



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

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

CAPÍTULO 1	1
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	
DOI 10.22533/at.ed.6522023031	
CAPÍTULO 2	11
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	
DOI 10.22533/at.ed.6522023032	
CAPÍTULO 3	23
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	
DOI 10.22533/at.ed.6522023033	
CAPÍTULO 4	36
MODELAGEM DE UM SISTEMA DE DISTRIBUIÇÃO COM GERAÇÃO, UTILIZANDO ALGORITMO GENÉTICO	
Igor Ferreira Visconti	
DOI 10.22533/at.ed.6522023034	
CAPÍTULO 5	49
INSTRUMENTAÇÃO, CONTROLE E SUPERVISÃO DE UM ABRASÔMETRO TIPO RODA DE BORRACHA	
Périson Pavei Uggioni André Roberto de Sousa Anderson Daleffe Diego Tiburcio Fabre	
DOI 10.22533/at.ed.6522023035	

CAPÍTULO 6	58
DESENVOLVIMENTO DE UM MODELO FUZZY E ALGORITMOS DE APRENDIZADO PARA SEQUÊNCIA DE PARTIDA DE PLANTAS INDUSTRIAIS	
André da Silva Barcelos Fábio Muniz Mazzone	
DOI 10.22533/at.ed.6522023036	
CAPÍTULO 7	72
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	
DOI 10.22533/at.ed.6522023037	
CAPÍTULO 8	82
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	
DOI 10.22533/at.ed.6522023038	
CAPÍTULO 9	95
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	
DOI 10.22533/at.ed.6522023039	
CAPÍTULO 10	110
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	
DOI 10.22533/at.ed.65220230310	
CAPÍTULO 11	124
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

CAPÍTULO 18	209
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	
DOI 10.22533/at.ed.65220230318	
CAPÍTULO 19	224
CONSTRUÇÃO, DESIGN DE CONTROLE E CONTROLE DE TRAJETÓRIA POR BLUETOOTH DE UM ROBÔ AUTO EQUILIBRANTE	
Giulio Cesare Mastrocinque Santo Claudio Garcia	
DOI 10.22533/at.ed.65220230319	
SOBRE OS ORGANIZADORES	240
ÍNDICE REMISSIVO	241

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

Data de aceite: 17/03/2020

Data de submissão: 10/12/2019

Rennan Santos de Araujo

Universidade Federal do ABC

Santo André – São Paulo

<http://buscatextual.cnpq.br/buscatextual/visualizacv.do?id=K4412055J2>

Luiz Alberto Luz de Almeida

Universidade Federal do ABC

Santo André – São Paulo

<http://buscatextual.cnpq.br/buscatextual/visualizacv.do?id=K4785395E9>

Felipe Sadami Oiwa da Costa

Universidade Federal do ABC

Santo André – São Paulo

<http://buscatextual.cnpq.br/buscatextual/visualizacv.do?id=K8754865J1>

RESUMO: A computação neuromórfica caracteriza um recente paradigma de arquitetura computacional que, respaldando-se na estrutura de um sistema neural biológico, almeja ser uma alternativa mais eficiente para o processamento de informações em larga escala. Atendendo a principal força motriz da computação neuromórfica, a economia energética, este trabalho propõe um novo modelo de neurônio, estimulado por impulsos codificados por PRBS (Pseudorandom Binary

Sequence) e modulados por PWM (Pulse Width Modulation), cuja memristência e ativação são baseadas no comportamento das dinâmicas térmicas e não lineares de transição de fase do composto inorgânico dióxido de vanádio VO_2 . Embasando-se nos resultados positivos obtidos pelas simulações computacionais neste trabalho, é esperado que esta nova proposta de neurônio artificial, quando implementada em uma rede neural pulsada, seja capaz de estabelecer maiores índices de plasticidade neural e eficiência energética.

PALAVRAS-CHAVE: Codificação de Impulsos PRBS-PWM; Eficiência Energética; Dióxido de Vanádio; Memristência; Redes Neurais Pulsadas.

VANADIUM DIOXIDE MEMRISTIVE NEURON MODEL BASED ON PRBS-PWM PULSE ENCODING

ABSTRACT: Neuromorphic computing features a recent paradigm of computational architecture that, based on the structure of a biological neural system, aims to be a more efficient alternative for the large-scale information processing. Attending to neuromorphic computing main driving force, the energy economy, this work proposes a new neuron model, stimulated by pulses encoded by PRBS (Pseudorandom Binary Sequence) and modulated by PWM

(Pulse Width Modulation), whose memristence and activation are based on the behavior of the thermal and nonlinear phase transition dynamics of the inorganic compound vanadium dioxide VO_2 . Based on the positive results obtained by the computational simulations in this work, it is expected that this new proposal of artificial neuron, when implemented in a spiking neural network, will be able to establish higher standards of neural plasticity and energy efficiency.

KEYWORDS: PRBS-PWM Pulse Encoding; Energy Efficiency; Vanadium Dioxide; Memristence; Spiking Neural Networks.

1 | INTRODUÇÃO

A computação neuromórfica pode ser definida como um modelo bioinspirado e, relativamente, contemporâneo de organização computacional que, baseando-se na complexa mecânica de atividades de um circuito neural biológico, objetiva ser uma alternativa mais eficiente para o processamento de informações, “ameaçando” a preponderante hegemonia da consolidada Arquitetura de von Neumann (WRIGHT, 2013).

Tendo em vista o iminente fim do efeito da lei publicada pelo químico estadunidense Gordon Earle Moore, em 1965, que constatava que a cada 18 meses, a capacidade de processamento dos chips aumentaria em 100%, ou seja, dobraria, sem que houvesse alterações no custo (WALDROP, 2016), pesquisas recentes, regularmente alicerçadas na sólida concepção abstraída por Carver Mead, em 1990 (MEAD, 1990), indicam que estruturas computacionais, inspiradas no funcionamento de complexas arquiteturas neurobiológicas, apresentam um grande potencial para tornarem-se uma alternativa eficiente para o futuro da computação.

Esta arquitetura bioinspirada, diferentemente daquela proposta por John von Neumann, em 1945, não apresenta uma unidade central de processamento, dividida em subunidades de controle e lógica, que, através do uso de registradores e ponteiros, armazenam e processam dados (JO, 2010). Nesta nova abordagem, toda a manipulação da informação é efetuada por intermédio de redes neurais artificiais, constituídas por “neurônios” e inúmeras interconexões, denominadas “sinapses”, entre os mesmos, que contribuem para que os dados sejam paralelamente processados e persistidos de uma maneira rápida, acurada, energeticamente eficiente e robusta em relação a eventuais falhas locais (MEAD, 1990).

Historicamente, a redução do custo energético de operações computacionais sempre foi um fator de suma relevância no desenvolvimento de novas tecnologias e este talvez seja o principal fator benéfico da computação neuromórfica (MEAD, 1990). Esta característica está fortemente ligada à arquitetura massivamente paralela das redes neurais artificiais, que pode ser implementada de maneira analógica ou digital

através do uso de transistores convencionais ou, mais recentemente, memristores baseados em materiais óxido metálicos (JO, 2010). No caso deste trabalho, o dióxido de vanádio.

Atualmente, pesquisas apontam diversas aplicações para a computação neuromórfica, em variados campos da ciência, destacando sua alta aptidão para o reconhecimento de padrões e memory retrieval (INDIVERI, 2009).

Vale-se destacar uma pesquisa realizada por um conjunto de cientistas afiliados ao Advanced Nanoscale Engineering Group, da Universidade de Oxford, que ambiciona desenvolver dispositivos de hardware integralmente implementados através de circuitos fotônicos que sejam capazes de simular sinapses neurais biológicas. A pesquisa evidencia que o uso de recursos ópticos possibilita que as simulações possam ocorrer em velocidade ultrarrápida, utilizando uma largura de banda virtualmente ilimitada e com uma alta taxa de redução de perda de potência elétrica (CHENG, 2017).

Outra importante contribuição para o desenvolvimento de sistemas neuromórficos complexos foi realizada através de uma pesquisa, publicada no primeiro semestre de 2017, que almejava investigar técnicas de aplicações de memória auto-associativa e reconhecimento de padrões em um sistema de osciladores micro-mecânicos (KUMAR e MOHANTY, 2017). Os resultados revelaram que a computação neuromórfica, quando aplicada de maneira física em um sistema de osciladores micro-mecânicos, através de um processo fabricação baseado em silício, produz um considerável nível de acréscimo na robustez contra ruídos e variações no processo de manufatura (KUMAR e MOHANTY, 2017).

Objetivando proporcionar uma maior facilidade nas simulações numéricas de sistemas computacionais neuromórficos memristivos, em maio de 2018, foi publicado um artigo com a proposta de uma plataforma customizável de software que, potencialmente, é capaz de emular o comportamento e representar as dinâmicas não-lineares de um sistema neural memristivo (XIA, 2018). A ferramenta desenvolvida, intitulada MNSIM, além de utilizar de diferenciadas métricas de desempenho para estimar as taxas de erros computacionais, também alcançou excelentes níveis de rapidez na execução de suas tarefas (XIA, 2018).

Grande parte das pesquisas recentes, no campo da computação neuromórfica, está direcionada a aplicações e simulações de sistemas neurais memristivos. Esta subclasse de sistemas neuromórficos concentra-se em abstrair modelos que sejam capazes de implementar a neuroplasticidade em redes neurais artificiais através do uso de memristores (MERKEL, 2016).

O memristor é um componente eletrônico passivo e não-volátil, de função não-linear, que apresenta a capacidade de processar e persistir dados com uma economia energética muito superior a sistemas que empregam a tecnologia CMOS

(Complementary Metal Oxide Semiconductor) (MERKEL, 2016). Este componente, cuja condutância pode ser precisamente modulada por carga e fluxo, quando presente na estrutura de um neurônio baseado em um material semiconductor óxido-metálico, pode possibilitar a implementação da plasticidade sináptica neural no sistema (JO, 2010).

A plasticidade sináptica neural refere-se à capacidade de um sistema neural se reestruturar em resposta a experiências ou estímulos (TSODYKS, 1998). Este processo, que promove uma constante remodelação e rearranjo dos mapas neurosinápticos, objetiva viabilizar um maior nível de acurácia, conectividade e densidade para redes neurais artificiais (JO, 2010).

Neste trabalho, é proposto um novo modelo de neurônio artificial, estimulado por impulsos codificados em PRBS-PWM, cuja memristência e ativação baseiam-se no comportamento dinâmico do composto dióxido de vanádio.

O restante deste estudo está organizado da seguinte forma: Nas Seções 2, 3 e 4, são realizadas introduções teóricas sobre os seguintes temas: Redes neurais artificiais, redes neurais pulsadas, plasticidade neural e auto-organização de mapas neurais. Em sequência, na Seção 5, são apresentados os detalhes do modelo proposto por este trabalho. Na Seção 6, é descrita a metodologia de pesquisa e os resultados obtidos são expostos e analisados. Por fim, a Seção 7 encerra este artigo retratando as conclusões finais e propostas de trabalhos futuros.

2 | REDES NEURAIS ARTIFICIAIS

Redes neurais artificiais (RNAs) são modelos computacionais que se baseiam em simular as capacidades cognitivas de um sistema nervoso biológico com o intuito de viabilizar uma estrutura capaz emular o comportamento inteligente do cérebro (HAYKIN, 1994; RAUBER, 2005). Uma RNA é, geralmente, estruturada por diversas unidades de processamento de dados, denominadas “neurônios”, que estão interconectadas entre si, por intermédio de “sinapses”, e propagam informações através de estímulos (HAYKIN, 1994).

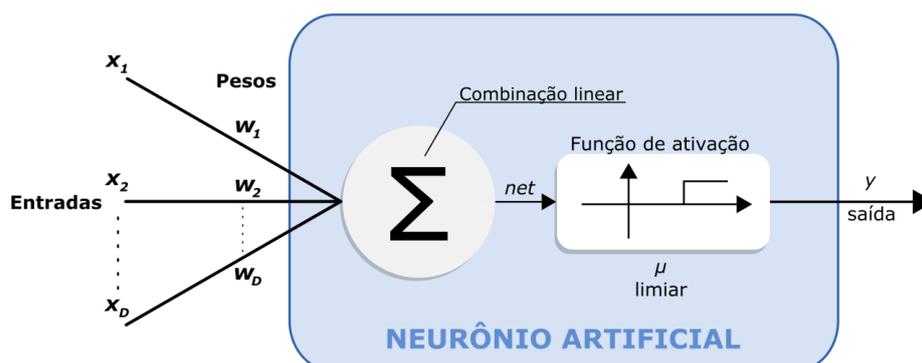


Figura 1 – Modelo de neurônio artificial baseado na concepção de McCulloch e Pitts

A Figura 1 reproduz o consolidado modelo de neurônio artificial proposto pelos cientistas Warren McCulloch e Walter Pitts, em 1943, para representar as dinâmicas biológicas que se manifestam dentro de uma célula do sistema nervoso (MCCOLLOCH e PITTS, 1943). Neste consistente modelo, os impulsos, provenientes de neurônios vizinhos, se tornam entradas x_j que, posteriormente, são adaptadas por seus respectivos pesos sinápticos w_j . Em seguida, é realizada uma combinação linear das entradas que resulta no valor de *net*. O valor de *net*, por sua vez, é comparado com um limiar μ , através da função de heaviside, e o resultado da comparação implica diretamente em um eventual “disparo”, representado pela saída y . A Equação (1) representa, matematicamente, o modelo da Figura 1 em função de y .

$$y = \Theta \left(\sum_{j=1}^D w_j x_j - \mu \right) \quad (1)$$

Um neurônio artificial, regularmente, pode ser estimulado por diferentes tipos de funções de ativação, sendo as mais comuns: A função linear, na qual a saída é um sinal linear contínuo; a função degrau (ou heaviside), que produz uma saída não-linear discreta, e a função sigmoideal, que resulta em uma sinal não-linear contínuo (RAUBER, 2005). As ativações fazem com que impulsos sejam enviados para neurônios vizinhos e proporcionem um constante índice de conectividade na RNA (HAYKIN, 1994).

O conceito de conectividade da RNA está ligado à topologia à qual a mesma está sujeita, ou seja, a forma à qual os neurônios estão distribuídos e interligados entre si (HAYKIN, 1994; RAUBER, 2005). Uma topologia bem estruturada possibilita uma maior fluidez na propagação de informações na RNA (RAUBER, 2005).

As RNAs são, usualmente, implementadas por software e possuem diversas aplicações na resolução de problemas de variadas áreas do conhecimento, através da aptidão das mesmas para reconhecimento de padrões, aprendizagem de máquinas, clustering e mineração de dados (RAUBER, 2005).

Para que a implementação da RNA seja considerada eficiente, é essencial que esta apresente um bom nível de plasticidade neural, característica responsável por tornar a rede mais dinâmica e engenhosa.

3 | PLASTICIDADE NEURAL E AUTO-ORGANIZAÇÃO DE MAPAS NEURAIIS

Por um longo período de tempo, vigorou-se uma preponderante teoria de que, após o seu desenvolvimento, o sistema nervoso central convertia-se em uma estrutura completamente inflexível e sujeita a danos permanentes (FERRARI, 2001). Atualmente, sabe-se que, durante todas as fases da ontogenia, o cérebro continua

evidenciando características de reconstrução e reorganização de suas propriedades morfológicas e funcionais em resposta a experiências vivenciadas (DE OLIVEIRA, 2001; FERRARI, 2001). Esta capacidade cerebral é, frequentemente, denominada “plasticidade neural” e está, diretamente, associada aos processos de aprendizagem, memória e recuperação de lesões no sistema nervoso central (FERRARI, 2001).



Figura 2 – Estágios nos quais ocorre a plasticidade neural

A plasticidade neural, geralmente, acontece nos três estágios ilustrados na Figura 2: Desenvolvimento, aprendizagem e período pós-lesão (DE OLIVEIRA, 2001).

O desenvolvimento de um sistema neural inicia-se na embriogênese e encerra-se, somente, no período extrauterino. Durante este intervalo de tempo, o cérebro sofre diversas influências genéticas, provenientes do microambiente fetal, e externas, fazendo com que a plasticidade seja uma atividade essencial para estruturação das funções do sistema nervoso (DE OLIVEIRA, 2001).

A aprendizagem é um processo que pode ocorrer em qualquer momento da vida e refere-se à capacidade de se adquirir um determinado conhecimento, armazená-lo e integrá-lo, de maneira interconectada, aos demais conhecimentos já persistidos, possibilitando que o mesmo possa ser acessado, posteriormente, quando requisitado (DE OLIVEIRA, 2001). No decorrer do processo de aprendizagem, ocorrem diversas modificações estruturais do sistema nervoso que promovem alterações plásticas como o incremento de neurotransmissores, crescimento de terminações, estreitamento da fenda sináptica, etc (DE OLIVEIRA, 2001).

O ato de aprender novas habilidades motoras também promove reestruturações, ou auto-organizações, no mapa neural do sistema nervoso (DE OLIVEIRA, 2001). Os mapas neurais são responsáveis por estruturar modelos que objetivam constituir repostas a estímulos que o sistema nervoso está sujeito e, durante o processo de aprendizagem, estes se auto-organizam para assegurar uma maior acurácia para com as respostas (SPORNS, 2005).

No período pós-lesão, ou seja, após o sistema nervoso ser afetado por processos lesionários, que em eventuais casos podem necrosar células nervosas, mecanismos de plasticidade neural são acionados e, durante um longo período de tempo, trabalham para reparar e reestruturar o sistema nervoso central, recuperando, entre outras habilidades, sua eficácia sináptica e supersensibilidade de denervação

(DE OLIVEIRA, 2001).

Em suma, a plasticidade neural altera padrões de conectividade no cérebro com o intuito de torná-lo mais “inteligente” e tolerante a falhas.

4 | REDES NEURAIS PULSADAS

Atualmente, as redes neurais pulsadas, ou baseadas em spikes, representam o modelo de RNA cujo funcionamento mais se aproxima de um neurônio biológico natural (MAASS, 1997). Nestes modelos, os sinais de entrada dos neurônios, estando estes em forma de impulsos, podem conter informações ou variáveis codificadas, através da diferença de tempo do intervalo entre os spikes, que, posteriormente, acarretarão, ou não, no disparo do neurônio (MAASS, 1997).

A codificação das informações transmitidas entre neurônios, através de impulsos, está usualmente relacionada à frequência (rate encoding) ou tempo (pulse encoding) dos spikes (GHOSH-DASTIDAR e ADELI, 2009). A codificação por tempo de spikes é, habitualmente, mais eficaz que a codificação por frequência, tendo em mente que esta pode prover uma maior quantidade de informações codificadas, utilizando o mesmo número de neurônios (GHOSH-DASTIDAR e ADELI, 2009).

Enquanto a variável “tempo” é constantemente trivializada em modelos de redes neurais de gerações anteriores, em redes neurais pulsadas, esta é extremamente primordial para um acurado funcionamento do sistema neural (MAASS, 1997). O tempo apresenta uma direta implicância na combinação linear dos potenciais pós-sinápticos excitatórios e inibitórios, resultantes dos disparos de neurônios vizinhos e conectados através de sinapses, que, por intermédio da aplicação de pesos sinápticos e de uma função de ativação pré-estabelecida, pode fazer com que o potencial do neurônio atinja um determinado valor de threshold e, conseqüentemente, efetue o disparo (MAASS, 1997).

Os pesos sinápticos, em redes neurais pulsadas, frequentemente, possuem o papel de restringir os sinais de entrada a valores não nulos, tendo em mente que as sinapses biológicas e, por conseqüência, os potenciais pós-sinápticos, são, estritamente, excitatórias (positivas) ou inibitórias (negativas) (MAASS, 1997). Quando o neurônio não apresenta valores de potenciais pós-sinápticos, é, matematicamente, conveniente assumir que o potencial de ativação equivale a zero e o threshold será sempre maior que zero (MAASS, 1997).

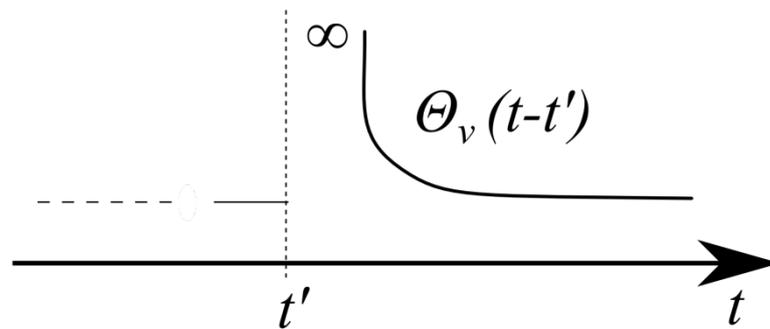


Figura 3 – Representação da função de threshold de um neurônio biológico

Normalmente, a função de threshold, quando bem especificada, é responsável por proporcionar um certo intervalo de tempo entre os disparos do neurônio (MAASS, 1997). Este intervalo é constituído pelas de fases de “repolarização” e “hiperpolarização” (GHOSH-DASTIDAR e ADELI, 2009). Simulando um neurônio biológico em um cenário determinístico (sem ruídos), a Figura 3 evidencia que t' , representando o valor de tempo no qual ocorreu o disparo mais recente, deve, teoricamente, no momento em que $P_v(t)$ equivaler ao valor da função de threshold $\Theta_v(t-t')$, efetuar o disparo. Após o disparo, os potenciais pós-sinápticos se alteram baseando-se nos valores dos tempos dos spikes do próprio neurônio em questão (GHOSH-DASTIDAR e ADELI, 2009).

Este alto nível de detalhamento do funcionamento de uma rede neural pulsada, que promove um maior grau de realidade na emulação de neurônio biológico, por muitas décadas foi, computacionalmente, inviável e mesmo quando ocorreram avanços tecnológicos que possibilitariam o desenvolvimento de tal modelo, os algoritmos de aprendizagem correntes daquela época, devido a suas incompatibilidades com a complexidade de novos paradigmas, se tornaram os gargalos deste progresso (GHOSH-DASTIDAR e ADELI, 2009). Atualmente, grande parte dos estudos que ambicionam promover avanços significativos na estruturação dos modelos de redes neurais pulsadas, foca-se no desenvolvimento de novos algoritmos de aprendizagem que possam suprir as complexidades geradas quando a rede se torna muito grande (GHOSH-DASTIDAR e ADELI, 2009).

Em síntese, diversas pesquisas recentes têm demonstrado que as redes neurais pulsadas apresentam uma grande aptidão para resolver problemas complexos de reconhecimento padrões, como resultado de seu alto potencial de promoção de plasticidade e representação dinâmica, além de apresentar uma notável disposição para codificar, com maior acurácia, as informações transmitidas entre neurônios interconectados.

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

Alicerçando-se nos conceitos apresentados anteriormente, este trabalho almeja apresentar um novo modelo de neurônio, estimulado por impulsos codificados por PRBS (Pseudorandom Binary Sequence) e modulados por PWM (Pulse Width Modulation), cuja memristência e ativação são assentadas pelo comportamento das dinâmicas térmicas e não lineares de transição de fase do composto inorgânico óxido-metalúico dióxido de vanádio (VO_2). É, também, conjecturado que este novo paradigma de neurônio, quando presente em uma RNA pulsada, seja capaz de estabelecer maiores índices de plasticidade sináptica e resistência a ruídos, tornando o sistema neural mais robusto, conectivo, energeticamente econômico e tolerante a falhas.

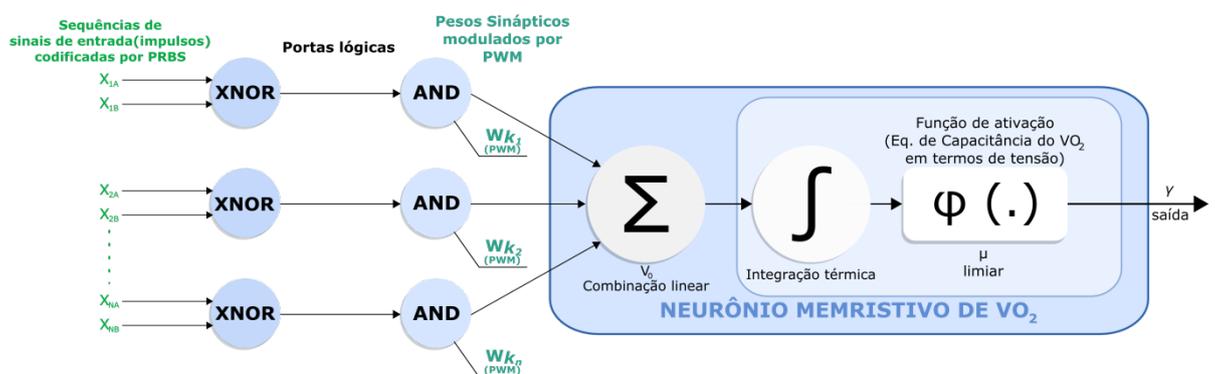


Figura 4 - Modelo de neurônio memristivo de dióxido de vanádio com codificação de impulsos PRBS-PWM

5.1 Codificação de impulsos PRBS-PWM

A Figura 4 ilustra o modelo de neurônio proposto que, a princípio, estaria presente na camada de entrada de uma RNA pulsada, em topologia feedforward, recebendo como input duplas de sequências de sinais analógicos X_{NA} e X_{NB} , com variados graus de ortogonalidade, que, inicialmente, são convertidas em valores binários através da codificação PRBS.

A codificação PRBS representa um padrão de geração de sequências binárias, regularmente utilizado em aplicações para telecomunicações e encriptação, que almeja produzir sinais de saída, estatisticamente, semelhantes a sequências binárias puramente aleatórias (MACWILLIAMS e SLOANE, 1976; SPINLER e XIE, 2007). Apesar de a codificação PRBS ser determinística e estabelecida a partir de um algoritmo computacional definido, devido à alta complexidade de sua geração, o resultado da mesma é de difícil predição e, conseqüentemente, considerado “pseudoaleatório” (MACWILLIAMS e SLOANE, 1976).

No modelo proposto, a codificação PRBS objetiva proporcionar, além de um sólido padrão sequencial para os sinais de entrada, também uma maior robustez a

ruídos, considerando que é esperado que exista um baixo grau de correlação entre as sequências codificadas e os potenciais ruídos em um cenário não-determinístico.

Posteriormente, o operador lógico XNOR apresenta a função de mensurar o grau de correlação entre uma dupla de sequências de entrada. Realizando uma operação bitwise, esta porta lógica determina que quanto maior a correlação entre as sequências binárias, maior será a potência do sinal a ser emitido e, caso as sequências sejam completamente ortogonais, o resultado será nulo e proporcionará um acréscimo no nível de eficiência energética para com o neurônio e, conseqüentemente, para com a RNA.

Os pesos sinápticos Wk_n do neurônio são aplicados por portas AND que realizam multiplicações binárias entre as saídas das portas XNOR e determinados sinais de tensão modulados por variáveis duty cycles de PWM. A técnica de PWM, empregada no modelo de neurônio proposto, tem o papel de regular as larguras dos pulsos de ondas quadradas que controlam a potência dos sinais que representam os pesos a serem multiplicados pela correlação das sequências binárias resultantes da operação lógica de coincidência (XNOR).

Esta proposta de mecânica de pré-processamento neural, potencialmente, acarretará na redução do custo energético de operações computacionais realizadas pela RNA, observando-se que caso as entradas de um determinado neurônio sejam, integralmente, não-correlacionadas, nenhum processamento será realizado e o neurônio permanecerá em repouso aguardando novas excitações.

5.2 Memristência e ativação do neurônio de dióxido de vanádio (VO_2)

No modelo de neurônio proposto, e evidenciado pela Figura 4, após a aplicação dos pesos sinápticos Wk_n , é realizada uma combinação linear das sequências de entrada que resultam no somatório V_0 demonstrado em (2).

$$V_0 = \sum (X_{NA} \odot X_{NB}) \wedge Wk_n \quad (2)$$

O valor de V_0 , por sua vez, é incorporado ao valor de entrada da tensão V , como retratado em (3).

$$V = V \times V_0 \quad (3)$$

Almejando obter um maior nível de memristência quando aplicado a uma RNA, o modelo de neurônio proposto utiliza das características intrínsecas de transição de fase de estado sólido do composto inorgânico VO_2 quando apresentado em forma de filme de fino (ALMEIDA, 2003).

Esta transição de fase do filme fino de VO_2 é instigada por variações de temperatura e modifica, significativamente, as propriedades elétricas e cristalográficas do composto, alterando sua qualidade de semicondutor para metal e, conseqüentemente, seu sistema cristalino tetragonal para monoclinico,

caracterizando uma transformação de fase de primeira ordem (ALMEIDA, 2003).

$$C \frac{dT}{dt} = \frac{V^2}{R(t)} - G(T - T_s) \quad (4)$$

$$C \frac{dT}{dt} = I^2 R(t) - G(T - T_s) \quad (5)$$

A Equação (4) resulta no valor da capacitância térmica C , sendo esta apresentada em forma da taxa de variação da temperatura T em relação ao tempo t , que é calculada com base na diferença entre o valor da condutância térmica G e a relação de dependência entre o valor da tensão de polarização V^2 e a resistência elétrica em relação ao tempo $R(t)$ (ALMEIDA, 2003). Ainda na mesma equação, a condutância térmica G reflete a perda de calor entre a temperatura do filme T e a temperatura do substrato T_s . É constatado, experimentalmente, que uma curva característica RXT , quando em transição de fase semicondutor-metal, sempre produz fenômenos histeréticos (ALMEIDA, 2003). Neste trabalho, as dinâmicas histeréticas reproduzidas pela evolução da fração volumétrica dos microcristais do filme fino de VO_2 , em função da temperatura, são descritas baseando-se no modelo L^2P (Limiting Loop Proximity) (ALMEIDA, 2003).

A partir da Equação (4), é possível inferir também que, quando apresentada em termos de tensão, a região crítica das dinâmicas histeréticas reproduzidas pelo filme fino de VO_2 é muito mais sensível do que quando a mesma se encontra em termos de corrente, como evidenciado em (5), considerando que no caso da aplicação de tensão, a relação de dependência entre potência e resistência é inversamente proporcional, enquanto para a corrente, o seu valor aumenta o quadrado vezes a resistência, proporcionando um comportamento muito mais linear.

$$T = \frac{1}{C} \int \left[\frac{V^2}{R(t)} - G(T - T_s) \right] dt \quad (6)$$

A função de ativação do modelo de neurônio proposto, descrita em (4), está associada à taxa de variação da capacitância térmica C que quando alcança um valor pré-determinado de resistência elétrica, em relação ao tempo, atinge o valor do limiar de ativação μ , e efetua o disparo do neurônio, evidenciado pela saída y . A Equação (6), por sua vez, descreve a integração térmica das entradas que resultam na temperatura T de entrada da função de threshold do neurônio.

6 | METODOLOGIA E RESULTADOS DAS SIMULAÇÕES

Com intuito de validar o modelo proposto, foi desenvolvido um script, utilizando o software interativo MATLAB, que, a partir de parâmetros pré-definidos e variadas entradas de tensão e duty cycles de PWM, emula o comportamento dinâmico descrito

em (4) e possibilita a averiguação de diversos cenários que acarretam, ou não, no disparo do neurônio.

Almejando adquirir resultados mais acurados na obtenção de soluções numéricas para a Equação (4), foi implementada uma versão built in do método Runge-Kutta de 4ª Ordem, ou RK4.

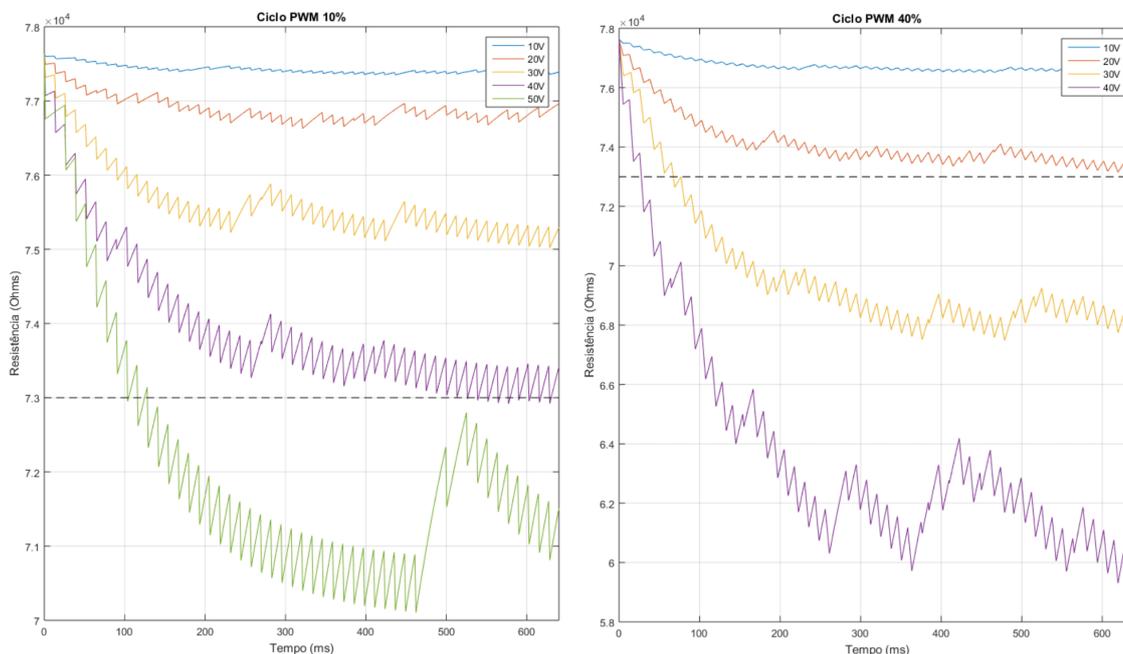


Figura 5 - Resultados das simulações com tensões variáveis [10V, 20V, 30V, 40V e 50V], duty cycles de 10% e 40% de PWM e um acréscimo de uma taxa de 40% de ortogonalidade entre as sequências de entrada

Na Figura 5, o valor do limiar de ativação μ está fixado na resistência elétrica de $7.3 \times 10^4 \Omega$ e foi acrescentada uma taxa de 40% de ortogonalidade, ou não-correlação, às sequências binárias pré-sinápticas de entrada. Como previsto na concepção da ativação do neurônio proposto, e demonstrado em (4), valores maiores de tensão apresentam uma maior sensibilidade de ativação, portanto, focando-se exclusivamente no comportamento do sistema quando excitado com uma tensão de 40V, modulado por um duty cycle de 10% de PWM e com o acréscimo de uma taxa de 40% de ortogonalidade entre as sequências de entrada, nota-se que a ativação ocorre em um tempo um pouco superior a 500ms e, sob as mesmas condições de potência e taxa de ortogonalidade, porém com um duty cycle de 40% de PWM, a ativação ocorre em menos de 100ms. Tal averiguação salienta o mérito da regulagem das larguras dos pulsos de ondas quadradas na ativação do neurônio e demonstra que um cenário com uma modulação PWM de menor potência oferece um controle mais robusto para com eventuais disparos.

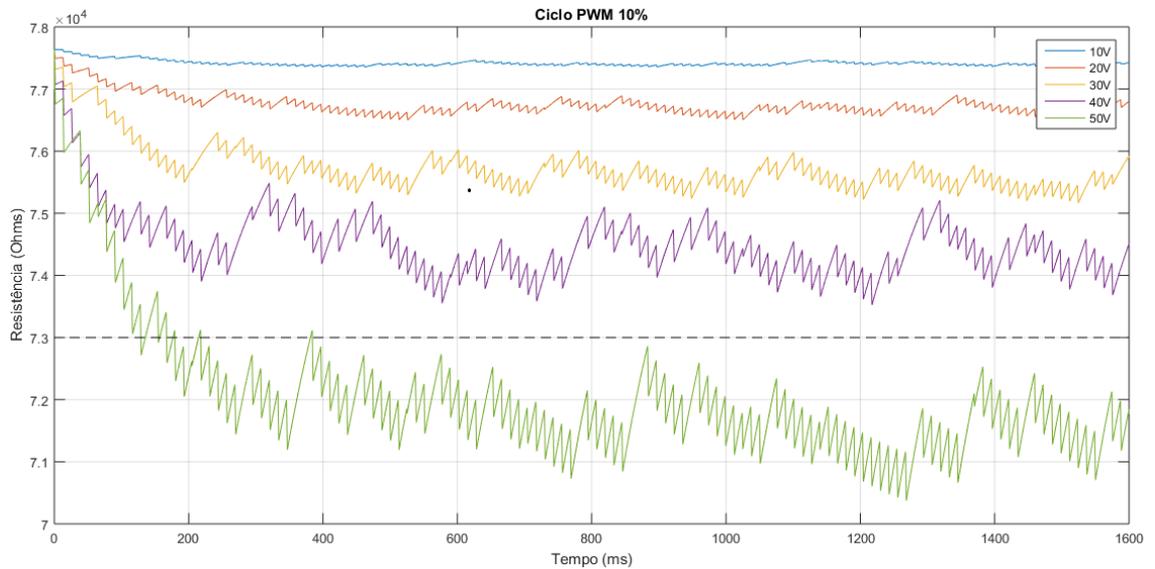


Figura 6 - Resultado das simulações com tensões variáveis [10V, 20V, 30V, 40V e 50V], duty cycle de 10% de PWM e um acréscimo de uma taxa de 98% de ortogonalidade entre as sequências de entrada

A Figura 6 representa uma conjuntura com condições iniciais semelhantes as da Figura 5, porém com a adição de uma taxa de 98% de ortogonalidade entre as sequências de entrada e um maior intervalo de tempo de execução. Nota-se que quando as sequências de entrada são acrescidas com uma taxa de ortogonalidade próxima de 100% e, novamente, focando-se exclusivamente no comportamento do sistema quando excitado com uma tensão de 40V e modulado por um duty cycle de 10% de PWM, é possível verificar que mesmo em um intervalo de tempo muito superior, neste caso, de 1600ms, o neurônio nunca é ativado. Esta constatação evidencia o notável papel do modelo proposto na redução do custo energético de operações computacionais dentro de uma RNA, considerando que quanto menor a correlação entre as sequências de entrada, maior será o período de repouso do neurônio.

7 | CONCLUSÕES

Este trabalho, respaldando-se nos conceitos apresentados em seu encetamento, asseverou a relevância e robustez do modelo de neurônio proposto para com o principal desígnio da computação neuromórfica: A economia energética.

As simulações computacionais realizadas demonstraram que a aplicação da codificação de impulsos PRBS-PWM, em conjunto com um acurado controle de taxas de ortogonalidade entre as sequências de entrada, fazem com que este modelo de neurônio, ativado a partir da taxa de variação da capacitância térmica do composto inorgânico dióxido de vanádio, seja uma eficiente alternativa para, futuramente, estruturar redes neurais pulsadas mais energeticamente eficientes, vigorosas,

conectivas, tolerante a falhas e que proporcionem um maior nível de plasticidade neural.

Em trabalhos futuros, serão analisados, mais profundamente, os resultados e o comportamento de simulações computacionais utilizando de excitações com variadas entradas de tensão, corrente elétrica e taxas de ortogonalidade. Almeja-se também o projeto de um software simulador, a ser desenvolvido em uma linguagem orientada a objetos, que seja capaz de emular o completo funcionamento de uma RNA constituída por neurônios baseados no modelo proposto neste estudo.

AGRADECIMENTOS

Os autores agradecem à Universidade Federal do ABC (UFABC) por viabilizar a realização desta pesquisa.

REFERÊNCIAS

- ALMEIDA, L. A. L. **Modelo de histerese para transição semicondutor-metal em filmes finos de VO₂**. Faculdade de Engenharia Elétrica da Universidade Federal de Campina Grande, 2003.
- CHENG, Zengguang et al. **On-chip photonic synapse**. Science advances, v. 3, n. 9, p. e1700160, 2017.
- DE OLIVEIRA, Claudia Eunice Neves; SALINA, Maria Elisabete; ANNUNCIATO, Nelson Francisco. **Fatores ambientais que influenciam a plasticidade do SNC**. Acta Fisiátrica, v. 8, n. 1, p. 6-13, 2001.
- FERRARI, Elenice A. et al. **Plasticidade neural: relações com o comportamento e abordagens experimentais**. Psicologia: teoria e pesquisa, 2001.
- GHOSH-DASTIDAR, Samanwoy; ADELI, Hojjat. **Spiking neural networks**. International journal of neural systems, v. 19, n. 04, p. 295-308, 2009.
- HAYKIN, Simon. **Neural networks: a comprehensive foundation**. Prentice Hall PTR, 1994.
- INDIVERI, Giacomo; CHICCA, Elisabetta; DOUGLAS, Rodney J. **Artificial cognitive systems: From VLSI networks of spiking neurons to neuromorphic cognition**. Cognitive Computation, v. 1, n. 2, p. 119-127, 2009.
- JO, Sung Hyun et al. **Nanoscale memristor device as synapse in neuromorphic systems**. Nano letters, v. 10, n. 4, p. 1297-1301, 2010.
- KUMAR, Ankit; MOHANTY, Pritiraj. **Autoassociative memory and pattern recognition in micromechanical oscillator network**. Scientific reports, v. 7, n. 1, p. 411, 2017.
- MAASS, Wolfgang. **Networks of spiking neurons: the third generation of neural network models**. Neural networks, v. 10, n. 9, p. 1659-1671, 1997.
- MACWILLIAMS, F. Jessie; SLOANE, Neil JA. **Pseudo-random sequences and arrays**. Proceedings of the IEEE, v. 64, n. 12, p. 1715-1729, 1976.

- MCCULLOCH, Warren S.; PITTS, Walter. **A logical calculus of the ideas immanent in nervous activity**. The bulletin of mathematical biophysics, v. 5, n. 4, p. 115-133, 1943.
- MEAD, Carver. **Neuromorphic electronic systems**. Proceedings of the IEEE, v. 78, n. 10, p. 1629-1636, 1990.
- MERKEL, Cory et al. **Neuromemristive systems: Boosting efficiency through brain-inspired computing**. Computer, v. 49, n. 10, p. 56-64, 2016.
- RAUBER, Thomas Walter. **Redes neurais artificiais**. Universidade Federal do Espírito Santo, 2005.
- SPINNLER, B.; XIE, C. **Performance assessment of DQPSK using pseudo-random quaternary sequences**. In: 33rd European Conference and Exhibition of Optical Communication. VDE, 2007. p. 1-2.
- SPORNS, Olaf; TONONI, Giulio; KÖTTER, Rolf. **The human connectome: a structural description of the human brain**. PLoS computational biology, v. 1, n. 4, p. e42, 2005.
- TSODYKS, Misha; PAWELZIK, Klaus; MARKRAM, Henry. **Neural networks with dynamic synapses**. Neural computation, v. 10, n. 4, p. 821-835, 1998.
- WALDROP, M. Mitchell. **The chips are down for Moore's law**. Nature News, v. 530, n. 7589, p. 144, 2016.
- WRIGHT, C. David; HOSSEINI, Peiman; DIOSDADO, Jorge A. Vazquez. **Beyond von-Neumann computing with nanoscale phase-change memory devices**. Advanced Functional Materials, v. 23, n. 18, p. 2248-2254, 2013.
- XIA, Lixue et al. **MNSIM: Simulation platform for memristor-based neuromorphic computing system**. IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems, v. 37, n. 5, p. 1009-1022, 2017.

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