

Aplicação de redes neurais artificiais para rastreamento de ponto de máxima potência em painel solar aplicado a um conversor Cúk

Luiz Fernando Marquez Arruda*
Moises Ferber de Vieira Lessa** Diego Santos Greff***

* PGESE - Programa de Pós-graduação em Engenharia de Sistemas Eletrônicos, Universidade Federal de Santa Catarina, SC, (e-mail: eng.luizarruda@gmail.com)

** PPGESE - Programa de Pós-graduação em Engenharia de Sistemas Eletrônicos, Universidade Federal de Santa Catarina, SC, (e-mail: moises.ferber@ufsc.br)

*** PPGESE - Programa de Pós-graduação em Engenharia de Sistemas Eletrônicos, Universidade Federal de Santa Catarina, SC, (e-mail: diego.greff@ufsc.br)

Abstract: This article presents a study on the application of artificial neural networks as a maximum power point tracking algorithm (MPPT) in photovoltaic systems. To find the duty cycle of converters faster and deliver a higher power to the load, a neural network is proposed as an improvement of the MPPT algorithm. A comparison is made between the use of a classic MPPT and the trained neural network. The PSIM software will be used to simulate photovoltaic systems and Python for programming and training the artificial neural network. The results show a clear improvement in performance by the proposed method in comparison to the classic Perturb and Observe.

Resumo: Este artigo apresenta um estudo sobre a aplicação de redes neurais artificiais como algoritmo de rastreamento de ponto de máxima potência (MPPT) em sistemas fotovoltaicos aplicado a um conversor CC-CC Cúk. Visando encontrar de forma mais rápida a razão cíclica da chave de comutação em conversores CC/CC e entregar uma maior potência a carga, é proposta uma rede neural como melhoria de algoritmo MPPT. É feita uma comparação entre o uso de MPPT clássico e da rede neural treinada. Será utilizado o software PSIM para simulação de sistemas fotovoltaicos e Python para programação e treinamento da rede neural artificial. Os resultados mostram uma melhora clara do método proposto quando comparado ao método clássico "Perturba e Observa".

Keywords: DC/DC Converter, Maximum Power Point Tracker, MPPT, Artificial Neural Network, ANN, Photovoltaic Solar Energy.

Palavras-chaves: Conversor CC/CC, Rastreamento de Ponto de Máxima Potência, MPPT, Redes Neurais Artificiais, RNA, Energia Solar Fotovoltaica.

1. INTRODUÇÃO

O crescimento populacional, os avanços tecnológicos e as instalações industriais requerem grandes quantidades de energia elétrica e este número se eleva com o passar dos anos. Segundo o relatório da EPE (2020), a matriz energética brasileira no ano de 2018 foi composta por fontes renováveis (66.6% de Hidráulica, 8.5% Biomassa, 7.6% Eólica e 0.5% de Energia Solar) e não renováveis (8.6% de Gás Natural, 3.2% Carvão e Derivados, 2.5% Nuclear e 2.4% Derivados de Petróleo). Conforme o relatório, a principal fonte de energia elétrica brasileira é a hídrica, que embora seja uma fonte renovável, normalmente demanda grandes áreas de inundação de florestas para as barragens,

e está sujeito ao regime de chuvas variáveis. Em segundo lugar tem-se as termoelétricas, usuárias pelas fontes não renováveis, que realizam a queima de combustível fóssil para geração de energia e como consequência gera alto dano ao meio ambiente, especialmente na emissão de CO_2 (valor aproximado e 88 $kgCO_2/MWh$) e/ou na produção de lixo radioativo a exemplo das usinas nucleares EPE (2020). Diversos acordos, a exemplo do Acordo de Paris, tratados e legislações criadas por países do mundo inteiro tem o intuito de reduzir as emissões de CO_2 e o consumo de fontes de energias não renováveis, visando a diminuição dos impactos ambientais. No entanto a necessidade crescente por energia, fomenta pesquisas e utilização de novas fontes, em especial as limpas e renováveis, afirmando o compromisso com requisitos mundiais de sustentabilidade e acordos de controle de emissão de CO_2 Althof and Ferber (2017).

* Este trabalho foi parcialmente apoiado pelas agência CAPES (Processo No. 88887.487624/2020-00).

Avaliando as fontes de energia elétrica renováveis, pode-se enumerar alguns problemas em relação a elas, como por exemplo, a hidrelétrica que necessita de um regime regular de chuvas a montante da barragem, a biomassa que exige um alto custo de implementação e a energia eólica que necessita de ventos, local específico e uma área muito maior que a área requerida pela energia solar por MW gerado. O parque eólico Osório localizado nos municípios de Osório, Índios e Sangradouro - Rio Grande do Sul, por exemplo, ocupa uma área de 130 Km^2 com capacidade de geração de 300MW, enquanto que o parque solar de Nova Olinda no Piauí ocupa apenas 5.3% dessa área total, com potência de 292 MW. A energia solar depende do sol, mas em contrapartida, apresenta uma enorme facilidade de instalação e baixo custo de implementação. Essa fonte de energia é a grande aposta no cenário energético brasileiro, pois somente no ano de 2018 obteve um crescimento de 316.1% se comparado ao ano anterior, o que é muito maior que o crescimento observado para a energia eólica que cresceu apenas 14.4% no mesmo período EPE (2020). Observando esse crescimento, o modelo de geração distribuída através da energia solar vem sendo amplamente estudado, principalmente na busca do aumento da eficiência no processo de conversão, nas técnicas de rastreamento de ponto de máxima potência (MPPT), no sombreamento e em outros.

Os sistemas fotovoltaicos são dispositivos que convertem a irradiação solar W/m^2 diretamente em eletricidade, sem a necessidade de um motor térmico ou uma máquina girante. Esse sistema não possui partes móveis, requer mínima manutenção, é silencioso, possui vida útil na ordem de 20 anos para o painel solar e não emite ou são extremamente baixos durante seus anos de geração. O conversor CC-CA, também conhecido como inversor, é o dispositivo utilizado para converter energia elétrica de corrente contínua em corrente alternada e sua saída sendo esta monofásica ou trifásica. A classificação dos inversores é feita através da sua potência, variando de centenas de watts até megawatts. A seleção do modelo de inversor é realizado pelo tipo de carga que este alimentará. Sua função principal é manter uma tensão de saída estável, converter a potência de entrada em saída com a maior eficiência possível e operar próximo do ponto de máxima potência (MPP). O desempenho do inversor depende do ponto de trabalho, forma de onda, distorção harmônica, frequência, eficiência do painel fotovoltaico, MPPT, sincronização com a rede, aquisição de dados, transformador e pelo desligamento da rede por manutenção Teodorescu et al. (2011).

As características de não linearidade e dependência às condições climáticas, tais como, irradiação solar, temperatura e velocidade do vento, requerem a implementação de algoritmos MPPT em sistemas de energia solar. As células fotovoltaicas possuem um ponto de operação ideal, conhecido por ponto de máxima potência (MPP) Singh and Lalwani (2018). O MPP muda de acordo com condições climáticas, envelhecimento do painel, sujeira e outros elementos externos. Os algoritmos de MPPT utilizam de uma programação lógica para encontrar o MPP, de maneira a permitir que o inversor trabalhe com a máxima potência disponível e melhore seu funcionamento encontrando a tensão que maximize a corrente Kalogirou (2016). A tensão de saída dos conversores CC-CC depende, entre outros fatores, diretamente da razão cíclica, logo, o algoritmo de

MPPT busca obter a razão cíclica que entregue a maior potência possível para a carga Sahu and Dixit (2014).

Dentre as mais de 26 técnicas de MPPT apresentadas por Subudhi and Pradhan (2012), pode-se destacar as técnicas de P&O (Perturba e Observa) e IC (Condutância Incremental). A técnica de P&O apresenta as vantagens de fácil implementação e utilização de sensores de tensão e corrente elétrica. Essa técnica consiste em perturbar o sistema aumentando ou diminuindo a razão cíclica e avaliar a potência de saída, ou seja, caso ela aumente incrementa a perturbação no mesmo sentido, caso contrário inverte o sentido da perturbação. É importante ressaltar que a técnica encontra o MPP após um certo tempo, mas com as perturbações constantes, perde eficiência em busca de um ponto já encontrado. A técnica de IC possui um funcionamento semelhante ao do método P&O, ela também causa variações ao sistema, porém utiliza-se das derivadas de tensão e corrente para definir o tamanho da perturbação, ou seja, passos longos em direção ao MPP quando se está distante e passos menores quando próximo ao MPP. Em tese essa técnica chega mais rapidamente ao ponto de MPP, mas em seguida apresenta o mesmo problema de perturbar um sistema já otimizado. Tendo em vista os métodos existentes e suas características positivas e negativas, este trabalho propõe um método MPPT baseado em Redes Neurais Artificiais (RNA).

A técnica de RNA encontra o MPP de forma mais eficiente utilizando de medições de irradiação solar e temperatura, definindo o ponto de máxima potência através de uma operação matemática e não apenas perturbando o sistema, o que causa perda de eficiência após encontrar o MPP Bahgat et al. (2005).

Uma característica muito importante da RNA é sua generalização que consiste em avaliar como o modelo se comporta para dados não vistos no conjunto de treinamento, ou seja, quanto próximo será a resposta da rede para uma situação não apresentada previamente. Ainda, espera-se que o modelo apresente uma boa generalização, isto é, se aproximar ao máximo da resposta esperada Haykin (2007).

2. PROBLEMA PROPOSTO

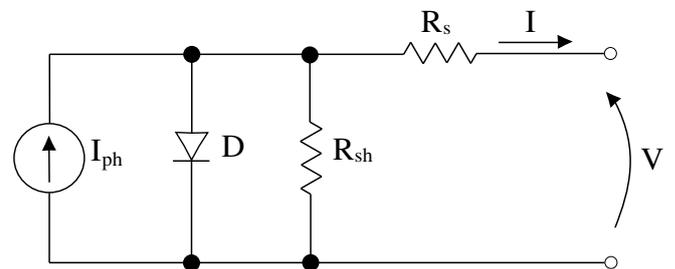


Figura 1. Circuito Equivalente

O circuito da Figura 1 modela o funcionamento de uma célula fotovoltaica Essefi et al. (2014), em que a corrente de saída é obtida através da análise de circuito, gerando a equação 1, onde V representa tensão, I corrente, I_{ph} fotocorrente, I_o corrente de saturação reversa da célula, n fator de qualidade da junção p-n, k constante de Boltzmann, q carga do elétron, T_{ref} temperatura ambiente em kelvin, R_s resistência em série e R_{sh} resistência em paralelo.

$$I = I_{ph} - I_o \left(e^{\frac{qV + IR_s}{nkT_{ref}}} - 1 \right) - \frac{V + IR_s}{R_{sh}} \quad (1)$$

As Figuras 2 e 3 apresentam as curvas características de um painel fotovoltaico, demonstrando que o MPP se encontra em um ponto de equilíbrio entre as grandezas de tensão e corrente elétrica, além disso, a Figura 3 mostra a dependência direta da potência em relação as condições climáticas.

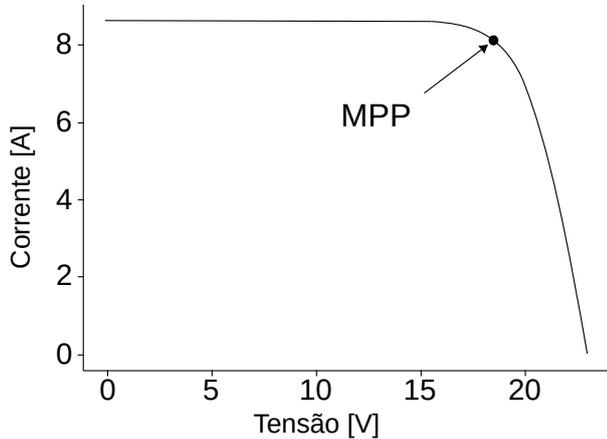


Figura 2. Curva tensão vs. corrente do painel solar

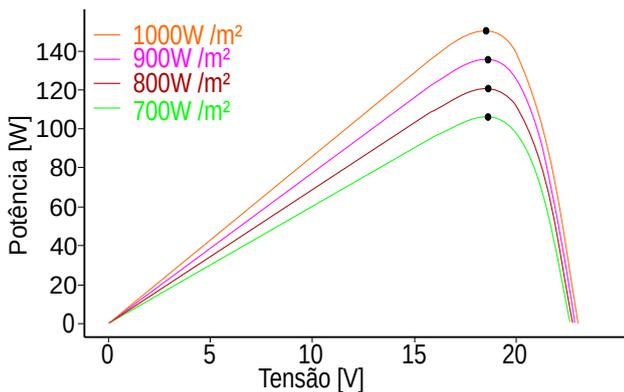


Figura 3. Curva de potência vs. tensão do painel solar

A instabilidade e impossibilidade de controle das condições climáticas fazem com que o MPP varie ao longo do tempo. Assim, surge a problemática de conseguir atingir o mais rápido possível o MPP de maneira a entregar a máxima potência disponível a carga em diferentes condições climáticas.

3. METODOLOGIA

A RNA utilizada é do tipo Multi Layer Perceptron (MLP) apresentada na Figura 4. Ela é baseada na estrutura cerebral e se destaca em resolver problemas complexos e que não possuem um algoritmo conhecido Learning (2017). O treinamento da RNA consiste em utilizar os dados de entrada e saída conhecidos de um determinado problema, chamado por conjunto de treinamento, e encaminhar para aprendizado em uma determinada arquitetura. Sua regra de aprendizado consiste em atualizar o peso de ligação entre os neurônios, fazendo com que os valores de saída da rede sejam os mais próximos possíveis dos valores de

saída do conjunto de treinamento Hiyama and Kitabayashi (1997). Para adquirir um boa generalização o conjunto de treinamento é dividido em grupo de treinamento e grupo de validação. A seleção da arquitetura da rede neural é feita de forma aleatória através do método de tentativa e erro em que a melhor rede é aquela que apresenta o menor erro médio quadrático Hiyama and Kitabayashi (1997).

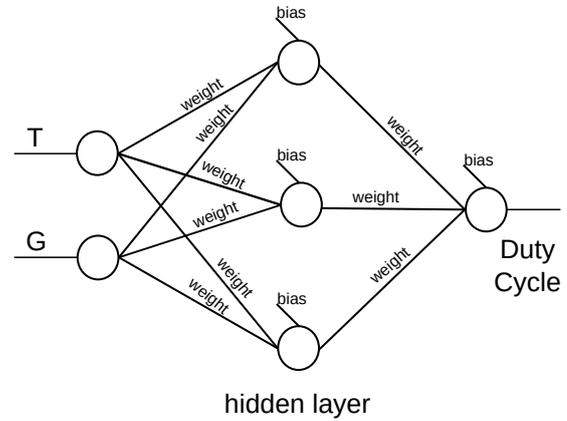


Figura 4. Exemplo de uma Multi Layer Perceptron

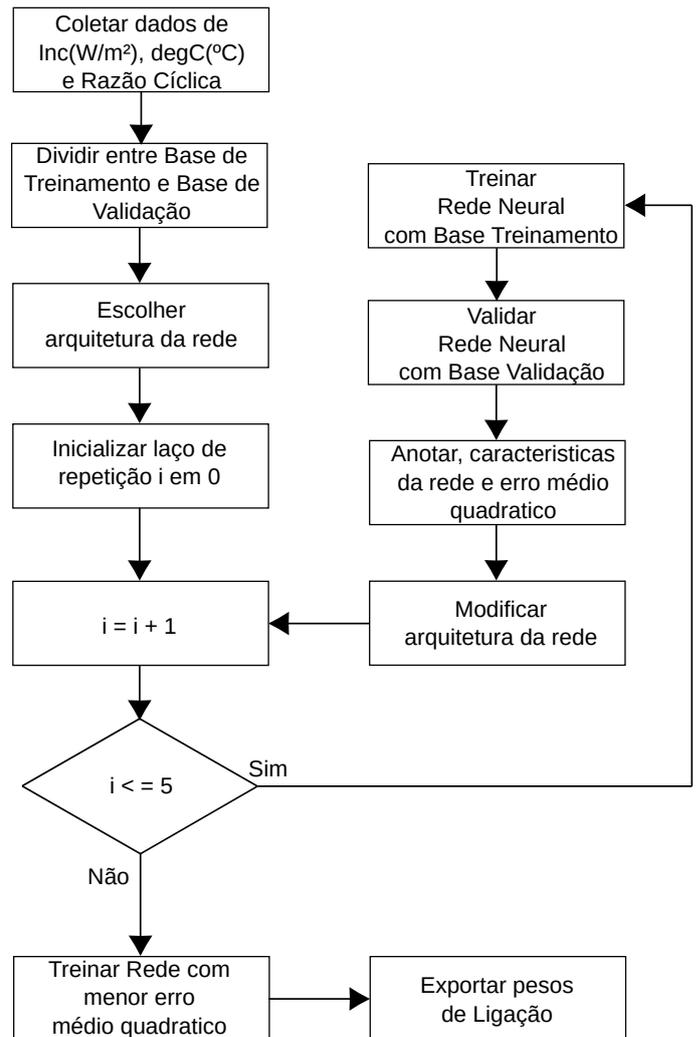


Figura 5. Fluxograma de treinamento RNA

Neste trabalho, a RNA é composta por três camadas sendo elas: camada de entrada, camada oculta e camada de saída. As camadas de entrada e saída tem vários neurônios, um para cada dado de entrada ou saída de informação da rede, e a camada oculta pode se dividir em diversas camadas com vários neurônios cada Hiyama and Kitabayashi (1997). Os neurônios da camada de entrada recebem a informação dos elementos sensores. Os neurônios das camadas seguintes recebem o valor de bias e o somatório de cada neurônio da camada anterior multiplicado pelo peso de ligação, o valor final é submetido a uma função de ativação, obtendo o valor resultante do neurônio. A propagação dos valores de entrada pela rede até chegar ao neurônio de saída é chamado de *feedforward*, e é repetida para cada valor do conjunto de treinamento. A diferença entre o valor calculado e o valor desejado é chamado de erro médio quadrático, esse erro é propagado proporcionalmente pela rede em sentido contrário, indo da camada de saída até a camada de entrada, ajustando os valores dos pesos de ligação entre os neurônios, esse método é conhecido por *backpropagation*. Considera-se que a rede aprendeu a resolver o problema, quando erro médio quadrático do conjunto de treinamento apresenta um valor abaixo do parametrizado na arquitetura para treinamento da rede Haykin (2007).

Para o treinamento da RNA apresentada na Figura 5 foi utilizado o compilador Python juntamente com a biblioteca scikit-learn. A arquitetura selecionada é do tipo MLP e a configuração da camada oculta e função de ativação são feitas através do método de tentativa e erro, e a melhor configuração encontrada contempla dois neurônios na camada de entrada, duas camadas ocultas, sendo a primeira com dez neurônios e a segunda com quatro neurônios e um único neurônio na camada de saída. A classe *MLPRegressor* treina usando retro propagação sem função de ativação na camada de saída e oferece suporte a regressão linear múltipla. Além disso, utilizou a função de ativação logística. Pedregosa et al..

O banco de dados das condições climáticas foi formado de 81.907 registros de irradiação solar e temperatura, aos quais foram submetidos ao algoritmo de cálculo da razão cíclica ideal programado em Python, utilizando da equação de ganho estático, equação 2 e equação de cálculo de corrente de saída equação 1. Para encontrar a razão cíclica ideal do conjunto de treinamento da rede foi utilizado uma carga fixa de 10 Ohms. Os dados da base de treinamento são apresentados na Figura 6, ela mostra a quantidade de registros com uma determinada grandeza. Ao analisar a imagem é possível notar existem aproximadamente 4000 registros de temperaturas próximas a 29 °C. O histograma apresenta os dados de irradiação solar, temperatura e razão cíclica representados por W/m^2 , degC e D respectivamente.

A Figura 7 demonstra a relação entre os atributos existentes na rede RNA. Nota-se a relação mais forte entre os atributos de irradiação solar e a razão cíclica. A razão cíclica está fortemente correlacionada à irradiação. Ainda, a temperatura tem correlação com a razão cíclica, porém fraca.

A Figura 8 representa a relação entre os atributos responsáveis pela razão cíclica do conversor CC-CC. As cores de

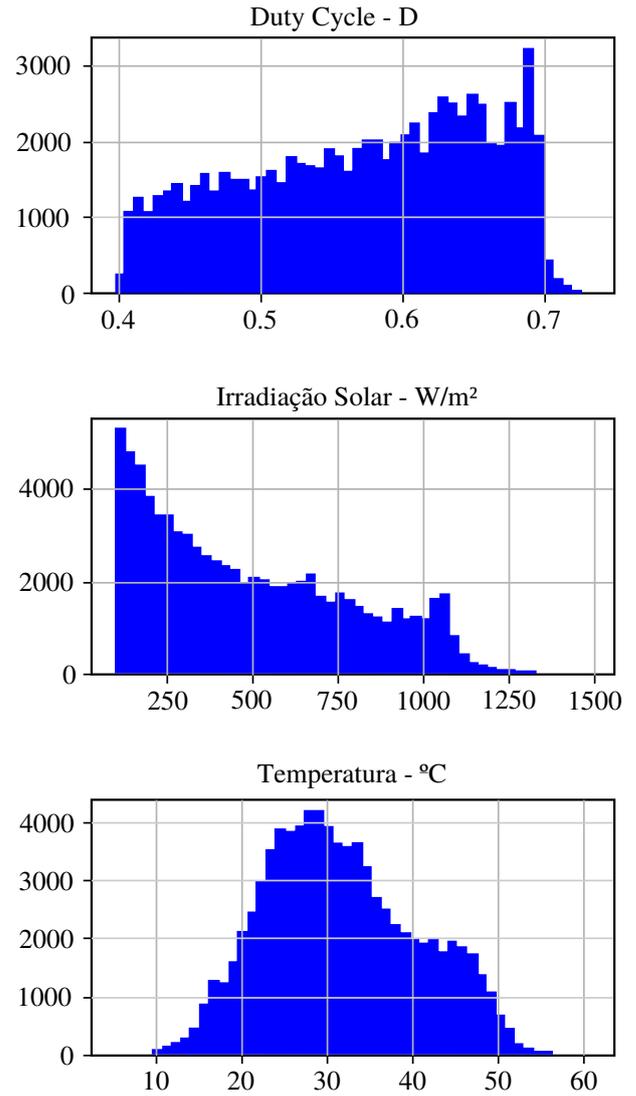


Figura 6. Histograma do conjunto de treinamento

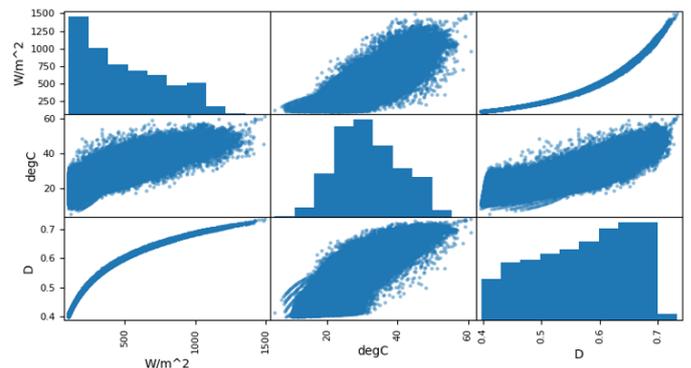


Figura 7. Relação entre atributos

azul a vermelho representam a temperatura que variam de 0 a 60 °C, na horizontal temos a irradiação solar e na vertical a razão cíclica com variações de 0.30 a 0.80. Verifica-se que para mesma irradiação solar temos diferentes razões cíclicas, isso ocorre em função do efeito da temperatura na geração de energia, desta forma esta figura apresenta o comportamento da razão cíclica em função da junção dos seus atributos irradiação solar e temperatura.

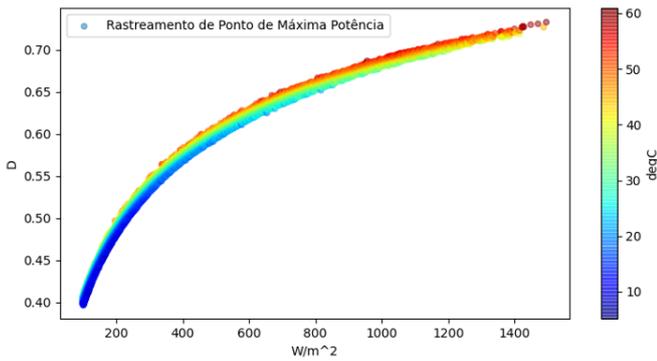


Figura 8. Relação entre razão cíclica, irradiação solar e temperatura

Após o treinamento da RNA, 0.57% dos registros apresentam uma saída contendo um erro maior que 0,009 entre o valor da resposta definida pela rede e o valor da base de treinamento. A Figura 9 é o resultado do treinamento da rede neural para os dados de validação, a linha vermelha representa a relação entre a predição da rede neural e os valores reais, os pontos de azul representam a resposta da rede para determinada entrada de dados, sendo assim quando mais próximo a linha vermelha, melhor está o comportamento da RNA. Repare que a RNA proposta está com uma baixa taxa de erro, ou seja, atende o nível de precisão necessário para aplicação.

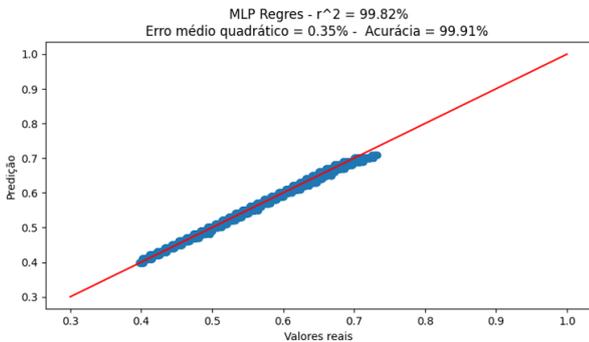


Figura 9. Curva de treinamento

4. APLICAÇÃO

4.1 Painel Solar

Para aplicação e comprovação do método de MPPT-RNA utilizou-se um conversor CC-CC Cúk, tendo como fonte de alimentação um painel fotovoltaico Yingli modelo YL150P-17B cujas características são descritas na Tabela 1.

Os dados do painel foram inseridos no modelo de simulação de painéis solares do software PSIM, representado na Figura 10. Este software permite a simulação de circuitos eletrônicos, com a possibilidade de inserção de código C e de simulação em diferentes cenários de aplicação, tornando possível a análise comparativa das diferentes técnicas acima citadas.

Condições Padrões STC			
Potência de Saída	Pmax	150	W
Eficiência	n	15	%
Tensão em Pmax	Vmpp	18.5	V
Corrente em Pmax	Impp	8.12	A
Tensão em circuito aberto	Voc	22.9	V
Corrente em curto-circuito	Isc	8.61	A
Coef. Temperatura para Voc	β	-0.37	%/°C
Coef. Temperatura para Isc	α	0.06	%/°C
Número de Células	36		

Tabela 1. Dados do painel - YL150P-17B

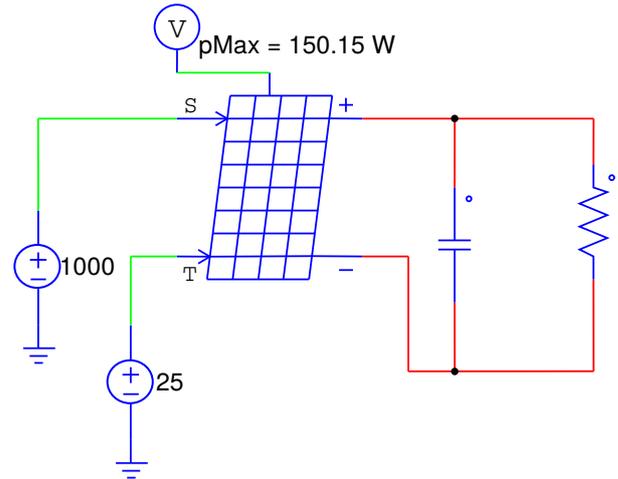


Figura 10. Painel Solar no software PSIM

4.2 Rede Neural Artificial

O método MPPT-RNA consiste em coletar informações de climáticas em tempo real e definir a razão cíclica do conversor conforme fluxograma apresentado na Figura 11 e em Figura 12.

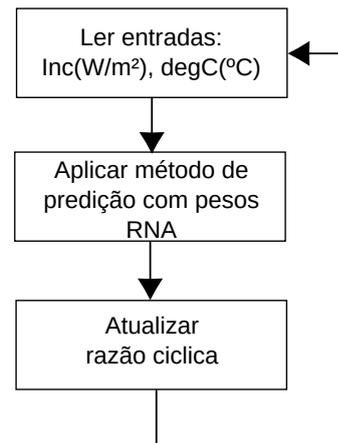


Figura 11. Utilização de RNA para definição de Razão Cíclica

4.3 Conversor CC-CC

O Conversor Cúk apresentado na Figura 13 é um conversor CC-CC que têm encontrado aplicações em sistemas fotovoltaicos, por suas características do tipo fonte de corrente

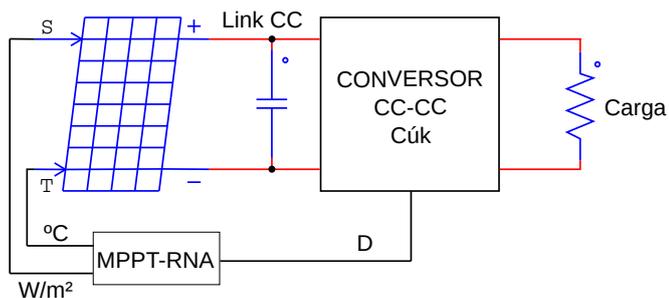


Figura 12. Técnica MPPT-RNA

na entrada e saída, e neste caso não isolado e com apenas um interruptor de potência comandado pela razão cíclica D , que em conjunto com indutores e capacitores controlam o fluxo de energia elétrica. Dentre os capacitores presentes no conversor Cúk, o C_1 é o componente responsável pela transferência de energia entre a fonte E_1 e a carga E_2 Martins and Barbi (2006).

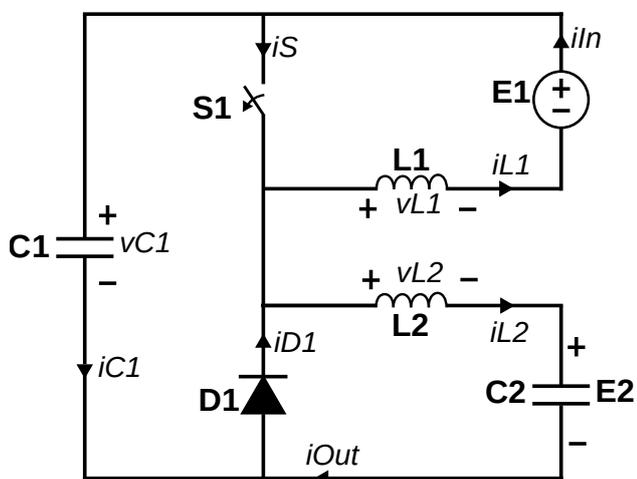


Figura 13. Representação simplificada de um conversor Cúk

Dados de projeto:

Parâmetro	Valor
E_1	18.5V
P_S	150W
P_O	150W
R	10 Ω
E_2	-38.729V
Δi_{L_1}	5%
Δi_{L_2}	1%
Δv_{C_1}	10%
Δv_{C_2}	5%
f	100K $_{hz}$

Tabela 2. Parâmetros de projeto

De posse dos valores de projeto, calcula-se os valores dos valores componentes utilizados na Tabela 3, onde operando-se a chave de comutação a uma frequência de 100 khz é possível obter uma eficiência de 94.5% de Souza et al. (2015).

Componente	Valor
L1	308 uH
L2	3232 uH
C1	5 uF
C2	25 nF

Tabela 3. Valores dos Componentes

O ganho estático deste conversor é definido por:

$$E_2 = E_1 \frac{D}{1-D} \quad (2)$$

Onde D é a razão cíclica definida pela RNA para as diferentes condições climáticas.

Sabe-se que o conversor cúk permite que a tensão de saída possa ser menor, igual ou maior que a tensão de entrada, para isso deve-se aplicar uma razão cíclica < 0.5 , 0.5 ou > 0.5 , respectivamente. Outra característica interessante é que a tensão de saída tem polarização invertida em relação a entrada de tensão Martins and Barbi (2006).

Os cenários para avaliação do método estão apresentados na Tabela 4.

Cenário	Irradiação Solar W/m2	Temperatura °C
1	700	20
2	600	40
3	400	35
4	900	55

Tabela 4. Cenários

5. RESULTADOS

O sistema apresentado foi simulado para os três métodos de MPP: P&O, IC e RNA. A Figura 14 apresenta os resultados de potência em função do tempo para os métodos de P&O, IC e RNA, contemplando diversos cenários. Note que o MPPT-RNA utilizado como método de controle de razão cíclica em algoritmos de MPPT é superior aos outros métodos testados, conseguindo de maneira mais rápida atingir o MPP disponível no painel solar.

Em uma análise mais detalhada da Figura 14, a cor preta representa a máxima potência disponível do painel fotovoltaico de acordo com os cenários definidos na simulação e, conforme ele varia, as técnicas tendem a se adequar as novas condições, com valor de potência próximo a 96W no intervalo de 4ms. Em azul observa-se a curva obtida pelo algoritmo de P&O, com potência entorno de 89W. É possível notar que ela demora 3.75ms para atingir o MPP no primeiro cenário, 1.25ms no segundo cenário, 2.5ms no terceiro cenário e 3.13ms no ultimo cenário, isso ocorre devido o tempo de perturbação do sistema e da avaliação da resposta. A cor vermelha representa a técnica de IC. Observa-se que esta técnica no primeiro cenário efetua passos largos e consegue chegar mais rápido que a técnica P&O ao ponto de MPP, no primeiro cenário 1.87ms, no segundo cenário 0.4ms, 2.5ms no terceiro cenário e 3.1ms no ultimo cenário totalizando 91W de potência. Em laranja tem-se a técnica de MPPT-RNA. Ela não efetua perturbações ao sistema, utiliza da RNA para calcular a

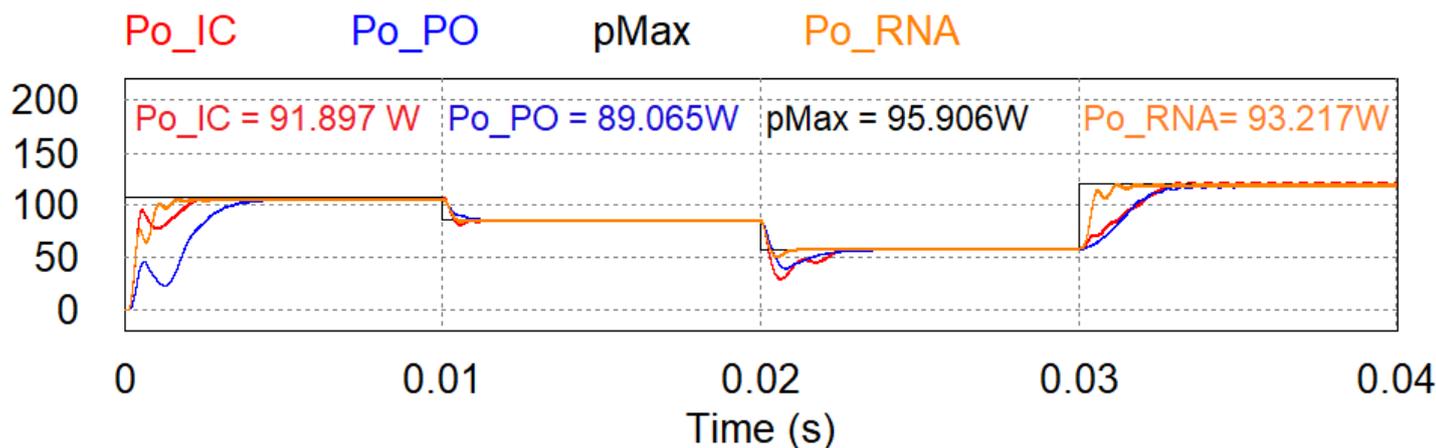


Figura 14. Comparativo de técnicas de MPPT

razão cíclica ideal de acordo com os dados de irradiação solar e temperatura, se ajusta nos cenários diminuindo o tempo de busca pelo MPP chegando ao valor de 1.2ms no primeiro cenário, 0.4ms no segundo cenário, 0.6ms no terceiro cenário e 0.8ms no último cenário, aumentando a eficiência dos conversores CC-CC e extraíndo uma maior potência disponível se comparada as demais técnicas, contemplando valores próximos a 93W, correspondendo a 97% da geração.

6. CONCLUSÃO

Este trabalho apresentou uma alternativa para MPPT em sistema fotovoltaico relevante na área de fontes de energias renováveis, com enfoque maior em MPPT aplicados a conversores instalados em painéis fotovoltaicos. Foi proposto um método utilizando RNA que busque encontrar mais rapidamente o MPP entregando uma maior potência a carga.

Visando o aperfeiçoamento do sistema de aplicação de painéis fotovoltaicos, em especial na técnica de MPPT aplicada a conversores, este trabalho teve por objetivo propor um método que utiliza o RNA de maneira a encontrar mais rápido o MPP e entregar uma maior potência a carga. Para isso, foi implementada uma aplicação utilizando simulação numérica no software PSIM obtendo resultado para os diferentes cenários propostos. A RNA mostrou sua superioridade em relação aos métodos de P&O e IC. Apesar de necessitar elevados recursos em processamento para treinamento da rede e para a coleta de dados na montagem da base de treinamento, a técnica MPPT-RNA apresenta-se vantajosa por entregar uma maior potência a carga com um tempo menor na busca do MPP. Além disso, caso treinada corretamente pode comprovar sua eficácia em resolução de problemas de MPPT.

A evolução tecnológica emergente em análises computacionais buscando a resolução de problemas através de inteligência artificial, possibilita a este trabalho implementações futuras, seja por melhoria da técnica MPPT-RNA ou para diferentes arquiteturas de redes neurais artificiais.

REFERÊNCIAS

Althof, R.B. and Ferber, M. (2017). Efficient uncertainty analysis of wind farms in the time domain using the

unscented transform. In *2017 IEEE 8th International Symposium on Power Electronics for Distributed Generation Systems (PEDG)*, 1–4. IEEE.

Bahgat, A., Helwa, N., Ahmad, G., and El Shenawy, E. (2005). Maximum power point tracking controller for pv systems using neural networks. *Renewable Energy*, 30(8), 1257–1268.

de Souza, J.P., de Oliveira, P., Gules, R., Romaneli, E.F., and Badin, A.A. (2015). A high static gain cuk dc-dc converter. In *2015 IEEE 13th Brazilian Power Electronics Conference and 1st Southern Power Electronics Conference (COBEP/SPEC)*, 1–6. IEEE.

EPE, E.d.P.E. (2020). Relatório Síntese 2019. <http://epe.gov.br/sites-pt/publicacoes-dados-abertos/publicacoes/PublicacoesArquivos/publicacao-377/topico-470/Relat%C3%B3rio%20S%C3%ADntese%20BEN%202019%20Ano%20Base%202018.pdf>. [Online; accessed 01-April-2020].

Essefi, R.M., Souissi, P.M., and Abdallah, P.H.H. (2014). Maximum power point tracking control technique for photovoltaic systems using neural networks. In *2014 5th International Renewable Energy Congress (IREC)*, 1–6. IEEE.

Haykin, S. (2007). *Redes neurais: princípios e prática*. Bookman Editora.

Hiyama, T. and Kitabayashi, K. (1997). Neural network based estimation of maximum power generation from pv module using environmental information. *IEEE Transactions on Energy Conversion*, 12(3), 241–247.

Kalogirou, S.A. (2016). *Engenharia de energia solar. Processos e Sistemas*. Rio.

Learning, A.G.H.O.M. (2017). *with Scikit-Learn and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems*. O'Reilly Media.

Martins, D.C. and Barbi, I. (2006). *Eletrônica de Potência: conversores cc-cc básicos não isolados*. Edição dos Autores.

Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., and Duchesnay, E. (????). 1.17. neural network models (supervised) — scikit-learn 0.23.2 documentation. (Accessed on 08/26/2020).

- Sahu, T.P. and Dixit, T. (2014). Modelling and analysis of perturb & observe and incremental conductance mppt algorithm for pv array using cuk converter. In *2014 IEEE Students' Conference on Electrical, Electronics and Computer Science*, 1–6. IEEE.
- Singh, S. and Lalwani, M. (2018). Simulation of converter topologies for pv grid connected system. In *2018 3rd International Innovative Applications of Computational Intelligence on Power, Energy and Controls with their Impact on Humanity (CIPECH)*, 1–6. IEEE.
- Subudhi, B. and Pradhan, R. (2012). A comparative study on maximum power point tracking techniques for photovoltaic power systems. *IEEE transactions on Sustainable Energy*, 4(1), 89–98.
- Teodorescu, R., Liserre, M., and Rodriguez, P. (2011). *Grid converters for photovoltaic and wind power systems*, volume 29. John Wiley & Sons.