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***

* Programa de Pós-Graduação em Engenharia da Informação,
Universidade Federal do ABC, SP, (e-mail:
rennan.araujo@ufabc.edu.br).

** Programa de Pós-Graduação em Engenharia da Informação,
Universidade Federal do ABC, SP, (e-mail: luiz.almeida@ufabc.edu.br)

*** Programa de Pós-Graduação em Engenharia da Informação,
Universidade Federal do ABC, SP, (e-mail: oiwa.costa@ufabc.edu.br)

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.

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.

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

Palavras-chave: Codificação de Impulsos PRBS-PWM; Eficiência Energética; Dióxido de Vanádio; Memristência; Redes Neurais Pulsadas; Plasticidade Neural.

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 et al., 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,

dobriaria, 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 et al., 2010). Nesta nova abordagem, toda a manipu-

lação 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 et al., 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 et al., 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 et al., 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 micromecânicos (Kumar and Mohanty, 2017). Os resultados revelaram que a computação neuromórfica, quando aplicada de maneira física em um sistema de osciladores micromecânicos, 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 and 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 et al., 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 et al., 2018).

Grande parte das pesquisas recentes, no campo da computação neuromórfica, está direcionada a aplicações e simu-

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

lações 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 et al., 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 et al., 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 et al., 2010).

A plasticidade sináptica neural refere-se à capacidade de um sistema neural se reestruturar em resposta a experiências ou estímulos (Tsodyks et al., 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 et al., 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: Na 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).

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 (McCulloch and 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 sigmoidal, 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 NEURAIS

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 et al., 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 et al., 2001; Ferrari et al., 2001). Esta capacidade cerebral é, frequentemente, denominada “plasticidade neural” e está, diretamente, associada aos processos de aprendizagem, memória e recupe-

Figura 2. Estágios nos quais ocorre a plasticidade neural

ração de lesões no sistema nervoso central (Ferrari et al., 2001).

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

O ato de aprender novas habilidades motoras também promove reestruturações, ou auto-organizações, no mapa neural do sistema nervoso (de Oliveira et al., 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 repostas (Sporns et al., 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 et al., 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).

Figura 3. Representação da função de *threshold* de um neurônio biológico

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 and 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 and 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 consequência, 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).

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 and 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 and 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 dé-

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

cadadas 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 and 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 and 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 asentadas pelo comportamento das dinâmicas térmicas e não lineares de transição de fase do composto inorgânico óxido-metálico 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.

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 and Sloane, 1976; Spinnler and 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, consequentemente, considerado “pseudoaleatório” (MacWilliams and 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, consequentemente, 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 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, consequentemente, 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 $R \times T$, 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 a 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

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

Figura 6. Resultados 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

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.

Na Figura 5, o valor do limiar de ativação 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 regulação 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.

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. CONCLUSÃO

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, à 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. (2003). Modelo de histerese para transição semicondutor-metal em filmes finos de vo2. *Faculdade de Engenharia Elétrica da Universidade Federal de Campina Grande*.
- Cheng, Z., Ríos, C., Pernice, W.H., Wright, C.D., and Bhaskaran, H. (2017). On-chip photonic synapse. *Science advances*, 3(9), e1700160.
- de Oliveira, C.E.N., Salina, M.E., and Annunziato, N.F. (2001). Fatores ambientais que influenciam a plasticidade do snc. *Acta Fisiológica*, 8(1), 6–13.

- Ferrari, E.A., Toyoda, M.S.S., Faleiros, L., Cerutti, S.M., et al. (2001). Plasticidade neural: relações com o comportamento e abordagens experimentais. *Psicologia: teoria e pesquisa*.
- Ghosh-Dastidar, S. and Adeli, H. (2009). Spiking neural networks. *International journal of neural systems*, 19(04), 295–308.
- Haykin, S. (1994). *Neural networks: a comprehensive foundation*. Prentice Hall PTR.
- Indiveri, G., Chicca, E., and Douglas, R.J. (2009). Artificial cognitive systems: From vlsi networks of spiking neurons to neuromorphic cognition. *Cognitive Computation*, 1(2), 119–127.
- Jo, S.H., Chang, T., Ebong, I., Bhadviya, B.B., Mazumder, P., and Lu, W. (2010). Nanoscale memristor device as synapse in neuromorphic systems. *Nano letters*, 10(4), 1297–1301.
- Kumar, A. and Mohanty, P. (2017). Autoassociative memory and pattern recognition in micromechanical oscillator network. *Scientific reports*, 7(1), 411.
- Maass, W. (1997). Networks of spiking neurons: the third generation of neural network models. *Neural networks*, 10(9), 1659–1671.
- MacWilliams, F.J. and Sloane, N.J. (1976). Pseudo-random sequences and arrays. *Proceedings of the IEEE*, 64(12), 1715–1729.
- McCulloch, W.S. and Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, 5(4), 115–133.
- Mead, C. (1990). Neuromorphic electronic systems. *Proceedings of the IEEE*, 78(10), 1629–1636.
- Merkel, C., Hasan, R., Soures, N., Kudithipudi, D., Taha, T., Agarwal, S., and Marinella, M. (2016). Neuro-memristive systems: Boosting efficiency through brain-inspired computing. *Computer*, 49(10), 56–64.
- Rauber, T.W. (2005). Redes neurais artificiais. *Universidade Federal do Espírito Santo*.
- Spinnler, B. and Xie, C. (2007). Performance assessment of dqpsk using pseudo-random quaternary sequences. In *33rd European Conference and Exhibition of Optical Communication*, 1–2. VDE.
- Sporns, O., Tononi, G., and Kötter, R. (2005). The human connectome: a structural description of the human brain. *PLoS computational biology*, 1(4), e42.
- Tsodyks, M., Pawelzik, K., and Markram, H. (1998). Neural networks with dynamic synapses. *Neural computation*, 10(4), 821–835.
- Waldrop, M.M. (2016). The chips are down for moore's law. *Nature News*, 530(7589), 144.
- Wright, C.D., Hosseini, P., and Diosdado, J.A.V. (2013). Beyond von-neumann computing with nanoscale phase-change memory devices. *Advanced Functional Materials*, 23(18), 2248–2254.
- Xia, L., Li, B., Tang, T., Gu, P., Chen, P.Y., Yu, S., Cao, Y., Wang, Y., Xie, Y., and Yang, H. (2018). Mnsim: Simulation platform for memristor-based neuromorphic computing system. *IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems*, 37(5), 1009–1022.