


HENRIQUE AJUZ HOLZMANN  
JOÃO DALLAMUTA  
MARCELO HENRIQUE GRANZA  
(ORGANIZADORES)

# A PRODUÇÃO DO CONHECIMENTO NA ENGENHARIA ELÉTRICA 2

**Atena**  
Editora  
Ano 2020



HENRIQUE AJUZ HOLZMANN  
JOÃO DALLAMUTA  
MARCELO HENRIQUE GRANZA  
(ORGANIZADORES)

# A PRODUÇÃO DO CONHECIMENTO NA ENGENHARIA ELÉTRICA 2

**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  
Profª Drª Angeli Rose do Nascimento – Universidade Federal do Estado do Rio de Janeiro  
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 de Maria Ausiliatrice  
Prof. Dr. Julio Candido de Meirelles Junior – Universidade Federal Fluminense  
Profª Drª Keyla Christina Almeida Portela – Instituto Federal de Educação, Ciência e Tecnologia de Mato Grosso  
Profª Drª Lina Maria Gonçalves – Universidade Federal do Tocantins  
Profª Drª Natiéli Piovesan – Instituto Federal do Rio Grande do Norte  
Prof. Dr. Marcelo Pereira da Silva – Universidade Federal do Maranhão  
Profª Drª Miranilde Oliveira Neves – Instituto de Educação, Ciência e Tecnologia do Pará  
Profª Drª Paola Andressa Scortegagna – Universidade Estadual de Ponta Grossa  
Profª Drª Rita de Cássia da Silva Oliveira – Universidade Estadual de Ponta Grossa  
Profª Drª Sandra Regina Gardacho Pietrobon – Universidade Estadual do Centro-Oeste  
Profª Drª Sheila Marta Carregosa Rocha – Universidade do Estado da Bahia  
Prof. Dr. Rui Maia Diamantino – Universidade Salvador  
Prof. Dr. Urandi João Rodrigues Junior – Universidade Federal do Oeste do Pará  
Profª Drª Vanessa Bordin Viera – Universidade Federal de Campina Grande  
Prof. Dr. 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. Fernando José Guedes da Silva Júnior – Universidade Federal do Piauí  
Profª Drª Gabriela Vieira do Amaral – Universidade de Vassouras  
Prof. Dr. Gianfábio Pimentel Franco – Universidade Federal de Santa Maria  
Profª Drª Iara Lúcia Tescarollo – Universidade São Francisco  
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 Renata Mendes de Freitas – Universidade Federal de Juiz de Fora  
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  
Profª Drª Luciana do Nascimento Mendes – Instituto Federal de Educação, Ciência e Tecnologia do Rio Grande do Norte  
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. Me. Abrãao Carvalho Nogueira – Universidade Federal do Espírito Santo  
Prof. Me. Adalberto Zorzo – Centro Estadual de Educação Tecnológica Paula Souza  
Prof. Dr. Adaylson Wagner Sousa de Vasconcelos – Ordem dos Advogados do Brasil/Seccional Paraíba  
Prof. Me. André Flávio Gonçalves Silva – Universidade Federal do Maranhão

Profª Drª Andreza Lopes – Instituto de Pesquisa e Desenvolvimento Acadêmico  
 Profª Drª Andrezza Miguel da Silva – Universidade Estadual do Sudoeste da Bahia  
 Prof. Dr. Antonio Hot Pereira de Faria – Polícia Militar de Minas Gerais  
 Profª Ma. Bianca Camargo Martins – UniCesumar  
 Profª Ma. Carolina Shimomura Nanya – Universidade Federal de São Carlos  
 Prof. Me. Carlos Antônio dos Santos – Universidade Federal Rural do Rio de Janeiro  
 Prof. Ma. Cláudia de Araújo Marques – Faculdade de Música do Espírito Santo  
 Prof. Me. Daniel da Silva Miranda – Universidade Federal do Pará  
 Profª Ma. Dayane de Melo Barros – Universidade Federal de Pernambuco  
 Prof. Me. Douglas Santos Mezacas -Universidade Estadual de Goiás  
 Prof. Dr. Edwaldo Costa – Marinha do Brasil  
 Prof. Me. Eliel Constantino da Silva – Universidade Estadual Paulista Júlio de Mesquita  
 Profª Ma. Fabiana Coelho Couto Rocha Corrêa – Centro Universitário Estácio Juiz de Fora  
 Prof. Me. Felipe da Costa Negrão – Universidade Federal do Amazonas  
 Profª Drª Germana Ponce de Leon Ramírez – Centro Universitário Adventista de São Paulo  
 Prof. Me. Gevair Campos – Instituto Mineiro de Agropecuária  
 Prof. Me. Guilherme Renato Gomes – Universidade Norte do Paraná  
 Profª Ma. Jaqueline Oliveira Rezende – Universidade Federal de Uberlândia  
 Prof. Me. Javier Antonio Albornoz – University of Miami and Miami Dade College  
 Profª Ma. Jéssica Verger Nardeli – Universidade Estadual Paulista Júlio de Mesquita Filho  
 Prof. Me. José Luiz Leonardo de Araujo Pimenta – Instituto Nacional de Investigación Agropecuaria Uruguay  
 Prof. Me. José Messias Ribeiro Júnior – Instituto Federal de Educação Tecnológica de Pernambuco  
 Profª Ma. Juliana Thaisa Rodrigues Pacheco – Universidade Estadual de Ponta Grossa  
 Prof. Me. Leonardo Tullio – Universidade Estadual de Ponta Grossa  
 Profª Ma. Lilian Coelho de Freitas – Instituto Federal do Pará  
 Profª Ma. Liliani Aparecida Sereno Fontes de Medeiros – Consórcio CEDERJ  
 Profª Drª Lívia do Carmo Silva – Universidade Federal de Goiás  
 Prof. Me. Luis Henrique Almeida Castro – Universidade Federal da Grande Dourados  
 Prof. Dr. Luan Vinicius Bernardelli – Universidade Estadual de Maringá  
 Profª Ma. Marileila Marques Toledo – Universidade Federal dos Vales do Jequitinhonha e Mucuri  
 Prof. Me. Rafael Henrique Silva – Hospital Universitário da Universidade Federal da Grande Dourados  
 Profª Ma. Renata Luciane Polsaque Young Blood – UniSecal  
 Profª Ma. Solange Aparecida de Souza Monteiro – Instituto Federal de São Paulo  
 Prof. Me. Tallys Newton Fernandes de Matos – Faculdade Regional Jaguaribana  
 Prof. Dr. Welleson Feitosa Gazel – Universidade Paulista

**Dados Internacionais de Catalogação na Publicação (CIP)  
(eDOC BRASIL, Belo Horizonte/MG)**

P964 A produção do conhecimento na engenharia elétrica 2 [recurso eletrônico] / Organizadores Henrique Ajuz Holzmann, João Dallamuta, Marcelo Henrique Granza. – Ponta Grossa, PR: Atena, 2020.

Formato: PDF  
 Requisitos de sistema: Adobe Acrobat Reader  
 Modo de acesso: World Wide Web  
 Inclui bibliografia  
 ISBN 978-65-86002-65-2  
 DOI 10.22533/at.ed.652202303

1. Engenharia elétrica – Pesquisa – Brasil. I. Holzmann, Henrique Ajuz. II. Dallamuta, João. III. Granza, Marcelo Henrique.  
 CDD 623.3

**Elaborado por Maurício Amormino Júnior – CRB6/2422**

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

## APRESENTAÇÃO

Não há padrões de desempenho em engenharia elétrica que sejam duradouros. Desde que Gordon E. Moore fez a sua clássica profecia tecnológica, em meados dos anos 60, a qual o número de transistores em um chip dobraria a cada 18 meses - padrão este válido até hoje – muita coisa mudou. Permanece porém a certeza de que não há tecnologia na engenharia elétrica que não possa ser substituída a qualquer momento por uma nova, oriunda de pesquisa científica nesta área.

Produzir conhecimento em engenharia elétrica é, portanto, atuar em fronteiras de padrões e técnicas de engenharia. Algo desafiador para pesquisadores e engenheiros de produto.

Neste livro temos uma diversidade de temas nas áreas níveis de profundidade e abordagens de pesquisa, envolvendo aspectos técnicos e científicos. Aos autores e editores, agradecemos pela confiança e espírito de parceria.

Boa leitura

Henrique Ajuz Holzmann  
João Dallamuta  
Marcelo Henrique Granza

## SUMÁRIO

<b>CAPÍTULO 1</b> .....	<b>1</b>
UTILIZAÇÃO DE MODELOS MATEMÁTICOS DE TURBINAS EÓLICAS EM AMBIENTE DE SIMULAÇÃO MATLAB/SIMULINK NA APRENDIZAGEM DE SISTEMAS DE CONTROLE	
Marcos José dos Santos Junior Vlademir Ap. Freire Junior Marcelo Henrique Granza João Luiz Dallamuta	
<b>DOI 10.22533/at.ed.6522023031</b>	
<b>CAPÍTULO 2</b> .....	<b>11</b>
RECONHECIMENTO DE DÍGITOS EM IMAGENS DE MEDIDORES DE ENERGIA NO CONTEXTO DE UM APLICATIVO DE AUTOLEITURA	
Arthur Costa Serra João Vitor Ferreira França Ricardo Costa da Silva Marques Wesley Kelson Ribeiro Figueredo Artur Bernardo Silva Reis Italo Francyles Santos da Silva Simara Vieira da Rocha Aristófanés Correa Silva Eliana Márcia Garros Monteiro Italo Fernandes Serra da Silva Marcia Izabel Alves da Silva José Messias dos Santos	
<b>DOI 10.22533/at.ed.6522023032</b>	
<b>CAPÍTULO 3</b> .....	<b>23</b>
O CONCEITO DE CASA INTELIGENTE APLICADO A PAÍSES DESENVOLVIDOS E EMERGENTES: BENEFÍCIOS, BARREIRAS E GRAU DE ADESÃO	
Florença Moraes da Silva Rosana Aparecida Ferreira Nunes	
<b>DOI 10.22533/at.ed.6522023033</b>	
<b>CAPÍTULO 4</b> .....	<b>36</b>
MODELAGEM DE UM SISTEMA DE DISTRIBUIÇÃO COM GERAÇÃO, UTILIZANDO ALGORITMO GENÉTICO	
Igor Ferreira Visconti	
<b>DOI 10.22533/at.ed.6522023034</b>	
<b>CAPÍTULO 5</b> .....	<b>49</b>
INSTRUMENTAÇÃO, CONTROLE E SUPERVISÃO DE UM ABRASÔMETRO TIPO RODA DE BORRACHA	
Périson Pavei Uggioni André Roberto de Sousa Anderson Daleffe Diego Tiburcio Fabre	
<b>DOI 10.22533/at.ed.6522023035</b>	

<b>CAPÍTULO 6</b> .....	<b>58</b>
DESENVOLVIMENTO DE UM MODELO FUZZY E ALGORITMOS DE APRENDIZADO PARA SEQUÊNCIA DE PARTIDA DE PLANTAS INDUSTRIAIS	
André da Silva Barcelos Fábio Muniz Mazzone	
<b>DOI 10.22533/at.ed.6522023036</b>	
<b>CAPÍTULO 7</b> .....	<b>72</b>
SIMULAÇÃO DE SINTONIZAÇÃO DE AUTOMÁTICA PARA UM CONTROLADOR PID EM UMA PLANTA NÃO-LINEAR USANDO ALGORITMO GENÉTICO	
Diogo Aparecido Cavalcante de Lima Hiago Araújo Silva Alexandre Carvalho Silva Maurício José Aureliano Júnior Alexandre Cardoso Edgard Afonso Lamounier Júnior	
<b>DOI 10.22533/at.ed.6522023037</b>	
<b>CAPÍTULO 8</b> .....	<b>82</b>
CONSTRUÇÃO E CONTROLE DE POSIÇÃO PARA UM ROBÔ PARALELO COM APLICAÇÃO NA INDÚSTRIA CONFECCIONISTA	
Asafe dos Santos Silva Acarcio Gomes de Almeida Júnior Alexander Patrick Chaves de Sena João Manoel Freitas Souza José Lucas Moreira Cavalcanti de Abreu	
<b>DOI 10.22533/at.ed.6522023038</b>	
<b>CAPÍTULO 9</b> .....	<b>95</b>
DESENVOLVIMENTO DE UMA ESTRUTURA DE CONTROLE HÍBRIDA PARA SISTEMAS DE REFRIGERAÇÃO DE ALTA PRESSÃO	
Murilo Ferreria Vitor Alexsandro dos Santos Silveira Guilherme Matias Rodolfo César Costa Flesch	
<b>DOI 10.22533/at.ed.6522023039</b>	
<b>CAPÍTULO 10</b> .....	<b>110</b>
UMA NOVA ABORDAGEM DE UM SIMULADOR VIRTUAL DE IDENTIFICAÇÃO DA QUALIDADE DA ÁGUA BASEADO NA METODOLOGIA DE SISTEMAS INTELIGENTES INSERIDO NO CONTEXTO DE REDES NEURAIS	
Matheus Silva Pestana Orlando Donato Rocha Filho Danúbia Soares Pires	
<b>DOI 10.22533/at.ed.65220230310</b>	
<b>CAPÍTULO 11</b> .....	<b>124</b>
INFLUÊNCIA DO ERRO DE QUANTIZAÇÃO APLICADO NO CONTROLE DIGITAL DE VELOCIDADE DE UM MÓDULO SERVOMECANISMO DIDÁTICO	
Vlademir Ap. Freire Junior Marcelo Henrique Granza	



João Luiz Dallamuta

**DOI 10.22533/at.ed.65220230311**

**CAPÍTULO 12 ..... 135**

**CRIAÇÃO DE UM AMBIENTE DE SIMULAÇÃO DE CONTROLE AVANÇADO DE PROCESSOS EM UMA USINA SUCROENERGÉTICA**

Edilberto Pereira Teixeira

Luciano Rangel Pinheiro Neto

**DOI 10.22533/at.ed.65220230312**

**CAPÍTULO 13 ..... 147**

**ESTUDO DE TECNOLOGIAS ALTERNATIVAS PARA VALIDAÇÃO DE ALGORITMOS DE PROTEÇÃO**

Pablo Rodrigues Lopes

Rui Bertho Junior

**DOI 10.22533/at.ed.65220230313**

**CAPÍTULO 14 ..... 159**

**MODELAGEM INTELIGENTE NEBULOSA APLICADA À HIDROPONIA VIA SISTEMA EMBARCADO**

Kayon Vinicius Lima Lopes

Danúbia Soares Pires

Orlando Donato Rocha Filho

**DOI 10.22533/at.ed.65220230314**

**CAPÍTULO 15 ..... 172**

**MODELO DE NEURÔNIO MEMRISTIVO DE DIÓXIDO DE VANÁDIO COM CODIFICAÇÃO DE IMPULSOS PRBS-PWM**

Rennan Santos de Araujo

Luiz Alberto Luz de Almeida

Felipe Sadami Oiwa da Costa

**DOI 10.22533/at.ed.65220230315**

**CAPÍTULO 16 ..... 187**

**MODELO MISO NEBULOSO COM ESTRUTURA MAMDANI APLICADO À ANÁLISE E CONTROLE DE VAZÃO HÍDRICA**

Lorena Maria Figueiredo Albuquerque

Kayon Vinicius Lima Lopes

Orlando Donato Rocha Filho

Danúbia Soares Pires

**DOI 10.22533/at.ed.65220230316**

**CAPÍTULO 17 ..... 199**

**SISTEMA ESPECIALISTA PARA AVALIAÇÃO DE ENGENHARIA COGNITIVA EM *SERIOUS GAMES***

Mateus Gomes Binatti

Marcos Venícios Conceição de Araújo

Pollyana Coelho da Silva Notargiacomo

**DOI 10.22533/at.ed.65220230317**

<b>CAPÍTULO 18</b> .....	<b>209</b>
FILTRO DE KALMAN BASEADO EM MODELO FUZZY TAKAGI – SUGENO VIA ANÁLISE ESPECTRAL DE DADOS EXPERIMENTAIS	
Daiana Caroline dos Santos Gomes Ginalber Luiz de Oliveira Serra	
<b>DOI 10.22533/at.ed.65220230318</b>	
<b>CAPÍTULO 19</b> .....	<b>224</b>
CONSTRUÇÃO, DESIGN DE CONTROLE E CONTROLE DE TRAJETÓRIA POR BLUETOOTH DE UM ROBÔ AUTO EQUILIBRANTE	
Giulio Cesare Mastrocinque Santo Claudio Garcia	
<b>DOI 10.22533/at.ed.65220230319</b>	
<b>SOBRE OS ORGANIZADORES</b> .....	<b>240</b>
<b>ÍNDICE REMISSIVO</b> .....	<b>241</b>

## DESENVOLVIMENTO DE UM MODELO FUZZY E ALGORITMOS DE APRENDIZADO PARA SEQUÊNCIA DE PARTIDA DE PLANTAS INDUSTRIAIS

Data de aceite: 17/03/2020

### André da Silva Barcelos

Instituto de Ciência e Tecnologia, Universidade  
Federal Fluminense  
Macaé - RJ

[http://buscatextual.cnpq.br/buscatextual/  
visualizacv.do?id=K4427908A7](http://buscatextual.cnpq.br/buscatextual/visualizacv.do?id=K4427908A7)

### Fábio Muniz Mazzoni

Instituto de Ciência e Tecnologia, Universidade  
Federal Fluminense  
Rio das Ostras - RJ

[http://buscatextual.cnpq.br/buscatextual/  
visualizacv.do?id=K4427908A7](http://buscatextual.cnpq.br/buscatextual/visualizacv.do?id=K4427908A7)

**RESUMO:** Neste trabalho é desenvolvido um modelo fuzzy-analítico que descreve o comportamento de quatro unidades de processamento de gás natural, localizadas em um parque industrial e que podem operar em paralelo de acordo com a demanda energética nacional. A sequência de partida de unidades de processamento é um problema de decisão estratégica, que consiste em determinar qual das unidades tem prioridade para processar gás natural sob o viés da viabilidade econômica e operacional. Assim, utiliza-se de algoritmos de aprendizado de máquinas, com intuito de determinar a melhor sequência através de um modelo multivariável. A implementação desta

proposta acarretou em uma estimativa de redução de desperdícios na produção na ordem de 16% ao mês.

**PALAVRAS-CHAVE:** Gás natural; Aprendizagem de máquinas; Fuzzy; Tomada de decisão inteligente

### DEVELOPMENT OF A FUZZY MODEL AND LEARNING ALGORITHMS FOR INDUSTRIAL PLANT SEQUENCE START

**ABSTRACT:** This paper presents a fuzzy-analytic model to describe the behavior of four natural gas processing plants located in an industrial facilities which can operate in parallel mode, according to the national energy demand. The starting sequence of processing units is a strategic decision problem that consists of determining which of the units has priority to process natural gas under the bias of economic and operational viability. Thus, this work adopts machine learning algorithms in order to define the sequence of operation in a multivariable model. The implementation of this proposal led to an estimated reduction of waste production in the order of 16% per month.

**KEYWORDS:** Natural gas; Machine learning; Fuzzy; Intelligent decision making

## 1 | INTRODUÇÃO

As unidades de processamento de gás natural (UPGN's) que estão localizadas em parques industriais, são instalações que recebem o gás natural (GN) como insumo e tem a finalidade de produzir gás natural processado (GNP). Desta forma, os parques industriais utilizam-se de uma ou mais UPGN's em produção paralela para a demanda nacional de GNP (Perlotti et al., 2016).

Neste cenário, faz-se necessário definir a sequência de partida das UPGN's, onde considera-se as condições de operação de cada unidade (Gholian et al., 2013). Isto posto, o trabalho tem por objetivo desenvolver um modelo do comportamento de quatro UPGN's dentro de um parque industrial.

Este modelo de comportamento será utilizado por algoritmos de classificação, com a finalidade de determinar o sequenciamento de partida das UPGN's de acordo com a demanda de GNP. Para a elaboração do modelo, a seção 2 apresenta um resumo do processamento de gás natural com intuito de apontar variáveis e funções do comportamento das UPGN's.

A primeira função que consta no modelo é a estabilidade operacional, que depende das condições de automação, controle e equipamentos da planta industrial e será descrita por lógica fuzzy. As funções de vazão, eficiência da produção e desperdício de insumos são obtidas analiticamente no domínio do tempo. Por fim, a função de operacionalidade é modelada por lógica fuzzy, onde considera-se os aspectos de layout, construção e recursos da UPGN.

Na seção 3, são apresentados os algoritmos de classificação que são: O Technique for Order Preference by Similarity to a Ideal Solution (TOPSIS); Rede Neural Artificial (RNA); Máquina de Vetor Suporte (MVS) e Regressão Logística (RegLog). Os experimentos encontram-se descritos na seção 4, a seção 5 analisa os resultados das simulações a seção 6 apresenta a conclusão.

## 2 | DESENVOLVIMENTO DO MODELO

### 2.1 Processamento de gás natural

A indústria de beneficiamento do GN utiliza-se de UPGN's em paralelo que devem entrar em operação ou interromper a produção de forma independente. Cada uma das UPGN's contém uma torre de processamento que recebe como insumo o GN (composto de hidrocarbonetos), onde o metano (C1) e o etano (C2) são às frações de menor peso molecular e maior volatilidade que ascendem até o topo da torre de processamento.

O propano (C3), butano (C4) e pentanos (C5+), encontram-se em estado líquido e descem ao fundo da torre de processamento (Kidnay et al., 2011). A Figura

1 mostra o arranjo de quatro UPGN's em um parque industrial.




Figura 1. Fluxograma de Processamento

Conforme observa-se na Figura 2, o GNP é composto de  $C_1$  e  $C_2$  que ascendem ao topo da torre de processamento e será fornecido ao mercado consumidor, de acordo com a demanda. O líquido de fundo da torre é composto de  $C_3$ ,  $C_4$  e  $C_5+$  e caracteriza um subproduto que será direcionado para unidades de processamento de líquidos (Mokhata and Poe, 2012).




Figura 2. Torre de Processamento

A seguir serão apresentadas as variáveis e funções que determinam o comportamento de uma UPGN para compreender a dinâmica do processo de produção e construir um modelo.

## 2.2 Estabilidade Operacional

Para obter a estabilidade operacional, utiliza-se dos conceitos de grau de automação, capacidade de controle e do percentual de equipamentos em stand-by que define as três variáveis de entrada de uma função que retorna como saída a estabilidade operacional.

O grau de automação é definido com a quantidade de variáveis críticas do processo interno, alarmes e malhas de controle, enquanto a capacidade de controle é determinada pela quantidade de malhas estáveis e controláveis que são capazes de manter os processos termodinâmicos estabilizados. A terceira variável de entrada

é a quantidade percentual de equipamentos em standby que remete o potencial de manter a UPGN em operação contínua.

Para obter a estabilidade operacional que é a função de saída, este trabalho utiliza-se da lógica fuzzy e estabelece três superfícies simétricas que avalia as três variáveis de entrada, tomadas duas a duas em relação a estabilidade operacional. A função de pertinência é a trapezoidal com cinco hierarquias (Muito Baixo, Baixo, Adequado, Alto, Muito Alto) e com três superfícies semelhantes à Figura 3.




Figura 3. Superfície da estabilidade operacional

O método de defuzzyficação adotado é o centro de gravidade (COG), que retorna um valor numérico para a estabilidade operacional de acordo com as três variáveis de entrada.

### 2.3 Vazão da produção

Para medir a vazão de produção de GNP ( $\mu p(t)$ ), utiliza-se da integração do volume produzido  $vp(t)$  conforme a equação 1.

$$\mu p(t) = \int_{t=0}^t vp(t) dt \quad (1)$$

O resultado da equação 1 torna possível obter a vazão máxima ( $\mu p(\max)$ ) de produção e por conseguinte construir a Tabela 1. A unidade de processamento A produz a maior vazão de GNP possível ( $\mu p(\max) = 1$ ) quando comparada com as demais unidades.

UPGN	A	B	C	D
$\mu_{max}$	1,0000	1,0000	0,9074	0,9359

Tabela 1. Vazão da produção

## 2.4 Eficiência da produção

A vazão de produção de GNP ( $\mu_p(t)$ ) e a vazão de insumo ( $i_p(t)$ ) são utilizadas para medir a eficiência ( $\xi(t)$ ) da produção. Para realizar este cálculo, toma-se a razão da vazão de produção pela integração da vazão de insumo através da equação 2:

$$\xi(t) = \frac{\mu_p(t)}{\int_{t=0}^t i_p(t) dt} \quad (2)$$

O valor de  $\xi(t)$  representa a eficiência em que uma UPGN consegue transformar a fração de C1 e C2 do GN em produto ao longo do tempo. A Tabela 2 apresenta a eficiência média da produção  $\xi_{med}$  de cada UPGN.

UPGN	A	B	C	D
$\xi_{med}$	0,9231	0,7058	0,7003	0,8874

Tabela 2. Eficiência média da produção

## 2.5 Desperdício de insumo

Define-se como desperdício de insumo ( $\mu_d$ ) o volume de GN admitido na torre de processamento que por descontrolo ou desvios operacionais é impedido de converter-se em produto especificado.

Isto ocorre quando as frações de C3, C4 ou C5+ ascendem indevidamente ao topo da torre de processamento e entram na composição do GNP. Nesta condição todo o produto que sai pelo topo da torre de processamento encontra-se desespecificado e deve ser reprocessado ou descartado no sistema de rejeito.

O reprocessamento consiste em injetar o produto desespecificado na entrada de insumo da torre e esta manobra acarreta em retrabalho e redução da eficiência da produção. A equação 3 permite obter o volume reprocessado ( $\mu_r$ ).

$$\mu_r = \int_{t=0}^t \mu_r(t) dt \quad (3)$$

O sistema de rejeito é uma instalação industrial com a finalidade de descartar o gás que ascendeu ao topo da torre e encontra-se desespecificado. Obtém-se pela equação 4 a totalização do volume rejeitado ( $\mu_j$ ).

$$\mu_j = \int_{t=0}^t \mu_j(t) dt \quad (4)$$

O volume de gás desperdiçado é medido por meio da equação 5 e consiste na média harmônica do volume de gás reprocessado com o volume de gás enviado ao sistema de rejeito. A escolha da média harmônica consiste na possibilidade de ponderar o custo do reprocessamento e do rejeito.

$$\mu_d = \frac{2}{\frac{1}{\mu_r} + \frac{1}{\mu_j}} \quad (5)$$

A Tabela 3 é o resultado da equação 5 e demonstra o volume de desperdício de cada UPGN. Por definição faz-se necessário minimizar esta equação de acordo com as práticas de otimização da produção.

UPGN	A	B	C	D
$\mu_{médio}$	0,1419	0,1180	0,1312	0,1074

Tabela 3. Volume de desperdício

## 2.6 Operacionalidade

As UPGN's apresentam diferenças de layout, tecnologia, modelo de construção e particularidades em suas instalações que influenciam a capacidade de partir e operar adequadamente. Para obter a operacionalidade, utiliza-se da lógica fuzzy para criar uma superfície que avalia as três variáveis de entrada que são: o tempo de partida; os recursos necessários e o tempo de estabilização conforme observa-se na Figura 4:




Figura 4. Mapa de regras da operacionalidade

A função de pertinência adotada é a trapezoidal com cinco hierarquias (Muito Baixo, Baixo, Adequado, Alto e Muito Alto) e com três superfícies simétricas relacionadas duas a duas em função da Operacionalidade. O método de defuzzyficação adotado é o centro de gravidade que retorna um valor numérico de acordo com as três variáveis de entrada.



### 3 | ALGORITMOS PARA CLASSIFICAÇÃO

Realizou-se testes em algoritmos de aprendizado, regressores, redução dimensional, árvores de decisão e heurísticas com a finalidade de classificar corretamente os resultados do modelo proposto.

Os algoritmos que apresentaram os melhores resultados para a classificação do modelo foram o TOPSIS, a rede neural, a máquina de vetor suporte e a regressão logística que estão descritos nas próximas subseções.

#### 3.1 TOPSIS

O algoritmo Technique for Order Preference by Similarity to a Ideal Solution (TOPSIS) é definido como um método multicritério, onde mede-se a distância euclidiana entre todas as alternativas possíveis com a solução ideal (Şengül et al., 2015).

Conceitualmente define-se que a melhor alternativa (D+) encontra-se com a menor distância euclidiana possível para a solução ideal e por conseguinte, a pior alternativa (D-), encontra-se o mais próximo possível da solução não ideal (Hwang and Yoon, 1981).

O método TOPSIS avalia a matriz de alternativas da Figura 5 com todas as alternativas possíveis  $A_i$  associadas aos atributos  $C_j$  (Şengül et al., 2015).

$$A = \begin{matrix} & C_1 & C_2 & \dots & C_j \\ A_1 & \left\{ \begin{array}{cccc} x_{11} & x_{12} & \dots & x_{1j} \\ \vdots & & \ddots & \vdots \\ x_{i1} & x_{i2} & \dots & x_{ij} \end{array} \right. & & & \end{matrix}$$

Figura 5. Matriz de alternativas

O processo de execução do TOPSIS pode ser em uma sequência de etapas, onde avalia-se a construção da matriz de alternativas ponderadas (Behzadian et al., 2012). A seguir encontram-se as etapas descritas em detalhes.

- Construção da matriz de alternativas ponderadas: Utiliza-se de um vetor de pesos ( $w_1, w_2, \dots, w_n$ ) que deve ser fornecido pelo especialista para ponderar as alternativas em cada critério. Devido à questão cognitiva, o especialista pondera as alternativas de maneira incoerente e entende-se que a determinação de pesos torna-se induzida (Zavadskas and Podvezko, 2016).

Uma forma de obter pesos para solucionar problemas onde prevalece a indução humana, é utilizar-se de teorias e métodos que por definição são independentes do especialista. Um desses métodos calcula a medida de incerteza ou entropia do

sistema e mede o estado de desordem ou inconsistência em um dado momento (Ormos and Zibriczky, 2014).

O conceito de entropia na atribuição de pesos representa uma medida de estado momentâneo, onde espera-se que quanto maior for a inconsistência do sistema, maior será a entropia (Joshi and Kumar, 2014). Para este trabalho, os pesos ( $w_1, w_2, \dots, w_n$ ) são obtidos pela entropia da matriz de alternativas de acordo com as equações 6, 7 e 8.

$$e_j = -\frac{1}{\ln(m)} \sum_{i=1}^m x_{ij} \ln(x_{ij}) \quad (6)$$

$$d_j = 1 - e_j \quad (7)$$

$$w_j = \frac{d_j}{\sum_{j=1}^m d_j} \quad (8)$$

Uma vez que obtenha-se a entropia conforme a equação 6, utiliza-se da equação 7 e 8 para obtenção do vetor de pesos  $w_j$ . A matriz de alternativas ponderadas  $v_{ij}$  tem a forma descrita na equação 9, onde  $r_{ij}$  são os valores ( $x_{ij}$ ) da matriz de alternativas A normalizada.

$$v_{ij} = w_j r_{ij} \quad (9)$$

Vale salientar que a matriz ponderada é independente do especialista, pois neste caso realiza-se a determinação dos pesos ( $w_{ij}$ ) através da entropia dos valores ( $x_{ij}$ ) da matriz A (Yentes et al., 2013).

- Cálculo da similaridade: Define-se como similaridade a distância euclidiana de cada alternativa à solução ideal. Nesta etapa, calcula-se a similaridade da matriz ponderada, tanto para a solução ideal ( $D^+$ ), quanto para a solução não ideal ( $D^-$ ), conforme as equações 10 e 11.

$$D_i^+ = \sqrt{\sum_{j=1}^m [v_{ij}(x) - v_j^+(x)]^2} \quad (10)$$

$$D_i^- = \sqrt{\sum_{j=1}^m [v_{ij}(x) - v_j^-(x)]^2} \quad (11)$$

Ao final, utiliza-se da equação 12 para ordenar as alternativas e propor a solução do sequenciamento de partida, onde o vetor  $k_i$  apresenta um ranking de alternativas obtidas através da entropia da matriz A ( $x_{ij}$ ).

$$k_i = \frac{D_i^-}{D_i^- + D_i^+} \quad (12)$$

### 3.2 Rede Neural Artificial

A rede neural artificial é uma ferramenta computacional utilizada para classificação de dados com a possibilidade de estabelecer relações não lineares entre entrada e saída (Yegnanarayana, 2009)

Espera-se que as redes neurais tenham a capacidade de aprender através da melhoria de um critério de desempenho por um processo iterativo de ajustes de pesos da rede (Behbahani et al., 2009). A taxa de aprendizagem e os pesos influenciam no tempo de processamento da rede neural e desta forma faz-se necessário definir um critério de parada, onde fica estabelecido que a partir deste momento, a rede encontra-se treinada (Witten et al., 2016).

Durante o treinamento, obtém-se o percentual de acertos na classificação para um tempo de processamento. Ao dobrar-se o tempo de processamento, deve ocorrer a convergência do percentual de acertos até um limite temporal definido como critério de parada (Yegnanarayana, 2009).

### 3.3 Máquina de Vetor Suporte

Um algoritmo de máquina de vetor suporte (MVS) disponibiliza os dados no espaço e desenvolve hiperplanos de complexidade ajustável, com a finalidade de separar os dados em categorias distintas (Smola and Schölkopf, 2004). Desta forma, uma MVS é utilizada como um algoritmo classificador, regressor ou identificador de outliers (Cristianini and Shawe-Taylor, 2000).

Os hiperplanos são criados de acordo com a base de dados e o algoritmo utiliza-se de uma margem de separação, que permite uma correta classificação das instâncias (Smola and Schölkopf, 2004). Devido as instâncias deste trabalho, faz-se necessário a redução do custo computacional com a finalidade de convergir à solução. Assim, utiliza-se da classificação binária iterativa que propaga erros, porém retorna resultados viáveis (Witten et al., 2016).

### 3.4 Regressão Logística

Um algoritmo que utiliza-se de regressão para classificação encontra aplicação em domínios numéricos, pois entende-se que quaisquer técnicas de regressão, pode ser utilizada para classificação (Hosmer Jr et al., 2013). A forma multivariável do algoritmo de RegLog pode ser aplicada em domínios que existem três ou mais possibilidades de classificação, onde os resultados devem ser ordenados (Menard, 2002).

Outrossim, admite-se que os valores de máximo e mínimo de uma base de dados situam-se no limite superior e inferior das escalas. Por conseguinte, atualizam-se os parâmetros da curva, para que a função logística torne-se ajustada aos dados

durante a fase de treinamento (Witten et al., 2016).

## 4 | EXPERIMENTOS

O modelo descrito nas seções anteriores é representado numericamente em uma matriz 4x5, onde cada coluna são respectivamente os valores da estabilidade operacional, vazão de produção, eficiência, desperdício de insumo e operacionalidade de cada UPGN. Esta matriz é a representação numérica do modelo do comportamento que varia ao longo do tempo.

Este trabalho utiliza-se do histórico de 1072 matrizes (instâncias) de acordo com o modelo, que representam a partida e operação de plantas reais com intuito de realizar as simulações. Assim, quando um algoritmo computa estas instâncias, espera-se que o resultado seja o sequenciamento de partida.

O sequenciamento indicado pelo algoritmo é representado através de uma palavra, na qual a sequência de letras está disposta em ordem de preferência, como por exemplo a palavra cbda onde a UPGN C tem a prioridade da partida seguida da B e assim, sucessivamente. Isto posto, fica estabelecido que o modelo contém 20 entradas e 24 saídas e que o algoritmo utiliza-se de 1072 instâncias obtidas através de histórico.

Cada algoritmo contém parâmetros que podem ser ajustados iterativamente para melhorar o desempenho da classificação em detrimento do aumento do tempo de computação. Estes ajustes de parâmetros são realizados em simulações sucessivas através da redução do erro relativo.

Uma vez que não ocorra redução de erro relativo em duas simulações sucessivas ou melhoria do desempenho com ajuste de parâmetros, fica determinado que atingiu-se o critério de parada da simulação.

### 4.1 TOPSIS

O algoritmo TOPSIS retorna 771 instâncias classificadas corretamente e observa-se resultados ambíguos. Este fato reside na forma em que o algoritmo classifica suas instâncias e busca soluções.

Uma vez que o método baseia-se em ordenar soluções que se encontram na menor distância da solução ideal e por conseguinte na maior distância da solução não ideal. Fica evidente que em uma base de dados podem existir instâncias com os módulos aproximadamente iguais para a solução ideal e não ideal, porém com sentidos distintos.

A ordenação ambígua do método TOPSIS é imperceptível em modelos de ordem três ou com número de instâncias reduzidos (10 a 20). Porém quando a

ordem do modelo aumenta e o número de instâncias ultrapassa algumas centenas o algoritmo apresenta ambiguidade.

#### 4.2 Regressão Logística (RegLog)

Este algoritmo retorna 994 (92,72%) instâncias classificadas corretamente e aponta as palavras bcad e bacd como as que apresentam os maiores erros de classificação, com nove e sete instâncias respectivamente.

Ao observar a computação deste algoritmo, percebe-se que por seis vezes as instâncias que deveriam ser classificadas como bcad, são classificadas como bacd. Por outro lado, as instâncias que deveriam ser classificadas como bacd, são classificadas como bcad quatro vezes.

Fica evidente que quando a palavra inicia-se por b e termina com d, as letras do meio apresentam ambiguidade na classificação. Como experimento removeu-se as palavras bacd e bcad da classificação e o resultado da simulação atingiu o 94,87% de acertos.

#### 4.3 Rede Neural Artificial (RNA)

Este algoritmo consegue classificar 1001 (93,37%) instâncias corretamente após 65 simulações, onde realizam-se todos os ajustes necessários aos parâmetros da rede.

A avaliação dos resultados mostra que a instância que deveria ser classificada como dcba é classificada incorretamente em cinco ocasiões como cdba. Por outro lado, a palavra cbda é classificada como dcba seis vezes e evidencia que a rede apresenta uma região de ambiguidade.

#### 4.4 Máquina de Vetor Suporte (MVS)

Este algoritmo classifica 1034 (96,45%) instâncias corretamente após 225 simulações com tempo de processamento na ordem de horas. A região ambígua para este algoritmo situa-se nas palavras cbda e bcda, com quatro e três classificações erradas respectivamente.

### 5 | ANÁLISE DOS RESULTADOS

Este trabalho utiliza-se de quatro métricas para a análise dos resultados e validação da simulação. A primeira métrica é o percentual de instâncias classificadas corretamente por cada algoritmo (%cts) enquanto que a segunda métrica é a raiz quadrada do erro médio da melhor classificação (rqm).

A terceira métrica é o número total de simulações completas que permitiram

o ajuste iterativo de pesos e conseqüentemente, o aumento de desempenho da rede (nts). Por fim, a quarta métrica é o tempo total de processamento de todas as simulações (tts). Na Tabela 4 encontra-se um resumo das métricas adotadas.

Métrica	%cts	rqm	Nts	tts
TOPSIS	71,92	0.0961	60	00:15:25
RegLog	92,72	0.1380	163	00:56:25
RNA	93,37	0.0816	65	31:12:15
MVS	96,45	0.1925	225	01:15:20

Tabela 4. Métricas adotadas

Observa-se que a MVS apresenta o maior percentual de acertos para a classificação correta das instâncias, em um tempo total de simulação em aproximadamente 1 hora e 15 minutos. Por outro lado, a rede neural artificial necessita de um tempo de simulação próximo de 32 horas para conseguir um resultado inferior à MVS.

A raiz quadrada do erro médio (rqm) leva em conta todas as classificações das instâncias erradas e pondera sobre o quanto estariam distantes das instâncias corretas. Assim, afirma-se que os erros de classificação cometidos pelo algoritmo MVS tem maior magnitude que os erros cometidos pelos demais algoritmos.

## 6 | CONCLUSÃO

A decisão do sequenciamento de partida de plantas industriais é estratégica para as empresas inseridas na atividade de processamento, pois trata-se da produção de gás natural em um cenário de demanda nacional. Esta responsabilidade fica à cargo dos gestores destas unidades que devem determinar o sequenciamento de partida empiricamente.

Desta forma, este trabalho propõe um modelo fuzzy analítico, que utiliza-se de fatores operacionais e econômicos para determinar um modelo comportamento das UPGN's e definir o sequenciamento de partida, utilizando-se do algoritmos de máquina de vetor suporte.

Outra análise que pode ser realizada é que com este modelo, torna-se possível prever as deficiências operacionais de cada unidade e gerenciar recursos para investimentos ou manutenção com a finalidade de melhorar o desempenho na produção e operação. Este trabalho encontra-se em andamento e estima-se (baseado em histórico) que o lucro cessante encontra-se minimizado com uma redução do desperdício na ordem de 16% ao mês.

Como sugestão para trabalhos futuros, existe a possibilidade de aplicação

para diferentes tipos de plantas industriais. Um exemplo característico são os parques de compressão de gás natural e bombeamento de petróleo, que contém bombas industriais de grande porte e turbinas à gás que operam em paralelo e são responsáveis pelo envio de produto ao mercado consumidor.

## REFERÊNCIAS

- BEHBAHANI, R.M., JAZAYERI-RAD, H., HAJMIRZAEI, S. **Fault detection and diagnosis in a sour gas absorption column using neural networks**. Chemical engineering & technology, (2009).
- BEHZADIAN, M., et al. **A state-of the-art survey of topsis applications**. Expert Systems with applications, (2012).
- CRISTIANINI, N., SHAWE-TAYLOR, J. **An introduction to support vector machines and other kernel-based learning methods**. Cambridge university press, (2000).
- GHOLIAN, A., et al.,. **Optimal industrial load control in smart grid: A case study for oil refineries**. IEEE Power & Energy Society General Meeting, 1–5. IEEE, (2013).
- HOSMER Jr, D.W., LEMESHOW, S., STURDIVANT, R.X. **Applied logistic regression**, volume 398. John Wiley & Sons, (2013).
- HWANG, C.L., YOON, K. **Methods for multiple attribute decision making**. In Multiple attribute decision making, 58–191. Springer, (1981).
- JOSHI, D. and KUMAR, S. **Intuitionistic fuzzy entropy and distance measure based topsis method for multi-criteria decision making**. Egyptian informatics journal, (2014).
- KIDNAY, A.J., PARRISH, W.R., MCCARTNEY, D.G. **Fundamentals of natural gas processing**. CRC press, (2011).
- MENARD, S. **Applied logistic regression analysis**, volume 106. Sage, (2002).
- MOKHATA, S., POE, W.A. **Handbook of natural gas transmission and processing**. Gulf professional publishing, (2012).
- ORMOS, M. and ZIBRICZKY, D. **Entropy-based financial asset pricing**. PloS one, (2014).
- PERLOTTI, E.A., SANTOS, E.M.d., and COSTA, H.C.d.M. **Concentração espacial da indústria de São Paulo: evidências sobre o papel da disponibilidade de gás natural**. Estudos avançados, (2016).
- ŞENGÜL, Ü., et al. **Fuzzy topsis method for ranking renewable energy supply systems in turkey**. Renewable Energy, (2015).
- SMOLA, A.J., SCHOLKOPF, B. **A tutorial on support vector regression**. Statistics and computing, (2004)
- WITTEN, I.H., FRANK, E., HALL, M.A., PAL, C.J. **Data Mining: Practical machine learning tools and techniques**. Morgan Kaufmann. (2016).
- YEGNANARAYANA, B. **Artificial neural networks**. PHI Learning Pvt. Ltd. (2009).

YENTE, J.M., et al. **The appropriate use of approximate entropy and sample entropy with short data sets**. Annals of biomedical engineering, (2013)

ZAVADSKAS, E.K., PODVEZKO, V. **Integrated determination of objective criteria weights in mcdm**. International Journal of Information Technology & Decision Making, (2016).



## ÍNDICE REMISSIVO

### A

Abrasômetro 49, 50, 51, 52, 53, 54, 55, 56

Adesão 23, 31, 32

Ajuste automático 72, 190

Algoritmo genético 36, 37, 42, 47, 72, 73, 75, 76, 78, 79, 80, 81

Aprendizado de máquina 12

Aprendizagem de máquinas 58, 176

Arquitetura paralela 83, 84

Autoleitura 11, 12, 13, 14, 21

Automação 49, 51, 53, 56, 59, 60, 81, 95, 109, 124, 133, 135, 137, 151, 153, 157, 161, 170, 187, 198

Avaliação experimental 96, 109

### B

Barreiras 23, 32, 33

### C

Calorímetro de alta pressão 96

Casas inteligentes 23, 24, 25, 26, 29, 31, 32, 33

Consumo de energia 12, 13, 14

Controlador fuzzy 135, 142, 143, 145, 146

Controlador PI 1, 99, 124, 131

Controlador PID 72, 74, 75, 79, 81

Controle de processos 135, 136

Controle híbrido 95, 97, 99, 102, 105, 107, 108

Controle PID 74, 78, 83

### E

Energia eólica 1, 2, 4

Erro de quantização 124, 125, 126, 127, 133, 134

Estabilidade transitória 36

### F

Fuzzy 58, 59, 61, 63, 69, 70, 123, 135, 136, 138, 142, 143, 144, 145, 146, 159, 160, 170, 171, 187, 188, 194, 198, 207, 209, 210, 211, 212, 213, 216, 222, 223, 225, 239

### G

Gás natural 58, 59, 69, 70

### H

HOG 12, 14, 18, 19, 20, 21, 22

## I

Identificação de sistemas 36, 38, 39, 47, 48, 116, 124, 128, 134, 209

## L

Ladder 135, 136, 144, 145

Lógica fuzzy 59, 61, 63, 135, 138, 170, 207

LSS 12, 14, 18, 19, 20, 21, 22

## M

Máquinas de ensaio 49, 51

Modelagem de carga 36, 37, 38, 39, 46

Modelos matemáticos 1, 3, 10, 38, 39, 128, 135

## P

Países desenvolvidos 23, 24, 26, 28, 29

Países emergentes 23, 27, 28, 29, 31

Processamento de imagens 12, 21

Protótipo 73, 79, 82, 83, 84, 86, 93, 148, 149, 150, 167, 168, 189, 196

## R

Reconhecimento 11, 12, 13, 14, 16, 17, 19, 20, 21, 110, 112, 113, 123, 174, 176, 179, 203, 204, 210

Refrigeração com dióxido de carbono 96

Robô delta 83, 93, 94

## S

Servomecanismo 124, 125, 126, 127, 128, 131, 132, 133, 134

Sistema de posicionamento 83

Supervisor 52, 54, 55, 82, 85, 88, 135, 145

Svm 12, 14, 17, 19, 21, 22

## T

Tomada de decisão inteligente 58

Turbina eólica 1, 3, 4, 5, 6, 7, 10

## V

Válvulas automáticas industriais 95, 96

 **Atena**  
Editora

**2 0 2 0**