Implementação em PIC de um Controle de Fluxo de Potência em Painéis Fotovoltaicos Baseados em Redes Neurais

Alexis de Medeiros Torres
Universidade de Fortaleza
UNIFOR
Av. Washington Soares, 1321
Fortaleza – CE – Brasil
alexism@uf.unifor.br

Fernando L. M. Antunes
Universidade Federal do Ceará
UFC
Campus do Pici
Fortaleza – CE – Brasil
fantunes@dee.ufc.br

Fernando Soares dos Reis
Julio César M. de Lima
PUCRS
Av. Ipiranga, 6681
Porto Alegre – RS –Brasil
f.dosreis@ieee.org

***Resumo* - O trabalho proposto descreve a implementação de uma rede neural artificial, baseada em um microcontrolador da família PIC, para o controle de potência em sistemas de energia baseados em células fotovoltaicas. Uma rede neural é utilizada para determinar a cada instante, a tensão que garanta a máxima transferência de potência dos painéis solares de acordo com a irradiação solar. Esta implementação dispensa a utilização de um computador de maior porte, uma vez que a rede neural já foi treinada e desta forma, pode ser implementada em um sistema dedicado. A máxima transferência de potência do sistema é obtida ajustando o ciclo de trabalho de um conversor CC-CC, que leva o ponto de operação dos painéis ao de máxima transferência de potência.**

I - INTRODUÇÃO

A tecnologia em sistemas fotovoltaicos vem se expandindo, graças a crescente demanda por alternativas energéticas, principalmente por fontes seguras e não poluentes [1]. Células fotoelétricas são dispositivos não lineares, onde as características de corrente/tensão dependem da irradiação solar e da temperatura[2]. São dispositivos caros e de baixa eficiência.

Estudos demostram que em sistemas de energia baseados em células fotovoltaicas, 57% do total dos custos de implantação se referem ao custo dos painéis e 30% se referem ao custo dos sistemas de baterias [3]. De modo a tornar viável a implantação deste tipo de fonte energética, é vital a obtenção de um sistema que retire sempre a máxima potência destes painéis solares. Vários sistemas que possibilitam a máxima transferência de potência entre as células fotovoltaicas e a rede foram propostos de modo a aumentar a eficiência e diminuir os custos. O objetivo destes sistemas é obter através de circuitos eletrônicos e de algoritmos de controle, ajuste da tensão de saída dos painéis, de modo a se ter a qualquer instante, sempre a máxima potência permitida.

A máxima potência fornecida por um sistema baseado em células fotovoltaicas varia com o tempo, e depende de fatores ambientais tais como a irradiação solar ou a temperatura das células. Várias técnicas que empregam sistemas de equações não lineares para descrever o funcionamento de células fotovoltaicas têm sido empregadas para determinar o ponto de máxima potência [2,4]. Uma alternativa a este tipo de abordagem tem sido o emprego de redes neurais artificiais [1,5], com as quais foram obtidos excelentes resultados, uma vez que estas constituem um aproximador universal para sistemas dinâmicos não-lineares.

O objetivo deste trabalho é descrever a aplicação de uma rede neural artificial para determinar o ponto de máxima potência em sistemas de energia baseado em células fotovoltaicas. A implantação desta rede já foi feita utilizando-se um PC [6] neste artigo apresenta-se a implementação da mesma rede em um microcontrolador da família PIC [7], de modo a construir um sistema eficiente e de baixo custo.

II - DESCRIÇÃO DO SISTEMA

A figura 1 apresenta um diagrama em blocos do sistema de energia proposto. Este sistema é composto de quatro elementos básicos:

- Painel solar
- Conversor CC-CC
- Controlador baseado em rede neural
- Inversor trifásico.

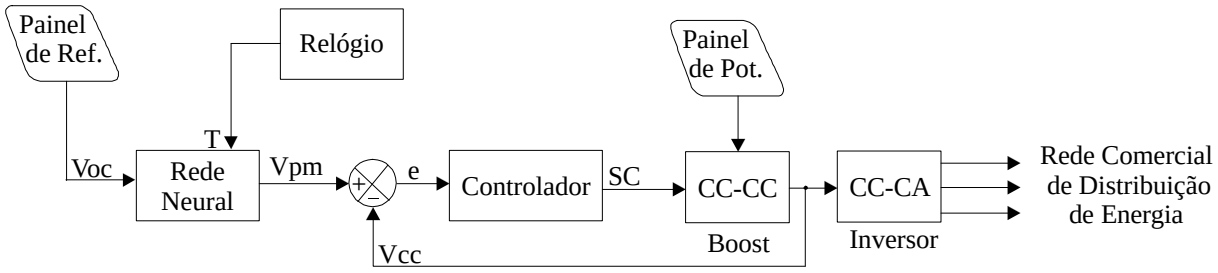

Figura 1. Diagrama em blocos do sistema.

O painel solar utilizado é composto de seis células fotovoltaicas para o fornecimento de energia e de uma célula fotovoltaica para obter a referência de tensão. O conversor CC-CC consiste de uma estrutura do tipo "Boost" de um único estágio, responsável por ajustar a tensão de saída (V_{CC}), que será entregue ao inversor trifásico, de forma a obter sempre o ponto de máxima potência. O controle baseado em uma rede neural artificial, a qual determina a tensão de saída do conversor CC-CC, foi implementado em um microcontrolador da família PIC. Um inversor é utilizado para gerar uma tensão senoidal trifásica, a partir da tensão CC disponível na saída do conversor "Boost", de forma a possibilitar a conexão com a rede elétrica comercial. Este inversor foi implementado utilizando modulação PWM otimizada, com eliminação de harmônicos [6, 10].

III - Implementação do Controle

Para implementar as estratégias de controle envolvidas no sistema, optou-se por utilizar um microcontrolador da família PIC, os quais são largamente utilizados devido as suas excelentes características, entre elas a adoção de uma arquitetura “harvard” que permite executar tarefas mais rapidamente e por ter uma filosofia RISC, no qual é necessário conhecer cerca de 30 instruções para a sua programação [7,8]. A figura 2 apresenta as funções incorporadas no microcontrolador.

Ao circuito foi adicionado apenas um conversor D/A, uma vez que o microcontrolador escolhido já incorpora os conversores A/D. Os conversores A/D são utilizados para coletar sinais analógicos provenientes da célula fotovoltaica de referência (V_{OC}) e da tensão de saída do conversor CC-CC (V_{CC}). No microcontrolador também foram implementados um circuito de relógio - necessário na determinação da tensão de saída do conversor CC-CC pela rede neural e um controlador do tipo PI - descrito pela expressão (1), o qual vai fornecer um sinal de controle (SC) para o conversor CC-CC.

$$SC(t) = K_p e(t) + K_i \int e(t)dt \qquad (1)$$

onde e(t) é o erro entre a tensão estimada pela rede neural e a tensão medida no conversor CC-CC e K_p e K_i as constantes do controlador. Este sinal ajusta o ciclo de trabalho do conversor "Boost" responsável pela adequação dos níveis de tensão entre os painéis e o inversor trifásico.

Para manter atualizado o relógio no microcontrolador durante um processo de inicialização, existe um canal de comunicação com um computador PC.

IV - Topologia da Rede Neural

A topologia da rede foi baseada no modelo de um neurônio cujo diagrama encontra-se representado na figura 3.

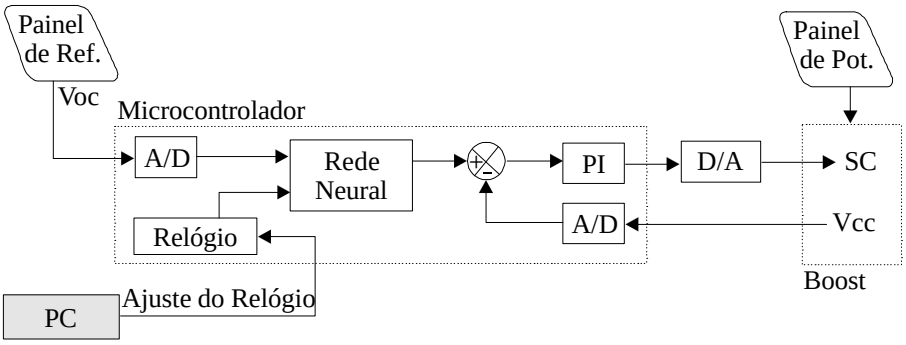

Figura 2. Diagrama em blocos do controle.

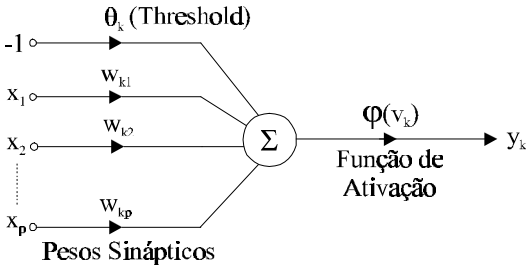

Figura 3. Modelo de um neurônio.

O comportamento deste neurônio [9] pode ser descrito pelas equações (2) e (3).

$$v_k = \sum_{j=1}^{p} w_{kj}.x_j - \theta_k \qquad (2)$$

$$y_k = \varphi(v_k) \qquad (3)$$

onde x_1, x_2, ..,x_p são as entradas do neurônio k; y_k a saída e w_{k1}, w_{k2},...,w_{kp} são os pesos sinápticos; v_k é denominado nível de ativação do neurônio e $\varphi(v_k)$ a função de ativação. A função de ativação escolhida é do tipo sigmoidal (4).

$$\varphi(v_k) = \frac{2}{1+e^{v_k}} - 1 \qquad (4)$$

A figura 4 apresenta a configuração da rede neural implementada, que está organizada como uma rede do tipo 2-4-1 (número de neurônios da camada de entrada, da camada escondida e da camada de saída) [9]. A saída estimada por um dado neurônio - $y_k(t)$, de uma certa camada, está descrito em (2).

A rede neural é utilizada para que seja determinada a tensão que deve ser fornecida pelo conversor CC-CC - V_{pm}, obtendo-se assim a máxima transferência de potência dos painéis solares. Para isto, um painel solar é utilizado como entrada de referência - V_{OC}, na rede neural.

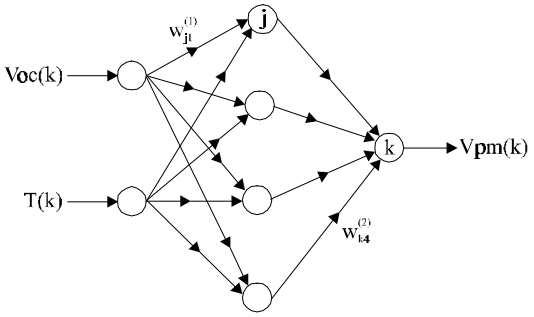

Figura 4. Topologia da rede neural.

Um parâmetro de tempo - T, também é colocado como entrada da rede, de modo a minimizar erros de interpretação em situações climáticas desfavoráveis. A rede estima o valor de saída do conversor CC-CC - V_{pm}, de acordo com os valores de V_{oc} e T.

Os pesos sinápticos foram continuamente atualizados durante o processo de treinamento através do método do gradiente descendente [9]. O algoritmo de treino utilizado foi o de "backpropagation", que tenta minimizar o erro dos neurônios da camada de saída (5,6), propagando uma correção nos pesos sinápticos dos neurônios de todas as camadas segundo se pode observar nas equações (11, 12 e 13).

$$e_j(n) = d_j(n) - y_j(n) \qquad (5)$$

$$E(n) = \frac{1}{2}\sum_j e_j^2(n) \qquad (6)$$

onde $e_j(n)$ é o erro no neurônio j da camada de saída; $d_j(n)$ a saída desejada e $y_j(n)$ a saída obtida no

neurônio j no instante n. Assim, tem-se para a propagação no sentido direto (7,8)

$$v_j^{(l)}(n) = \sum_{i=1}^{p} w_{ji}^{(l)}(n).y_i^{(l-1)}(n) \qquad (7)$$

$$y_j^{(l)}(n) = \mathrm{j}\left(v_j^{(l)}(n)\right) \qquad (8)$$

para $l=1..L$, onde $v_j^{(l)}(n)$ é o nível de ativação do neurônio j da camada l no instante n; $w_{ji}^{(l)}(n)$ são os pesos sinápticos do neurônio j da camada l conectados as entradas da camada l-1. Assim, para $l=1$ e para $l=L$, tem-se (9,10)

$$y_j^{(0)}(n) = x_j(n) \qquad (9)$$

$$y_j^{(L)}(n) = o_j(n) \qquad (10)$$

onde $x_j(n)$ representa a camada de entrada e $o_j(n)$ a camada de saída. Para atualizar os pesos sinápticos, foi utilizado o algoritmo do gradiente descendente, descrito em (11,12) é obtido minimizando a função erro (1)

$$\mathrm{d}_j^{(L)}(n) = e_j^{(L)}(n)o_j(n)\left(1-o_j(n)\right) \qquad (11)$$

$$\mathrm{d}_j^{(l)}(n) = y_j^{(l)}(n)\left(1-y_j^{(l)}(n)\right)\sum_k \mathrm{d}_k^{(l+1)}(n)w_{kj}^{(l+1)}(n) \qquad (12)$$

onde $\delta_j^{(L)}(n)$ é o gradiente de erro local do neurônio j da camada de saída e $\delta_j^{(l)}(n)$ é o gradiente de erro local do neurônio j de uma camada escondida. Desta forma, pode-se ajustar os valores das sinapses como segue (13)

$$\Delta w_{ji}^{(l)}(n) = \mathrm{a}\Delta w_{ji}^{(l)}(n-1) + \mathrm{h}\mathrm{d}_j^{(l)}(n)y_i^{(l-1)}(n) \qquad (13)$$

onde η é a taxa de aprendizado e α uma constante de "momento", adicionada de forma a obter um aprendizado mais rápido, sem instabilizar o sistema. O treinamento da rede foi feito "off-line" utilizando o software MATLAB®. O processo de treino foi baseado no algoritmo de "backpropagation" [9].

IV - Aquisição de Dados

Os dados necessários para o processo de treinamento a priori da rede neural foram obtidos através de medições feitas sobre uma determinada célula a qual denominou-se célula de referência. A figura 5 apresenta as curvas características de máxima transferência de potência e corrente de carga em função da tensão de saída de uma célula fotovoltaica para um determinado nível de irradiação solar, no qual os valores de tensão a vazio - V_{oc}, tensão de máxima potência - V_{pm}, corrente de curto circuito - I_{CC} e rendimento η são apresentados.

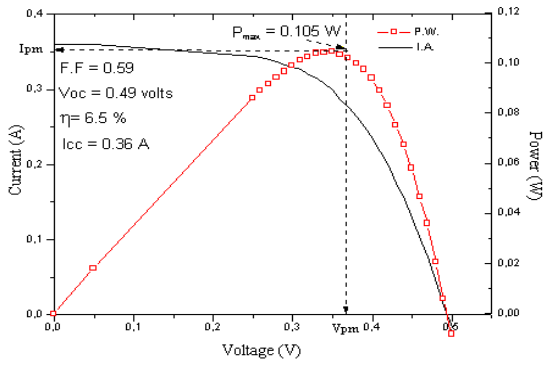

Figura 5. Característica de uma célula fotovoltaica.

As curvas representadas na figura 6, apresentam a tensão a vazio - V_{OC}, e a tensão de máxima potência - V_{pm}, coletados em um dia típico, cuja irradiação solar transcorreu durante o intervalo compreendido entre 08:48 e 18:03 horas - 30 de abril de 1998.

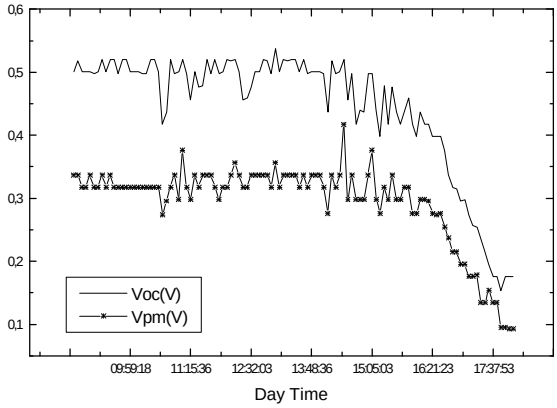

Figura 6. V_{oc} e V_{pm} para uma irradiação solar típica

V - Resultados

A rede neural foi implementada conforme a topologia representada na figura 1 e treinada com as tensões medidas nas células fotovoltaicas, cujos dados estão representados na figura 6. O processo de treinamento da rede foi efetuado conforme o algoritmo de treinamento descrito anteriormente, o qual obteve uma curva de erro de convergência que está representada na figura 7.

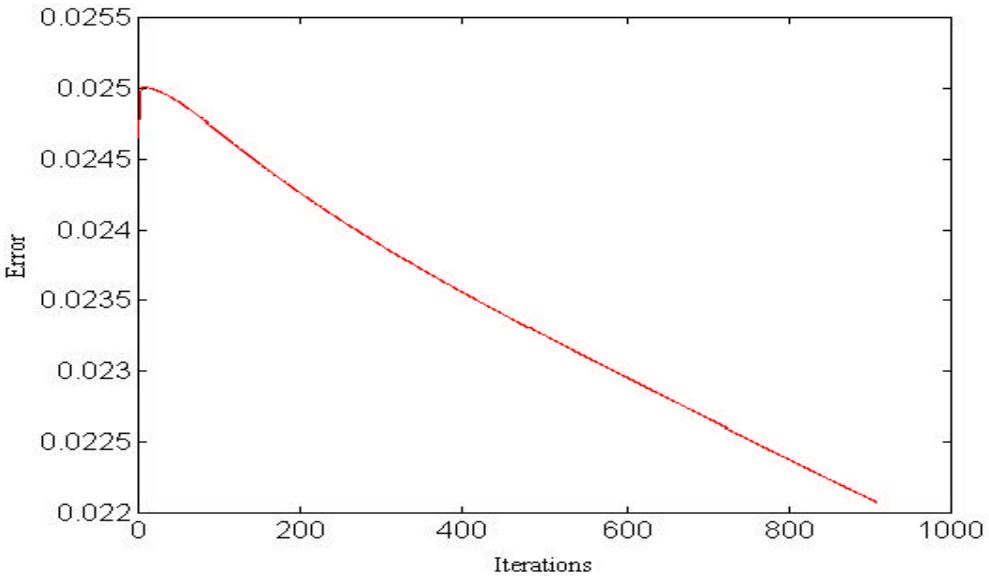

Figura 7. Curva de convergência da rede treinada.

O treinamento da rede neural foi feito com uma taxa de aprendizado η=0.2 e momento α=0.9. O treino da rede foi repetido até o erro convergir para $E(n) < 5x10^{-5}$.

A figura 8 apresenta a tensão de saída do inversor utilizado o qual emprega a técnica de modulação PWM senoidal otimizado [10], programado para eliminar as harmônicas de ordem inferior a 17 ª .

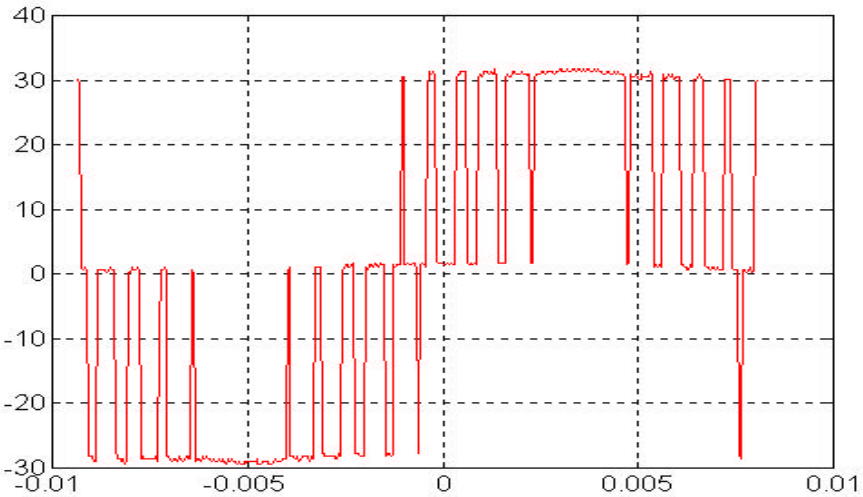

Figura 8 - Saída do PWM Otimizado

VI. AGRADECIMENTO

Os autores querem expressar seus agradecimentos a FUNCAP - Fundação Cearense de Amparo à Pesquisa pela bolsa de mestrado concedida ao Sr. Alexis de Medeiros Torres.

VII - CONCLUSÕES

Este trabalho apresentou a utilização de uma rede neural artificial na determinação da máxima tensão de saída para obtenção da máxima transferência de potência em sistemas fotovoltaicos.

A rede neural foi implementada com o auxílio do programa MATLAB, onde foi obtido o treinamento da rede com os dados obtidos em uma célula fotovoltaica de referência, utilizando o método de “backpropagation”.

A convergência da rede mostrou-se satisfatória na determinação da tensão de máxima potência, sobre o conjunto de dados apresentados.

O controle de potência é obtido com o ajuste do ciclo de trabalho de um conversor CC-CC do tipo "Boost", o qual irá fornecer uma tensão adequada para um inversor trifásico. Este ajuste permite obter a qualquer instante, a máxima transferência de potência de modo a extrair sempre o melhor desempenho células fotovoltaicas, para as mais diversas condições de irradiação solar.

A implementação do controle foi feita em um microcontrolador da família PIC, garantindo um bom desempenho do sistema, a um baixo custo, uma vez que ao fazer o treinamento da rede a priori, dispensou-se o emprego de um computador de maior desempenho, reduzindo significativamente custo do controle e aumentando a confiabilidade do sistema.

VIII - REFERÊNCIAS

[1] T. Hiyama et al, “Evaluation of Neural Network Based Real Time Maximum Power Tracking Controller for PV System”, IEEE Transactions on Energy Conversion, Vol. 10, N. 3, September 1995.

[2] Alghuwainem, S. M., “Matching of DC Motor to a Photovoltaic Generator Using a Step-Up Converter With a Current-Locked Loop”, IEEE Transactions on Energy Conversion, Vol. 9, N. 1, March 1994.

[3] J.H.R. Enslin, “Renewable energy as an economic energy source for remote areas”, Proceedings Renewable Energy, Vol. 1, N. 2, pp. 243-248, 1991.

[4] M.S. Imamura, P. Helm, W. Palz, “Photovoltaic System Technology - An European Handbook”, CEC, H. Stephens & Associates, 1992.

[5] M.S. Imamura, “Grid-Connected PV Plants: Field Experiences in Germany and a Pursuit of Higher Solar Energy Collection Efficienty”, Solar Energy Materials and Solar Cells, Vol. 35, November 1994.

[6] A. M. Torres et al, "An Artificial Neural Network-Based Real Time Maximum Power Traking Controller for Connecting a PV System to the Grid", IECON'98, Vo. 1, pp 554-558, Aachen, Alemanha, Setembro de 1998.

[7] PIC16/17 Microcontroller Data Book, Microchip 1996

[8] Embedded Control Handbook, Microchip, 1995.

[9] Simon Haykin, “Neural Networks, A Comprehensive Foundation”, McCPC, 1994.

[10] Perin, A . , “Contribution à l’étude des Convertisseurs Directs de Fréquence à Transistors de Puissance” , Tese de Docteur – Ingénieur, INP de Toulouse, França, 1984.