

ANÁLISE DA VIABILIDADE PARA DESENVOLVIMENTO DE ARQUITETURA NEUROMÓRFICA DE BAIXA POTÊNCIA VISANDO A IMPLEMENTAÇÃO DE UM CONTROLADOR MPPT PARA CÉLULA SOLAR FOTOVOLTAICA EM UM SISTEMA DE ENERGY HARVESTING

Phillipe de Carvalho T. R. Ferreira¹ (IC), Gabriel A. Fanelli de Souza (PQ)¹

¹Universidade Federal de Itajubá

Palavras-chave: Energy harvesting. Fuzzy. MPPT. Redes neurais.

Introdução

Diversos circuitos neuromórficos tem sido desenvolvidos e apresentados ao longo dos últimos anos devido ao seu alto potencial de executar algoritmos de inteligência artificial e aprendizado de máquina com baixo consumo de potência [1]. Tais arquiteturas apresentam-se altamente promissoras para serem implementadas nos mais diversos campos, como o de energy harvesting, substituindo de forma mais eficiente arquiteturas já concretizadas no ramo, como os sistemas de inferência Fuzzy [2]. Esta pesquisa tem como objetivo verificar a viabilidade e eficiência de um circuito integrado que implementa o modelo genérico de um neurônio, que será produzido em tecnologia TSMC 180 nanômetros em convênio com a Universidade Federal de Itajubá, para uma rede neural (RN) do tipo ELM (Extreme Learning Machine) que será utilizada como rastreador de ponto de máxima potência (MPPT) de aplicações de energy harvesting fotovoltaicos e terá como base sistemas de inferência Fuzzy, comumente utilizados para tais finalidades. Para tal objetivo serão utilizados dados advindos do protótipo do neurônio para os pesos de entrada e treinamento da RN a fim de se comparar com MPPTs baseados em lógica Fuzzy encontrados na literatura comparando o erro absoluto e erro médio quadrático (EMQ) entre as superfícies de controle geradas pelo MPPT Fuzzy e as redes neurais. Posteriormente o desempenho do MPPT controlado pela RN será comparado em ambiente de simulação com o MPPT controlado por sistemas de inferência Fuzzy com o intuito de comparar duty cycles, tensões e potências reguladas no controle de painéis fotovoltaicos.

Metodologia

O projeto do neurônio foi concebido em [3]. A partir deste projeto é necessário trazer os dados ao software MATLAB para realizar o treinamento da RN e compará-la ao controlador de lógica Fuzzy (FLC), utilizando a metodologia desenvolvida em [4], com a diferença de que serão utilizados dados experimentais

simulados de hardware para os pesos de entrada. Tais dados foram obtidos através da varredura de todas as entradas salvando a resposta dada pelo neurônio, simulando ao todo 100 neurônios. Após o término do treinamento da RN são obtidas as superfícies de controle (SC) vindas do FLC e da RN, sendo assim gerada a superfície de erro absoluto entre as SCs e o EMQ. Uma observação interessante sobre o aprendizado da RN do tipo ELM, é que esta rede busca otimizar seus pesos de modo a diminuir o EMQ apresentado na sua aproximação, porém para aplicações fotovoltaicas a SC gerada não precisa necessariamente apresentar o menor erro possível em toda sua extensão. Devido ao formato das curvas características de um painel fotovoltaico, o ponto de estabilização geralmente se encontra próximo da origem da superfície de controle, deste modo, contanto que a SC conduza a aplicação a sua origem, a única região que necessariamente carece ser precisa é a origem, de modo a possibilitar que o duty cycle fornecido pela RN seja o mais estável e preciso possível para rastrear e manter o MPP a todo momento.

Portanto uma comparação somente visual entre a SC vinda da RN e a SC do FLC pode levar a uma interpretação incorreta, sendo mais interessante analisar se na região de origem da superfície de erro absoluto o erro está próximo de zero, mas ainda se faz necessário levar ambos os controladores a ambiente de simulação SIMULINK para atuarem como MPPTs de cenários fotovoltaicos já desenvolvidos em [4] a fim de verificar se os parâmetros regulados (duty cycle (D), tensão e potência) estão dentro do desejado. Como base foram utilizados dois MPPT-FLC retirados da literatura [5 e 6], já analisados em [4].

Resultados e discussão

A seguir são apresentados as SCs obtidas dos FLC e RNs, assim como as superfícies de erro absoluto e o EMQ presente em cada situação.

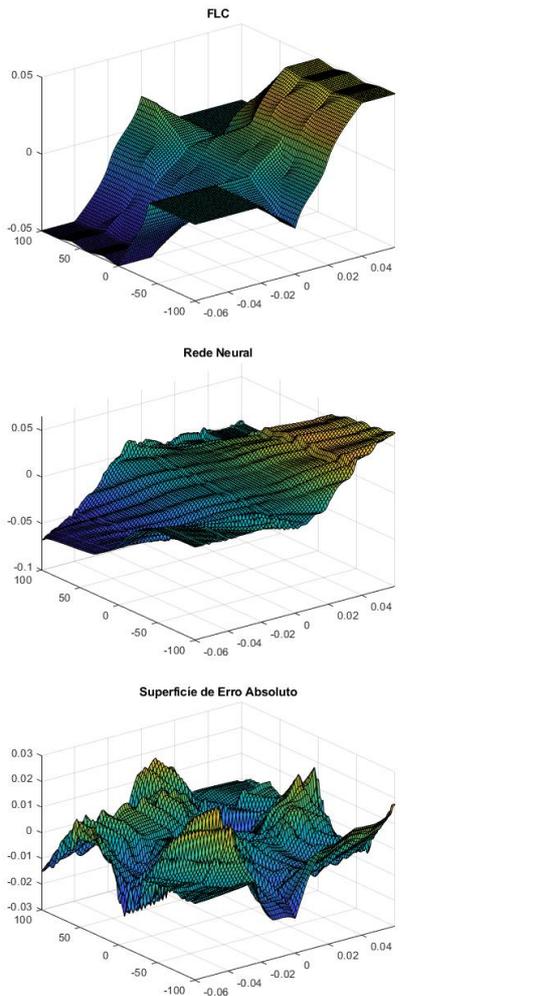


Figura 1 – SCs geradas para [5] e superfície de erro absoluto.

A figura 1 exhibe as SCs de controle obtidas para o artigo [5] e a superfície de erro absoluto entre as SCs, o EMQ foi de $3,8870 \cdot 10^{-5}$.

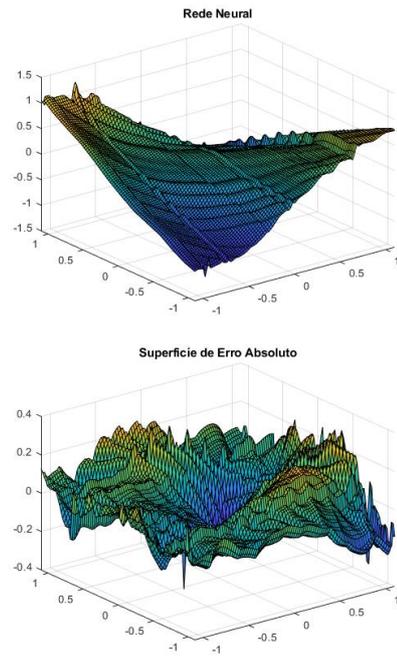
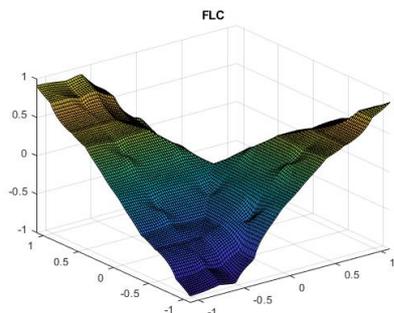


Figura 2 – SCs geradas para [6] e superfície de erro absoluto.

A figura 2 exhibe as SCs de controle obtidas para o artigo [14] e a superfície de erro absoluto entre as SCs, o EMQ foi de $9,2821 \cdot 10^{-3}$.

Tabela 1: Comparação entre EMQ obtidos em [4] e atuais

Ref.	Número de neurônios	EMQ obtidos em [4]	EMQ Atual (100 neurônios)
[5]	100	6,4930E-06	3,8870E-5
	70	7,9028E-06	
	50	1,1753E-05	
	10	2,4742E-05	
[6]	100	1,0399E-03	9,2821E-3
	50	1,0931E-03	
	25	1,2314E-03	
	10	1,3293E-03	

A tabela 1 apresenta um resumo dos EMQs obtidos em [4] e os compara com os EMQs obtidos com a RN treinada utilizando dados vindos do projeto em hardware do neurônio. A seguir são exibidos os resultados obtidos utilizando os FLCs e a RNs como MPPTs fotovoltaicos.

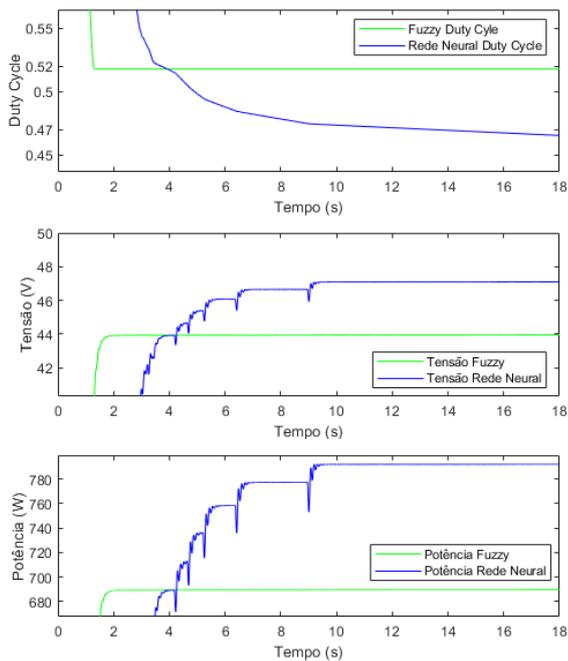


Figura 3 – Comparação entre parâmetros regulados pelo MPPT [5] e a RN

A figura 3 apresenta duty cycle, tensão e potência regulados pelo MPPT-FLC e o MPPT-RN do artigo [5]. O duty cycle regulado pelo FLC estabiliza em 52% enquanto o regulado pela RN estabiliza em 47%. A tensão regulada pelo FLC estabiliza em 44V enquanto a regulada pela RN é 47V. A potência regulada pelo FLC é de 690W enquanto a regulada pela RN é de 790W. Os valores alvos determinados em [4] para duty cycle, tensão e potência eram respectivamente 44,5%, 47V e 800W.

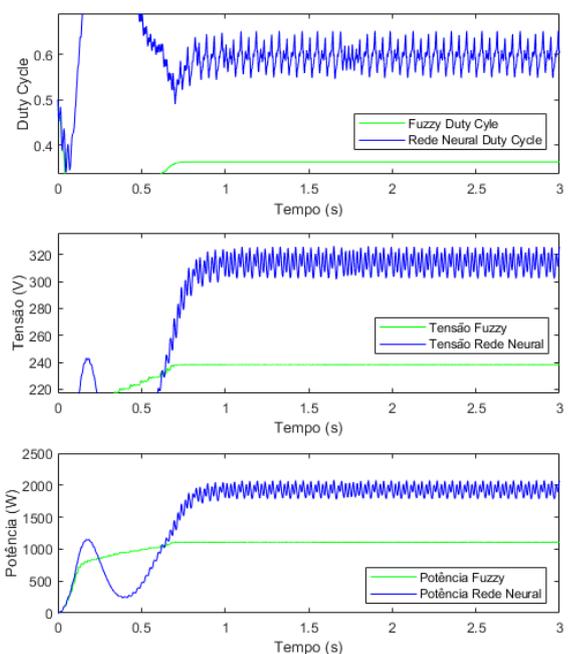


Figura 4 – Comparação entre parâmetros regulados pelo

MPPT [6] e a RN

A figura 4 apresenta duty cycle, tensão e potência regulados pelo MPPT-FLC e o MPPT-RN do artigo [6]. O duty cycle regulado pelo FLC estabiliza em 37% enquanto o regulado pela RN estabiliza em $(60 \pm 3)\%$. A tensão regulada pelo FLC estabiliza em 238V enquanto a regulada pela RN é $(315 \pm 6)V$. A potência regulada pelo FLC é de 1110W enquanto a regulada pela RN é de $(1920 \pm 100)W$. Os valores alvos determinados em [4] para duty cycle, tensão e potência eram respectivamente $(59 \pm 3)\%$, $(317 \pm 6)V$ e $(1950 \pm 100)W$.

Afim de demonstrar a dinâmica do MPPT desenvolvido ao longo de variações climáticas a irradiância disponível aos painéis fotovoltaicos foi variada de forma a deslocar a localização do ponto de máxima potência. Sendo assim a potência disponível varia mas o MPPT deve manter a tensão no patamar de saída desejado.

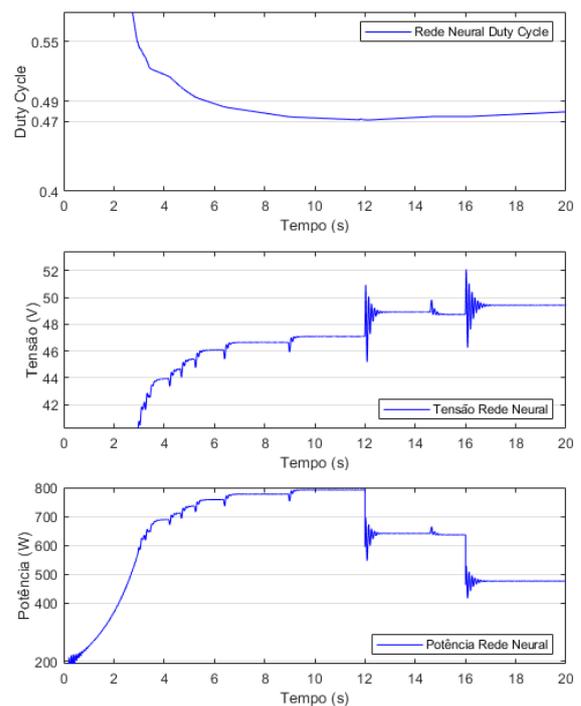


Figura 5 – Desempenho da RN [5] para diferentes valores de irradiância.

A figura 5 demonstra o desempenho da RN [5] ao longo da variação de irradiância disponível, sendo estas $(1000, 800 \text{ e } 600)W/m^2$ respectivamente de 0 a 12 segundos, 12 a 16 segundos e de 16 a 20 segundos.

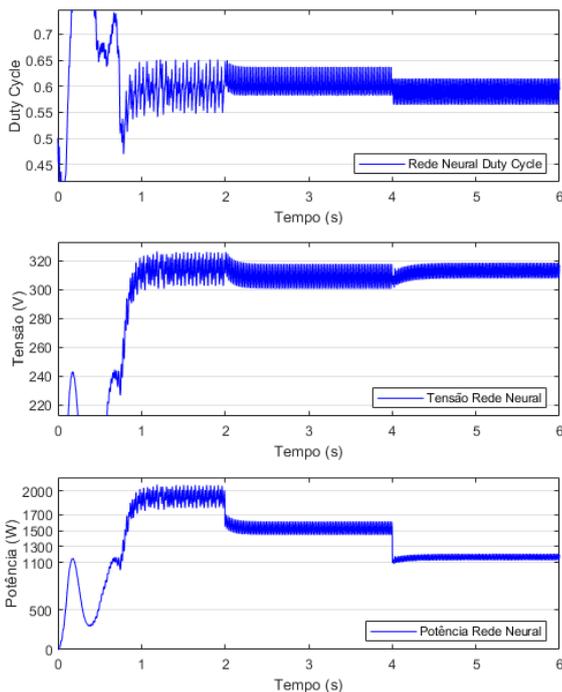


Figura 6 – Desempenho da RN [6] para diferentes valores de irradiância.

A figura 6 demonstra o desempenho da RN [6] ao longo da variação de irradiância disponível, sendo estas (1000, 800 e 600)W/m² respectivamente de 0 a 2 segundos, 2 a 4 segundos e de 4 a 6 segundos.

Conclusões

A partir dos resultados apresentados é possível concluir acertadamente que as redes neurais de tipo ELM desenvolvidas nesta pesquisa, treinadas com a resposta do protótipo de neurônio desenvolvido para hardware tendo como dados alvos/referência valores advindos de controladores baseados em lógica Fuzzy, conseguiram aproximar todas as superfícies de controle propostas, apresentando valores baixos de erro absoluto e erro médio quadrático. Também performaram com êxito suas funções como rastreadores do máximo ponto de potência para painéis fotovoltaicos atingindo de forma satisfatória os valores esperados de duty cycle, tensão e potência.

Sendo assim é esperado que o modelo de neurônio desenvolvido em hardware, tendo como base espelhos de corrente, produzido em uma rodada de fabricação acadêmica disponibilizada pela Universidade Federal de Itajubá, 2022, em tecnologia TSMC 180 nanômetros, performe apropriadamente sua função de neurônio para a camada de pesos de entrada da rede neural ELM.

Agradecimento

Agradeço ao CNPq, por proporcionar suporte financeiro a esta pesquisa, sem o qual a mesma não teria sido possível

Referências

- [1] BINAS, Jonathan et al. Precise deep neural network computation on imprecise low-power analog hardware. arXiv: Computer Science/Neural and Evolutionary Computing, v. 1606, n. 1606.07786, p. 0-0, 2016.
- [2] THAKUR, Chetan Singh et al. A low power trainable neuromorphic integrated circuit that is tolerant to device mismatch. IEEE Transactions on Circuits and Systems I: Regular Papers, v. 63, n. 2, p. 211-221, 2016.
- [3] MELO, J. Análise e projeto de um circuito neuromórfico para aplicações de baixa potência. UNIFEI, Itajubá, 2022.
- [4] FERREIRA, P. Análise da viabilidade para desenvolvimento de arquitetura neuromórfica de baixa potência visando a implementação de um controlador MPPT para célula solar fotovoltaica em um sistema de energy harvesting. UNIFEI, Itajubá, 2021.
- [5] BENDIB, B. et al. Advanced Fuzzy MPPT Controller for a stand-alone PV system. Energy Procedia, v. 50, p. 383-392, 2014.
- [6] ALTIN, Necmi. Single phase grid interactive PV system with MPPT capability based on type-2 Fuzzy logic systems. In: 2012 International Conference on Renewable Energy Research and Applications (ICRERA). IEEE, 2012. p. 1-6.