

**NELSON DE SOUZA AMORIM  
FERNANDO MANUEL ARAÚJO MOREIRA  
CARLOS CÉLIO SOUSA DA CRUZ  
UBIRAEALSON DE LIMA RUELA  
PAULA RENATHA NUNES DA SILVA  
JOSÉ ROBERTO BRANCO RAMOS FILHO  
VICENTE MOREIRA RODRIGUES  
THIAGO AUGUSTO DE SOUSA MOREIRA  
GILSON FERNANDES BRAGA JUNIOR  
ESTEFANY COUTO MILÉO  
(ORGANIZADORES)**

# **ANAIS DO XIV SIMPÓSIO BRASILEIRO DE ENGENHARIA FÍSICA**



**Atena**  
Editora

Ano 2020

**NELSON DE SOUZA AMORIM  
FERNANDO MANUEL ARAÚJO MOREIRA  
CARLOS CÉLIO SOUSA DA CRUZ  
UBIRAEALSON DE LIMA RUELA  
PAULA RENATHA NUNES DA SILVA  
JOSÉ ROBERTO BRANCO RAMOS FILHO  
VICENTE MOREIRA RODRIGUES  
THIAGO AUGUSTO DE SOUSA MOREIRA  
GILSON FERNANDES BRAGA JUNIOR  
ESTEFANY COUTO MILÉO  
(ORGANIZADORES)**

# **ANAIS DO XIV SIMPÓSIO BRASILEIRO DE ENGENHARIA FÍSICA**



**Atena**  
Editora

Ano 2020

2020 by Atena Editora

Copyright © Atena Editora

Copyright do Texto © 2020 Os autores

Copyright da Edição © 2020 Atena Editora

**Editora Chefe:** Profª Drª Antonella Carvalho de Oliveira

**Diagramação:** Geraldo Alves

**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. Carlos Antonio de Souza Moraes – Universidade Federal Fluminense

Prof. Dr. Constantino Ribeiro de Oliveira Junior – Universidade Estadual de Ponta Grossa

Profª Drª Cristina Gaio – Universidade de Lisboa

Profª Drª Denise Rocha – Universidade Federal do Ceará

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 Internazionale delle Figlie di 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. William Cleber Domingues Silva – Universidade Federal Rural do Rio de Janeiro

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  
Prof. Dr. Fágner Cavalcante Patrocínio dos Santos – Universidade Federal do Ceará  
Profª Drª Girlene Santos de Souza – Universidade Federal do Recôncavo da Bahia  
Prof. Dr. Júlio César Ribeiro – Universidade Federal Rural do Rio de Janeiro  
Profª Drª Lina Raquel Santos Araújo – Universidade Estadual do Ceará  
Prof. Dr. Pedro Manuel Villa – Universidade Federal de Viçosa  
Profª Drª Raissa Rachel Salustriano da Silva Matos – Universidade Federal do Maranhão  
Prof. Dr. Ronilson Freitas de Souza – Universidade do Estado do Pará  
Profª Drª Talita de Santos Matos – Universidade Federal Rural do Rio de Janeiro  
Prof. Dr. Tiago da Silva Teófilo – Universidade Federal Rural do Semi-Árido  
Prof. Dr. Valdemar Antonio Paffaro Junior – Universidade Federal de Alfenas

### **Ciências Biológicas e da Saúde**

Prof. Dr. André Ribeiro da Silva – Universidade de Brasília  
Profª Drª Anelise Levay Murari – Universidade Federal de Pelotas  
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 Eleuza Rodrigues Machado – Faculdade Anhanguera de Brasília  
Profª Drª Elane Schwinden Prudêncio – Universidade Federal de Santa Catarina  
Prof. Dr. Ferlando Lima Santos – Universidade Federal do Recôncavo da Bahia  
Prof. Dr. Gianfábio Pimentel Franco – Universidade Federal de Santa Maria  
Prof. Dr. Igor Luiz Vieira de Lima Santos – Universidade Federal de Campina Grande  
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 Mylena Andréa Oliveira Torres – Universidade Ceuma  
Profª Drª Natiéli Piovesan – Instituto Federaci do Rio Grande do Norte  
Prof. Dr. Paulo Inada – Universidade Estadual de Maringá  
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  
Prof. Dr. Carlos Eduardo Sanches de Andrade – Universidade Federal de Goiás  
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  
Prof. Dr. Marcelo Marques – Universidade Estadual de Maringá  
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

### **Conselho Técnico Científico**

Prof. Msc. Abrãao Carvalho Nogueira – Universidade Federal do Espírito Santo  
Prof. Msc. Adalberto Zorzo – Centro Estadual de Educação Tecnológica Paula Souza  
Prof. Dr. Adailson Wagner Sousa de Vasconcelos – Ordem dos Advogados do Brasil/Seccional Paraíba  
Prof. Msc. André Flávio Gonçalves Silva – Universidade Federal do Maranhão  
Profª Drª Andreza Lopes – Instituto de Pesquisa e Desenvolvimento Acadêmico  
Profª Msc. Bianca Camargo Martins – UniCesumar  
Prof. Msc. Carlos Antônio dos Santos – Universidade Federal Rural do Rio de Janeiro  
Prof. Msc. Cláudia de Araújo Marques – Faculdade de Música do Espírito Santo  
Prof. Msc. Daniel da Silva Miranda – Universidade Federal do Pará  
Profª Msc. Dayane de Melo Barros – Universidade Federal de Pernambuco

Prof. Dr. Edwaldo Costa – Marinha do Brasil  
 Prof. Msc. Eliel Constantino da Silva – Universidade Estadual Paulista Júlio de Mesquita  
 Prof. Msc. Gevair Campos – Instituto Mineiro de Agropecuária  
 Prof. Msc. Guilherme Renato Gomes – Universidade Norte do Paraná  
 Prof<sup>a</sup> Msc. Jaqueline Oliveira Rezende – Universidade Federal de Uberlândia  
 Prof. Msc. José Messias Ribeiro Júnior – Instituto Federal de Educação Tecnológica de Pernambuco  
 Prof. Msc. Leonardo Tullio – Universidade Estadual de Ponta Grossa  
 Prof<sup>a</sup> Msc. Lilian Coelho de Freitas – Instituto Federal do Pará  
 Prof<sup>a</sup> Msc. Liliani Aparecida Sereno Fontes de Medeiros – Consórcio CEDERJ  
 Prof<sup>a</sup> Dr<sup>a</sup> Lívia do Carmo Silva – Universidade Federal de Goiás  
 Prof. Msc. Luis Henrique Almeida Castro – Universidade Federal da Grande Dourados  
 Prof. Msc. Luan Vinicius Bernardelli – Universidade Estadual de Maringá  
 Prof. Msc. Rafael Henrique Silva – Hospital Universitário da Universidade Federal da Grande Dourados  
 Prof<sup>a</sup> Msc. Renata Luciane Polsaque Young Blood – UniSecal  
 Prof<sup>a</sup> Msc. Solange Aparecida de Souza Monteiro – Instituto Federal de São Paulo  
 Prof. Dr. Welleson Feitosa Gazel – Universidade Paulista

| <b>Dados Internacionais de Catalogação na Publicação (CIP)<br/>(eDOC BRASIL, Belo Horizonte/MG)</b> |  |
|---|--|
| S612a   | <p>           Simpósio Brasileiro de Engenharia Física (14 : 2019 : Santarém)<br/>           Anais [...] / XIV Simpósio Brasileiro de Engenharia Física, 23-25<br/>           outubro 2019, Santarém, PA; organizadores Nelson de Souza<br/>           Amorim... [et al.]. – Ponta Grossa, PR: Atena, 2020.         </p> <p>           Formato: PDF<br/>           Requisitos de sistema: Adobe Acrobat Reader<br/>           Modo de acesso: World Wide Web<br/>           ISBN 978-65-86002-15-7<br/>           DOI 10.22533/at.ed.157200203         </p> <p>           1. Engenharia física – Congressos. I. Título.         </p> <p style="text-align: right;">CDD 573.724</p> |
| <b>Elaborado por Maurício Amormino Júnior – CRB6/2422</b>   |  |

Atena Editora  
 Ponta Grossa – Paraná - Brasil  
[www.atenaeditora.com.br](http://www.atenaeditora.com.br)  
[contato@atenaeditora.com.br](mailto:contato@atenaeditora.com.br)

## APRESENTAÇÃO

O curso de Engenharia Física da Universidade Federal de São Carlos foi criado no ano 1999 e foi pioneiro nesta área no Brasil. No ano de 2019, o curso de engenharia física no Brasil completou 20 anos. Nesse contexto, a Universidade Federal de São Carlos (UFSCar) e a Universidade Federal do Oeste do Pará (UFOPa) promoveram o XIV Simpósio Brasileiro de Engenharia Física que foi realizado na cidade de Santarém-PA no período de 23 a 25 de Outubro de 2019 na Universidade Federal do Oeste do Pará – Campus Tapajós com o tema “Jubileu de 20 anos da Engenharia Física no Brasil”.

Com a proposta de promover o conhecimento científico e inovação tecnológica bem como a integração entre especialistas, docentes e discentes da área, foram discutidos os 20 anos de existência do curso no Brasil e o intercâmbio de informações técnicas-científicas através de minicursos e palestras relacionados as diferentes temáticas da Engenharia Física e suas perspectivas futuras.

A coleção Anais do XIV Simpósio Brasileiro de Engenharia Física é uma obra que tem como objetivo divulgar os diversos trabalhos que participaram do evento através de trabalhos acadêmicos que abordaram diferentes temas, tais como: termodinâmica, propriedades dielétricas de materiais, ciência dos dados e machine learning, internet das coisas, deep learning, processos oxidativos avançados, energia solar, gerenciamento de projetos, física quântica e automação. Deste modo a obra contribui para disseminar os resultados obtidos pelos acadêmicos e fortalecer a diversidade científica no país, de forma multidisciplinar.

Comitê Organizador

## SUMÁRIO

|  |           |
|--|-----------|
| <b>CAPÍTULO 1</b> .....  | <b>1</b>  |
| A IMPORTÂNCIA DO REALIMENTADOR NA EFICIÊNCIA DE UM CICLO DE RANKINE UTILIZANDO O EES   |           |
| Muller Gabriel da Silva Chaves<br>Carlos Eduardo Ribeiro Silva<br>Vitor Azevedo Pinto<br>Carlos Célio Sousa da Cruz                        |           |
| <b>DOI 10.22533/at.ed.1572002031</b>   |           |
| <b>CAPÍTULO 2</b> .....  | <b>11</b> |
| ANÁLISE TEÓRICA DAS PROPRIEDADES DIELÉTRICAS DA MACAÚBA ( <i>Acrocomia acuelata</i> )  |           |
| Alex Torres da Silva<br>Nelson de Souza Amorim   |           |
| <b>DOI 10.22533/at.ed.1572002032</b>   |           |
| <b>CAPÍTULO 3</b> .....  | <b>19</b> |
| APLICAÇÃO DE TÉCNICAS DE DATA SCIENCE E MACHINE LEARNING EM UM PROBLEMA DE CLASSIFICAÇÃO DE UM DATASET DE MARKETING BANCÁRIO               |           |
| Yasmin Braga Teixeira<br>João Vitor Rebelo Viana<br>Josecley Fialho Góes<br>Anderson Alvarenga de Moura Meneses                            |           |
| <b>DOI 10.22533/at.ed.1572002033</b>   |           |
| <b>CAPÍTULO 4</b> .....  | <b>28</b> |
| AQUISIÇÃO DE DADOS DO CONSUMO ELÉTRICO EM UMA EDIFICAÇÃO DA UFOPA UTILIZANDO CONCEITOS DE IOT  |           |
| Leonardo Paz Amoêdo<br>Dalton Felipe Silva Varão<br>João Elias Brasil Bentes Júnior<br>Anderson Alvarenga de Moura Meneses                 |           |
| <b>DOI 10.22533/at.ed.1572002034</b>   |           |
| <b>CAPÍTULO 5</b> .....  | <b>37</b> |
| DEEP LEARNING PARA REGRESSÃO DE POTÊNCIA ELÉTRICA DE UMA USINA DE ENERGIA DE CICLO COMBINADO   |           |
| Mauro Sérgio dos Santos Moura<br>Anderson Alvarenga de Moura Meneses   |           |
| <b>DOI 10.22533/at.ed.1572002035</b>   |           |
| <b>CAPÍTULO 6</b> .....  | <b>46</b> |
| DEGRADAÇÃO DE CORANTES EM MEIO AQUOSO EMPREGANDO DIÓXIDO DE TITÂNIO NA FORMA DE FILMES FINOS PREPARADOS SOBRE SUBSTRATO CERÂMICO COMERCIAL |           |
| Graziele Daiana Sena de Sousa<br>Adriano Cesar Rabelo  |           |
| <b>DOI 10.22533/at.ed.1572002036</b>   |           |

|   |            |
|---|------------|
| <b>CAPÍTULO 7</b> .....   | <b>59</b>  |
| FATORES CRÍTICOS QUE INTERFEREM NO GERENCIAMENTO DO TEMPO EM PROJETOS DE ENGENHARIA: ESTUDO DE CASO EM SANTARÉM – PA    |            |
| Raíssa Coelho Almeida<br>Kevin de Matos Costa   |            |
| <b>DOI 10.22533/at.ed.1572002037</b>  |            |
| <b>CAPÍTULO 8</b> .....   | <b>70</b>  |
| OBTENÇÃO DA EQUAÇÃO DE KLEIN-GORDON-FOCK EM COORDENADAS DO CONE DE LUZ  |            |
| Jorge Kysnney Santos Kamassury<br>Damião Pedro Meira Filho<br>Sérgio Antônio de Souza Farias<br>Natalie Von Paraski     |            |
| <b>DOI 10.22533/at.ed.1572002038</b>  |            |
| <b>CAPÍTULO 9</b> .....   | <b>83</b>  |
| RÁPIDO RECONHECIMENTO DE MODULAÇÕES ANALÓGICAS E DIGITAIS VIA REDES RESIDUAIS PROFUNDAS                                 |            |
| Jorge Kysnney Santos Kamassury<br>Vinícius Felipe de Oliveira da Silva  |            |
| <b>DOI 10.22533/at.ed.1572002039</b>  |            |
| <b>CAPÍTULO 10</b> .....  | <b>98</b>  |
| REVISÃO DE LITERATURA SOBRE A AUTOMAÇÃO NO ENSINO DE FÍSICA NO BRASIL   |            |
| Davi Henrique da Silva Pedroso<br>Gabriel Gonçalves da Silva<br>Gilson Fernandes Braga Junior                           |            |
| <b>DOI 10.22533/at.ed.15720020310</b>   |            |
| <b>CAPÍTULO 11</b> .....  | <b>109</b> |
| DIAGNÓSTICO DOS MICROSSISTEMAS DE ENERGIA SOLAR FOTOVOLTAICO INSTALADOS NAS COMUNIDADES RURAIS DO MUNICÍPIO DE SANTARÉM |            |
| Fabiane da Conceição Almeida<br>Manoel Roberval Pimentel Santos   |            |
| <b>DOI 10.22533/at.ed.15720020311</b>   |            |
| <b>SOBRE OS ORGANIZADORES</b> .....   | <b>119</b> |
| <b>ÍNDICE REMISSIVO</b> .....   | <b>121</b> |



## DEEP LEARNING PARA REGRESSÃO DE POTÊNCIA ELÉTRICA DE UMA USINA DE ENERGIA DE CICLO COMBINADO

Data de aceite: 27/01/2020

Data de submissão: 17/11/2019

### Mauro Sérgio dos Santos Moura

Universidade Federal do Oeste do Pará, Instituto de Engenharia e Geociências, Laboratório de Inteligência Computacional  
Santarém – Pará

<http://lattes.cnpq.br/8032432346264238>

### Anderson Alvarenga de Moura Meneses

Universidade Federal do Oeste do Pará, Instituto de Engenharia e Geociências, Laboratório de Inteligência Computacional  
Santarém – Pará

<http://lattes.cnpq.br/6272872215125680>

**RESUMO:** O uso da energia elétrica tornou-se vital ao ser humano e, em consequência, a análise dos meios de geração de energia também se mostra essencial. A previsão da potência elétrica de uma usina funcionando com carga total possui grande importância no que diz respeito a maximização de energia líquida gerada por horas disponíveis. Nas últimas décadas, houve um aumento expressivo no desenvolvimento e aplicação de modelos computacionais capazes de modelar, projetar e prever sistemas energéticos com grande eficiência. Uma usina de energia de ciclo combinado é constituída de turbinas a gás,

turbinas a vapor e geradores de vapor para recuperação de calor, a energia é gerada pelas turbinas que são combinadas em um ciclo e transferidas de uma a outra. *Deep Learning* (DL) é um tipo de aprendizado de máquina que visa treinar computadores para realização de tarefas humanas e dentre suas capacidades tem-se a possibilidade de se aplicar regressão. Tendo isso em vista, um modelo de rede neural foi desenvolvido e avaliado utilizando as métricas de *Mean Squared Error* (MSE) e coeficiente de determinação ( $R^2$ ), com o objetivo de fazer a regressão da Potência. Para isso, foi utilizado um conjunto de dados contidos em um repositório de dados da Universidade da Califórnia, os dados foram obtidos de uma Usina Elétrica de Ciclo Combinado. Por fim, os resultados obtidos foram em média 0,92 para  $R^2$  e 20,779 para MSE, o que demonstra uma boa modelagem do sistema com o uso de uma rede neural utilizando um framework de DL.

**PALAVRAS-CHAVE:** Energia, Potência Elétrica, Aprendizagem Profunda, Regressão.

### DEEP LEARNING FOR REGRESSION OF ELECTRICAL POWER FROM A COMBINED CYCLE POWER PLANT

**ABSTRACT:** The use of electric energy has become vital to the human being and, consequently, the analysis of the means of energy

generation is also essential. Thus, the prediction of the electric power of a power plant operating at full load is of great importance with regard to the maximization of available energy by hours. In the last decades, there has been an expressive increase in the development and application of computational models capable of modeling, designing and predicting energy systems with great efficiency. A combined cycle power plant is composed of gas turbines, steam turbines and heat recovery steam generators, the turbines are combined in one cycle and transferred from one to another generating the energy. Deep Learning (DL) is a type of machine learning that aims to train computers to perform human tasks and among its capabilities one has the possibility of applying regression. Based on this, a neural network model was developed and evaluated using Mean Squared Error (MSE) and coefficient of determination ( $R^2$ ) metrics, in order to perform the regression of electric energy variable by hour net. For this, a dataset contained in a University of California data repository was used, the data were obtained from a Combined Cycle Power Plant. Finally, the obtained results were on average 0.92 for  $R^2$  and 20,779 for MSE, which demonstrates a good modeling of the system with the use of a neural network using a DL framework.

**KEYWORDS:** Energy, Electric Power, Deep Learning, Regression.

## 1 | INTRODUÇÃO

Usinas Elétricas de Ciclo Combinado (CCPP, do inglês *Combyned Cycle Power Plant*) têm se tornado cada vez mais relevantes nas últimas décadas, devido a flexibilidade das estruturas para fornecer uma grande faixa de potência e energia térmica (Branco, 2005). Uma das variáveis importantes dentro do estudo de CCPP é a saída de energia por hora (Potência). Assim, é possível obter dados ambientais a partir de sensores e por estes realizar tarefas como regressão para conseguir valores de saída e energia.

Em relação ao uso de dados de CCPP para predição de valores de saída de energia, em (Tüfekci, 2014) é feita uma análise de diversas técnicas de *Machine Learning* (ML) utilizando um *dataset* coletado durante 6 anos em uma CCPP. Além disso, em (Kaya, Tüfekci e Gürgen, 2012) há uma análise do mesmo *dataset* mais abrangente utilizando diversos tipos de Redes Neurais Artificiais (RNAs), realizando comparações entre modelos convencionais de regressão, *feedforward* e clusterização, nesse caso foi observado que utilizando tipos sofisticados de pré-processamento há melhora na performance da RNA. Sendo assim, pode-se observar que RNAs têm grande relevância para a predição de dados da saída de energia em CCPP.

*Deep Learning* (DL) é uma área que, nos últimos anos apresenta grande potencial para resoluções de problemas de Aprendizado de Máquina. Sendo capaz de resolver problemas de classificação e regressão com alto nível de adaptação aos dados, assim como utilizá-la para grandes quantidades de dados. DL é uma

subárea de ML, que por sua vez é uma subárea de Inteligência Artificial. A grande diferença de DL dentre as técnicas de ML é a presença de várias camadas ocultas, que atualmente podem ultrapassar cem camadas consecutivas (Chollet, 2018). Com isso houve grandes melhoras em diversas áreas do conhecimento que necessitam de técnicas de ML para resolução.

Desse modo é possível aplicar DL nos mesmo dados da CCPP, juntamente de um pré-processamento para realizar a predição com melhor adaptação, criando a oportunidade de aplicação em outros tipos de dados.

Esse trabalho segue a seguinte estrutura: na Seção 2 são abordados os conceitos principais básicos para a compreensão do trabalho. Na seção 3 são apresentados os passos seguidos para a implementação da RNA. A seção 4 apresenta os resultados. Por fim, na seção 5 as conclusões são abordadas.

## **2 | REFERENCIAL TEÓRICO**

### **2.1 Usinas Elétricas de Ciclo Combinado**

Uma usina termelétrica, pode trabalhar em ciclo aberto ou ciclo combinado, sendo o ciclo aberto o funcionamento somente com uma turbina operando e ciclo combinado, também chamado de ciclo combinado de gás e vapor, onde turbinas de gás e vapor trabalham em conjunto (Çengel e Boles, 2011). Como o nome sugere, uma CCPP funciona baseada na combinação das tecnologias de produção de energia baseadas em turbinas a gás e a vapor associadas na mesma planta, ou seja, ambas as turbinas utilizam o mesmo combustível para gerar energia (Branco, 2005).

Variáveis como Temperatura Ambiente, Pressão Atmosférica e Humidade Relativa são conhecidas como fatores principais durante estudos para predição de geração de energia de uma usina de ciclo combinado (Kaya, Tüfekci e Gürgen, 2012), já que as turbinas dependem das variáveis ambientais.

Um modelo simples de CCPP com apenas uma turbina de gás, uma turbina a vapor e um sistema de recuperação de calor, pode ser encontrado em (“GasNet - site de gás natural e GNV”), a Fig. 1 representa uma adaptação desse modelo, na forma de uma exemplificação esquemática simplificada de como funciona uma CCPP.

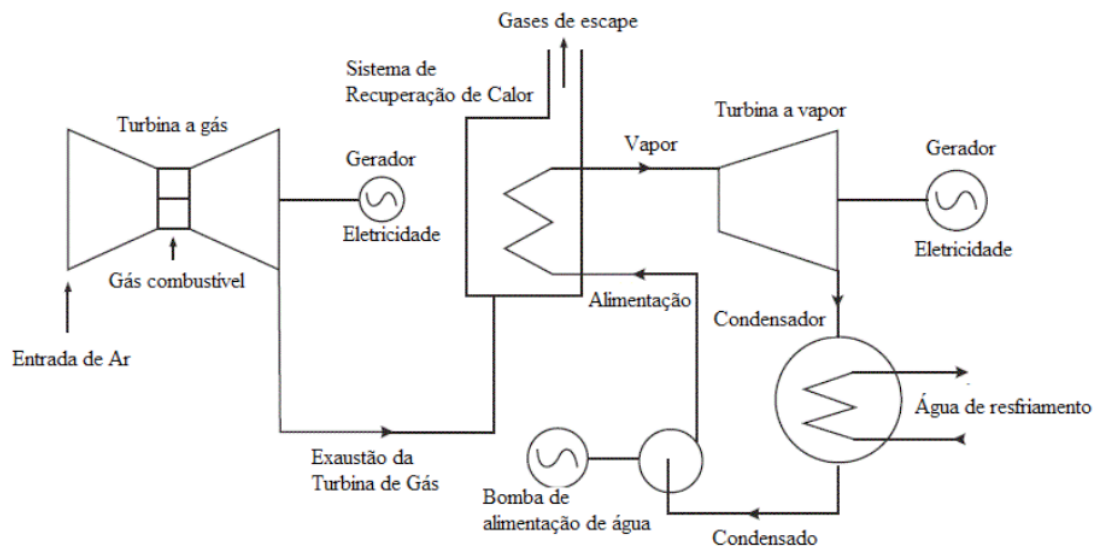


Fig. 1: Modelo adaptado de (GasNet) de uma CCPP simples. Fonte: O Autor.

## 2.2 MultiLayer Perceptron

Um modelo de RNA bastante utilizado dentro da área de DL é o Multilayer Perceptron (MLP), que consiste em uma RNA semelhante ao modelo perceptron com mais de uma camada de neurônios, o que possibilita resoluções de problemas não lineares. Esse modelo é composto por camadas de neurônios ligadas entre si utilizando funções de soma e ativação para determinar quando o neurônio ativar. O aprendizado nesse tipo de RNA é geralmente feito através do algoritmo de retro-propagação de erro (Haykin, 2005). O processo de treinamento e atualização dos pesos, realizado nas camadas ocultas, não é visível para o usuário, assim, é possível observar somente as entradas e as saídas da rede.

Ajustes podem ser feitos no modelo MLP para se obter melhores resultados, tais ajustes envolvem alteração da taxa de aprendizado, número de camadas, quantidade de neurônios, tipo de função de perda e ativação, número de épocas, dentre outros.

## 3 | METODOLOGIA

A linguagem de programação utilizada foi Python 3.5 com a IDE Spyder, com o auxílio das bibliotecas Keras, Pandas, Scikit-learn, dentre outras. A biblioteca Pandas foi utilizada para carregamento dos dados para o programa, o Keras foi utilizado para desenvolvimento do modelo de RNA MLP e o Scikit-learn foi utilizado para implementação das métricas.

### 3.1 Conjunto de Dados

O conjunto de dados está disponível no site UCI *Machine Learning* (<https://>

archive.ics.uci.edu) e consiste em dados coletados de uma CCPP durante 6 anos (2006-2011), quando a usina estava funcionando com carga total. O número de amostras consiste em 9568 instancias ambientais médias por hora.

A CCPP de onde foram coletados os dados, consiste em duas turbinas de gás, uma turbina de vapor e dois sistemas de recuperação de calor (Tüfekci, 2014).

A descrição dos dados com os nomes das variáveis, range, assim como unidade de medida do *dataset*, são apresentados na Tabela 1.

| Variável  | Range                      |
|---|----------------------------|
| Temperatura Ambiente                                  | 1.81°C até 37.11°C         |
| Pressão Atmosférica                                   | 992.89 até 1033.30 milibar |
| Humidade Relativa                                     | 22.56% até 100.16%         |
| Vácuo de Exaustão (Pressão)                           | 25.36 até 81.56 cm Hg      |
| Saída de Energia Elétrica líquida por hora (Potência) | 420.26 até 495.76 MW       |

Tabela 1: Variáveis do *Dataset*

Fonte: O Autor.

Como pode ser observado na Tabela 1, os recursos do *dataset* apresentam escalas diferentes, que quando analisadas fisicamente não podem ser comparadas, mas ao serem aplicadas em uma RNA, podem causar desvio no resultado. Sendo assim necessário um pré-processamento nos dados.

## 3.2 Implementação do Rede Neural Profunda

O processo de implementação da rede neural consiste em realizar um pré-processamento para normalização dos dados antes de serem submetidos as camadas de entrada. As entradas são repassadas para as camadas ocultas, onde os pesos são calculados, e por fim, os pesos calculados são repassados para as camadas de saída, onde é submetido a uma função de ativação que vai determinar a saída.

### 3.2.1 Pré-processamento

Antes da utilização do *dataset* na RNA, foi realizado um pré-processamento, aplicando a função *MinMaxScaler* da biblioteca *Scikit-learn* nos preditores, com o objetivo de redimensionar os valores para um mesmo intervalo.

### 3.2.2 Estrutura da Rede Neural

A estrutura da RNA consiste em um modelo MLP criado utilizando a biblioteca *Keras*, com uma camada de entrada (representada pelos neurônios X1, X2, X3,

X4), 3 camadas ocultas com função de ativação ReLU, e uma camada de saída (representada por Y1) com função de ativação Linear. O modelo foi compilado utilizando a função de perda como *Mean Squared Error* (MSE) e otimizador Adam. O número de neurônios e funções de perda e ativação foram definidos empiricamente a partir de testes. A Fig. 2 representa o modelo MLP da RNA criada.




Fig. 2: Estrutura da Rede Neural.

Fonte: O Autor.

### 3.2.3 Treinamento da Rede Neural

Os parâmetros de treinamento da rede neural foram determinados empiricamente, sendo eles 300 épocas e um *batch size* de 128, porém foram adicionados métodos de incrementação à taxa de aprendizado e de encerrar o processo de treinamento, caso a rede neural não apresente melhoras de métricas entre as épocas.

Para garantir a reprodutibilidade dos resultados a RNA foi realizado um teste com a metodologia da validação cruzada (Kohavi, 1995) utilizando o tempo como semente, executando 10 vezes a RNA e os resultados das métricas para cada execução foram salvos para análise futura.

### 3.2.4 Métricas

As métricas utilizadas para avaliação dos resultados da RNA foram MSE, *Root Mean Squared Error* (RMSE), Coeficiente de Determinação ( $R^2$ ) e *Mean Average Error* (MAE), as implementações foram feitas a partir da biblioteca Scikit-learn. As equações das métricas são descritas a seguir Eq. (1 a 4).

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (1)$$

$$RMSE = \sqrt{MSE} \quad (2)$$

$$R^2 = 1 - \frac{\sum_i^n (y_i - \hat{y}_i)^2}{\sum_i^n (y_i - \bar{y})^2} \quad (3)$$

$$MAE = \frac{\sum_{i=1}^n |y_i - x_i|}{n} \quad (4)$$

Vale ressaltar que as métricas RMSE e  $R^2$  são as métricas mais utilizadas para a análise e comparação dos resultados, sendo RMSE a raiz quadrada da média dos erros quadrados da regressão e  $R^2$  a proporção de adequação do modelo, sendo entre 0 a 1 (Bruce e Bruce, 2017). As demais métricas são utilizadas para confirmar os resultados obtidos. Além do mais, o coeficiente de variação (CV) será utilizado como avaliação dos resultados, o mesmo consiste na razão do desvio padrão pela média. Quanto menor o CV, maior a precisão dos dados.

### 3.3 Hardware

O hardware utilizado consiste em um desktop HP EliteDesk 800 G3 SFF com um processador Intel core i7 6700, 16 GB de RAM e uma GPU Nvidia Gt730 com 2 GB de memória de vídeo GDDR5.

## 4 | RESULTADOS E DISCUSSÕES

A Tabela 2 mostra os resultados da RNA ao utilizar a validação cruzada. Os dados estão descritos, com o número de vezes que a RNA foi executada, média das métricas, desvio padrão, valor mínimo e máximo atingidos pelas métricas e coeficiente de variação.

|                      | MSE    | RMSE  | R2    | MAE   |
|----------------------|--------|-------|-------|-------|
| <b>Contagem</b>      | 10     | 10    | 10    | 10    |
| <b>Média</b>         | 20,779 | 4,556 | 0,929 | 3,627 |
| <b>Desvio Padrão</b> | 1,272  | 0,139 | 0,005 | 0,065 |
| <b>Mínimo</b>        | 19,294 | 4,393 | 0,918 | 3,516 |
| <b>Máximo</b>        | 22,529 | 4,746 | 0,936 | 3,770 |
| <b>CV</b>            | 0,061  | 0,031 | 0,005 | 0,018 |

Tabela 2: Resultados de estatística descritiva do conjunto de dados

Fonte: O Autor.

Em (Tüfekci, 2014) é feita uma análise utilizando o mesmo *dataset* da CCPP com técnicas de ML, a métrica utilizada para avaliação, em comum com análise feita neste, foi RMSE. Os resultados no melhor dos casos foi de 3,787, que quando

comparado aos resultados obtidos pela RNA, é observada uma diferença de 0,769. Ainda em (Tüfekci, 2014), uma análise utilizando o modelo MLP foi realizada, onde foi obtido um valor de 5,399, com isso podemos ver uma diferença de 0,843. Quando a RNA é comparada aos resultados de (Tüfekci, 2014), a diferença é pequena, sendo menor que 1. Nesse caso, uma análise estatística deve ser feita para verificar se há diferença significativa ou não desses resultados. Considerando o objetivo da RNA como análise introdutória para futuras aplicações, temos que a diferença entre os resultados do modelo utilizado e a referência apresentou-se menor que 1, que nesse caso, significou uma boa robustez.

Observando a Tabela 2, a RNA profunda conseguiu valores abaixo de 0,07 para CV em todas as métricas, o que indica boa precisão dos resultados, como esperado, já que os erros são próximos de 0 e  $R^2$  próximo de 1.

## 5 | CONCLUSÃO

Uma RNA profunda foi desenvolvida utilizando DL com a linguagem de programação Python para regressão de valores de saída de energia elétrica de uma CCPP. A RNA é capaz de realizar a regressão com valores de  $R^2$  com média de 0,929, o que representa boa adaptação da rede aos dados fornecidos. Futuramente, é possível realizar estudos utilizando técnicas como *Grid Search* para encontrar parâmetros que possam ser otimizados na rede neural, possibilitando a obtenção de melhores resultados, assim como testes estatísticos para verificar a robustez do modelo.

## AGRADECIMENTOS

Esse trabalho foi parcialmente financiado pelo Banco da Amazônia S.A. (projeto “Sistema para monitoramento de energia usando Internet das Coisas, Big Data e Machine Learning). O autor M. S. S. M. agradece à UFOPA pelo apoio financeiro.

## REFERÊNCIAS

BRANCO, F. P. **Thermoeconomical analysis of plant fueled by natural gas operating in combined and opened cycle (in Portuguese)**. Dissertação (Dissertação em Engenharia Mecânica). UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA FILHO”, 2005.

BRUCE, P.; BRUCE, A. **Practical Statistics for Data Scientists**. O’Reilly Media, Inc., 2017.

ÇENGEL, Y. A.; BOLES, M. A. **Thermodynamics: An Engineering Approach**. 7th Editio ed. New York: MacGraw-Hill, 2011.

CHOLLET, F. **Deep Learning with Phyton**. Maning Publications Co., 2018.



GasNet. **GasNet - site de gás natural e GNV**. Disponível em: <<https://www.gasnet.com.br/termetricas/ciclo.asp>>. Acesso em: 9 de agosto de 2019.

HAYKIN, S. **Neural Networks - A Comprehensive Foundation**. Peason Prentice Hall, 2005.

KAYA, H.; TÜFEKCI, P.; GÜRGEN, S. F. **Local and Global Learning Methods for Predicting Power of a Combined Gas & Steam Turbine**. International Conference on Emerging Trends in Computer and Electronics Engineering (ICETCEE 2012), p. 13–18, 2012.

KOHAVI, R. **A study of cross-validation and bootstrap for accuracy estimation and model selection**. Proceedings of the Fourteenth International Joint Conference on Artificial Intelligence. International Conference on Emerging Trends in Computer and Electronics Engineering (ICETCEE 2012), v. 2, p. 7, 1995.

TÜFEKCI, P. **Prediction of full load electrical power output of a base load operated combined cycle power plant using machine learning methods**. International Journal of Electrical Power and Energy Systems, v. 60, p. 126–140, 2014.

## ÍNDICE REMISSIVO

### A

Acompanhamento do consumo 28, 30  
Aprendizado de máquina 19, 20, 21, 22, 37, 38, 83  
Aprendizagem profunda 37

### C

Campo eletromagnético clássico 70, 72, 79, 81  
Ciclo de rankine 1, 4  
Ciência de dados 19, 20  
Comunidades rurais 109, 110  
Constante dielétrica 11, 12, 13, 14, 15, 17  
Coordenadas do cone de luz 70, 71, 72, 74, 75, 76, 77, 78, 79, 81  
Cronogramas 59, 60, 61, 62, 67

### E

Ees 1, 2, 4, 5, 9  
Eficiência 1, 2, 4, 6, 7, 8, 9, 28, 29, 30, 31, 33, 35, 36, 37, 46, 50, 56, 84, 111, 115, 119  
Eficiência energética 28, 29, 30, 31, 33, 35, 36, 119  
Energia 2, 3, 4, 5, 6, 8, 11, 12, 26, 28, 29, 30, 31, 32, 33, 34, 35, 36, 37, 38, 39, 41, 44, 49, 50, 75, 109, 110, 111, 112, 116, 117, 118, 119, 120  
Energia elétrica 2, 3, 28, 29, 36, 37, 41, 44, 109, 110, 111, 117, 120  
Energia solar 109, 110, 111, 117  
Engenharia 7, 10, 11, 18, 36, 37, 44, 46, 58, 59, 62, 69, 103, 107, 108, 117, 119, 120  
Ensino-aprendizado 98  
Equação de klein-gordon-fock 70  
Experimento 98, 100, 102, 104, 107

### F

Falhas 61, 109, 115, 116, 117, 119  
Fator de perda 11, 12, 13, 15, 16, 17  
Filmes finos 46, 50, 51  
Fotocatálise heterogênea 46, 47, 48

### G

Gerenciamento 28, 29, 33, 59, 60, 61, 62, 63, 68, 69

### I

Interdisciplinaridade 98, 102, 103, 106  
Internet das coisas 26, 28, 30, 36, 44

## **K**

K-nearest neighbors 19, 20, 21

## **M**

Macaúba 11, 12, 13, 17, 18

Marketing bancário 19

Ms project 63

## **P**

Potência elétrica 37

Processos oxidativos avançados 46, 47, 48, 57, 58

Projetos 30, 59, 60, 61, 62, 63, 67, 68, 69, 100, 103, 106, 120

Propriedades dielétricas 11, 12, 18

## **R**

Realimentador 1, 2, 3, 4, 6, 7, 8, 9

Reconhecimento automático de modulações 83

Redes neurais 19, 21, 25, 38, 83, 84, 85, 87

Regressão 20, 37, 38, 43, 44, 89

Resnet 89, 90, 91

## **S**

Substrato cerâmico 46

## **T**

Tecnologia 1, 29, 36, 56, 57, 69, 70, 84, 98, 99, 100, 104, 105, 106, 107, 117, 120

Tempo de treinamento 83, 85, 92, 94

Tratamento de águas residuais 46, 57

 **Atena**  
Editora

**2 0 2 0**