \quad (4)$$

onde, i é a i -ésima entrada; VP_i , VN_i , FP_i e FN_i , representam os verdadeiros positivos e negativos e falsos positivos e negativos, respectivamente; N_i é o total de amostras, dados obtidos a partir dos valores classificados pela rede, comparando com o “gabarito” dos dados.

3.4 Análise estatística

Para análise estatística, foram construídos *boxplots* para análise exploratória visual dos resultados obtidos para as métricas (*Acurácia*, *Precisão*, *Recall* e *F1 Score*). Para a construção dos *boxplots* foi utilizada a linguagem *Python*, com o auxílio das bibliotecas *pandas* e *matplotlib.pyplot*. O teste usado para verificar se há diferença estatisticamente significativa entre os resultados das métricas para cada arquitetura foi o teste não-paramétrico de *Kruskal-Wallis*, com um nível de significância de 0,05, utilizando os procedimentos *UNIVARIATE* e *NPARI1WAY* do software *SAS / STAT® 9.2 University Edition*.

4 | RESULTADOS E DISCUSSÃO

Usando 10 testes como base, calculou-se uma média para cada arquitetura para analisar se há possíveis diferenças estatisticamente significativas pelas distintas inicializações dos pesos da rede. Classificou-se o conjunto de dados de teste comparando com o resultado já conhecido do *dataset*, formando os respectivos *bloxpots* das métricas especificadas para cada uma das 9 arquiteturas. As Figuras 3, 4, 5 e 6 apresentam a análise exploratória visual para cada uma das métricas.

A Figura 3 apresenta uma a métrica *acurácia*. Pode-se observar *outliers* nas arquiteturas 3,4,5 e 6.




Figura 3: *Boxplot* da Acurácia.

A Figura 4 analisa a precisão, que é a proporção do número de classificações corretas para o número total de instâncias positivas previstas, ou seja, se a rede classificou como vinho tinto realmente era vinho tinto e se a rede classificou como vinho branco o que realmente era branco.

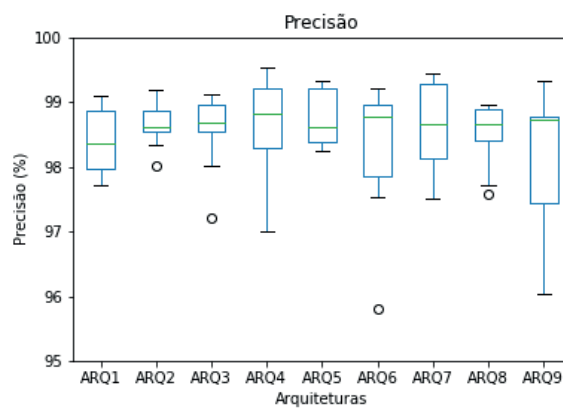


Figura 4: *Boxplot* da Precisão.

Na Figura 5 é ilustrado o *Recall*, que é a proporção do número de classificações corretas para o número total de instâncias positivas reais




Figura 5: *Boxplot* do Recall.

A Figura 6 retrata a *F1-score* que é a media harmônica entre precisão e recall, de modo a trazer um número único indicador da qualidade geral do seu modelo e trabalha bem até com conjuntos de dados de classes desproporcionais.




Figura 6: *Boxplot* do *F1 Score*.

Analisando as Fig. 3, 4, 5 e 6 nota-se que todas as arquiteturas testadas apresentaram métricas superiores a 95%. No entanto, pelos resultados do testes de *Kruskal-Wallis* fora revelado que não houve diferença estatisticamente significativa entre as arquiteturas, conforme descrito na Tabela 2.

Kruskal-Wallis	Acurácia	Precisão	Recall	<i>F1 Score</i>
χ^2	7,58	2,68	9,924	6,9389
p-value	0,4751	0,95	0,9983	0,5432

Tabela 2 - Resultados do teste de *Kruskal-Wallis*

De acordo com os valores de *p-value*, para todas as métricas analisadas, seu valor foi maior que o nível de significância 0,05 em todos os casos. Dessa forma, para o problema de classificação binária analisado, arquitetura de rede com uma HL e 20 neurônios (ARQ 1) apresenta desempenho estatisticamente igual quando utilizado uma rede com 3 HLs e 60 neurônios (ARQ 9). Sendo assim, pudemos observar que a análise visual dos *bloxplots* por si só não é suficiente para identificar se uma arquitetura é melhor que a outra, sendo necessário utilizar um teste estatístico como o de *Kruskall-Wallis*.

5 | CONCLUSÕES

Pelo teste estatístico de *Kruskal-Wallis* pode-se aferir que a diferença de desempenho entre as arquiteturas analisadas não é estatisticamente significativa (para um nível de significância de 5%). Neste sentido, considerando o problema de classificação binária avaliado, não há perdas significativas de desempenho ao

se utilizar arquiteturas com menos neurônios e camadas, resultando num relevante ganho computacional, visto que com o aumento da complexidade, maior é o custo computacional. Os resultados apresentados neste trabalho possibilitaram investigar, com rigor estatístico, o desempenho de arquiteturas de Redes *Deep Learning* na solução de problemas de classificação binária, contribuindo para construção de conhecimento e servindo de base para estudos relacionados ao conteúdo de *Deep Learning*. Como trabalhos futuros, propõe-se aplicar a metodologia a outros *benchmarks*, e com outras arquiteturas de redes.

AGRADECIMENTOS

H.M.F.S. agradece à Universidade Federal do Oeste do Pará (Bolsa PIBIC/UFOPA). M.T.M agradece ao apoio da CAPES e UFOPA. A.A.M.M. agradece à UFOPA (Edital PROPPIT - Apoio a Grupos de Pesquisa).

REFERÊNCIAS

Beltran, D. M.; Vicencio, S. B. (2008), "***Chilean Wine Classification Using Volatile Organic Compounds Data Obtained With a Fast GC Analyzer***".

IEEE Transactions on Instrumentation and Measurement, vol 57, 2421-2436. Bishop, C. M. (2006), "***Pattern Recognition and Machine Learning***", *Information Science and Statistics*. Springer-Verlag, Berlin.

Cortez, P.; Cerdeira, A.; Almeida, F.; Matos, T.; Reis, J. (2009), "***Modeling wine preferences by data mining from physicochemical properties***", *Decision Support Systems*, vol 47, 547-553.

de Freitas, G.C.S.; Peixoto, F.C.; Vianna Jr, A.S. (2008), "***Simulation of a thermal battery using Phoenics***". *Journal of Power Sources*, 179, 424-429. B .

Ebeler, S., (1999), "***Flavor Chemistry: Thirty Years of Progress***", Klumer Academic Publishers, 409-422.

Edwards, C. (2018), "***Deep Learning hunts for signals among the noise***". *Communications of the ACM*, vol 61 (6), 13-14.

Glorot, X.; Bengio, Y. (2010), "***Understanding the difficulty of training Deep feedforward neural networks***", *Proceedings of the Thirteenth International Conference on Artificial Intelligence and Statistics*, PMLR 9:249-256.

Goodfellow, I.; Bengio, Y.; Courville, A. (2016), "***Deep Learning***". MIT Press. Gupta, Y. (2018), "***Selection of important features and predicting wine quality using machine Learning techniques***", *Procedia Computer Science*, vol 125, 305-312.

Haykin, S. (2008), "***Neural Networks and Learning Machines***" 3rd Edition, *Prentice Hall*.

Lecun, Y., Bengio, Y., Hinton, G. (2015), "***Deep Learning***". *Nature*, 521 (7553), 436-444.

Legin, A., Rudnitskaya, A., Lvova, L., Vlasov, Y., Di Natale, C., D'Amico, A., (2003), "***Evaluation of Italian wine by the electronic tongue: recognition, quantitative analysis and correlation with***

human sensory perception", *Analytica Chimica Acta*, 484 (1), 33-44.

Nielsen, M. A. (2015), "**Neural Networks and Deep Learning**". Determination Press.

Rich, E.; Knight, K. (1991), "**Artificial Intelligence**", McGraw-Hill.

Sun, L.X.; Danzer, K.; Thiel, G. (1997), "**Classification of wine samples by means of artificial neural networks and discrimination analytical methods**", *Fresenius Journal of Analytical Chemistry*, vol 359 (2), 143–149.

Witten, I. H.; Frank, E. (2005), "**Data Mining: Practical Machine Learning Tools and Techniques with Java Implementations**", 2º ed., Morgan Kaufmann, San Francisco".

Gulli, Antonio;Pal, Sujit (2017) ,"**Deep Learning with Keras**".

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 tratos 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

Agricultura 30, 38, 42, 43, 44, 45, 46, 52, 53, 56, 57, 77, 106, 110, 112, 141, 280, 281, 286, 287, 289, 333, 408

Agricultura de precisão 56, 289

Astrobiologia 116, 117, 118, 119, 121, 122, 123, 124

Atividade fotocatalítica 301

B

Bagaço de cana 64, 230, 233

C

Campo magnético estático 77, 83

Catalisador ácido sólido 157, 159

Celulose 65, 230, 231, 232, 233, 234, 235, 236

Compostos fenólicos 36, 385, 386, 387, 393, 394

Copolímeros 339, 340, 341, 342, 343, 344

Cromatografia 96, 97, 100, 105, 233, 234, 387, 399

D

Desenvolvimento tecnológico 373

E

Educação 1, 11, 25, 28, 30, 35, 37, 39, 41, 49, 50, 51, 52, 106, 107, 108, 109, 114, 115, 116, 117, 119, 120, 121, 122, 123, 124, 126, 137, 148, 149, 152, 153, 154, 155, 156, 168, 169, 177, 178, 179, 245, 246, 260, 261, 262, 263, 268, 290, 291, 325, 327, 328, 329, 337, 338, 356, 357, 358, 360, 361, 362, 363, 364, 365, 366, 369, 370, 371, 372, 373, 374, 375, 376, 377, 378, 380, 381, 382, 383, 384

Eletroforese 96, 97, 102

Energia solar 347, 348, 349, 350, 354, 355

Ensino de matemática 51, 114

Estratégias regionais de inovação 20, 21

G

Geotecnologias 52, 53, 56, 57

H

Hidrólise 96, 230, 231, 232, 233, 234, 235, 236

I

Íons metálicos 62, 64, 65, 69, 400

M

Metátese 339, 340, 341, 346

Minigeração 347, 349, 350, 354, 355

N

Nanopartículas 186

Norborneno 339, 340, 341

O

Oxidação seletiva de metanol 397, 399

P

Planejamento territorial 52, 53, 55

Planetário 116, 117, 118, 119, 122, 148, 149, 150, 151, 152, 153, 154, 155

Poliméricas 157, 159, 161, 163, 183, 188

R

Resina polimérica 157, 159, 160, 163, 164

S

Saber popular 1, 3, 4

Agência Brasileira do ISBN
ISBN 978-85-7247-621-8

