

# DETECÇÃO DE ANOMALIAS EM PAINÉIS FOTOVOLTAICOS UTILIZANDO REDES ABNET, PSOM E MLP

**Ricardo Henrique Fonseca Alves** – ricardohenriquefa@gmail.com

**Getúlio Antero de Deus Júnior** – gdeusjr@ufg.br

**Flávio Henrique Teles Vieira** – flavio\_vieira@ufg.br

**Marcelo Stehling de Castro** – mcastro@ufg.br

**Sérgio Granato de Araújo** – granato@emc.ufg.br

**Rodrigo Pinto Lemos** – lemos@ufg.br

Universidade Federal de Goiás, Escola de Engenharia Elétrica, Mecânica e de Computação

**Resumo.** Este trabalho tem como objetivo principal propor um método baseado em Redes Neurais Artificiais (RNA) para detectar anomalias em painéis fotovoltaicos instalados em sistemas de geração elétrica, tendo como base imagens termográficas. Assim, foram utilizadas técnicas de processamento de imagem e reconhecimento de padrões por meio de RNA com treinamento supervisionado e adaptativo. Para a implementação do sistema de detecção de anomalias, foram selecionadas imagens do tutorial “Solar Cell Development” da FLIR systems, sendo que estas imagens termográficas apresentam pontos de aquecimento em células específicas de determinado painel fotovoltaico. A ferramenta computacional Matlab© foi utilizada para realizar o pré-processamento do banco de imagens e para o treinamento de uma rede ABNET, uma rede PSOM e uma rede MLP. Por meio de validação cruzada, a taxa de acertos para a classificação dos padrões da rede ABNET e PSOM foi de 87,5% e para a rede MLP foi de 96%. Os resultados corroboram para utilização dessas redes em um banco de imagens que será construído por meio do Projeto de Pesquisa e Desenvolvimento (P&D) em andamento.

**Palavras-chave:** Painéis Fotovoltaicos, Redes Neurais Artificiais, Classificação de Padrões.

## 1. INTRODUÇÃO

A demanda de energia no mundo vem crescendo e junto com esta necessidade, cresce ainda a preocupação em suprir esta demanda utilizando-se fontes renováveis e sustentáveis. Nesse cenário, surge a fonte energética solar, oriunda do sol, que é inesgotável e que carrega consigo os princípios da sustentabilidade (energia limpa).

A implantação da geração solar apresenta diversos desafios, dentre eles, os preços de implantação e manutenção de um sistema fotovoltaico, que apesar de virem sofrendo reduções, costumam ser bem elevados. Isso tem estimulado uma busca iminente pela diminuição destes valores visando um crescimento cada vez maior desta fonte energética. Uma maneira de diminuir os custos da geração solar baseia-se na elevação do tempo de vida útil dos painéis fotovoltaicos, atrelados às manutenções em pontos com anomalias no sistema. Dessa forma, este trabalho busca propor um método de detecção de anomalias em módulos fotovoltaicos que possam vir a prejudicar o bom funcionamento do mesmo, diminuindo seu tempo de vida útil.

O uso de imagens termográficas tem se mostrado efetiva na detecção de pontos quentes em painéis fotovoltaicos, sendo que estas imagens ajudam a evidenciar pontos de aquecimento que são causadores de efeitos de destruição irreversível na estrutura da célula solar (Simon, Meyer, 2010).

Desta forma a termografia torna-se uma grande aliada visto que as condições de aquecimento nos painéis fotovoltaicos podem ser identificadas com o sistema elétrico em operação. Na identificação de qualquer anomalia, o conjunto de módulos fotovoltaicos poderá ser isolado, permitindo a devida manutenção em um Sistema Fotovoltaico Conectado à Rede.

Nesse contexto, o presente trabalho busca propor um método de detecção de anomalias em módulos fotovoltaicos, como por exemplo detecção de falhas e de sombreamento parcial, de forma a auxiliar no gerenciamento de uma planta solar e na medição do tempo de vida útil dos equipamentos. Este artigo está organizado em seis seções. A Seção II apresenta o problema de aquecimento que pode surgir em painéis fotovoltaicos na Geração Fotovoltaica. A Seção III apresenta as redes ABNET (Castro, Von Zuben e Deus Júnior, 2003), PSOM (Deus Júnior, Castro e Portugêis, 1999) e MLP (Haykin, 2009). Já a Seção IV apresenta propostas para as redes ABNET, PSOM e MLP para detecção de pontos de aquecimento no conjunto de módulos fotovoltaicos. A Seção V apresenta uma proposta de solução prática para implementação das redes ABNET, PSOM e MLP utilizando Raspeberry PI 2 (Upton, 2014). Finalmente, uma conclusão é apresentada na Seção VI.

## 2. AQUECIMENTO EM PAINÉIS FOTOVOLTAICOS

A geração fotovoltaica faz uso de elementos semicondutores fotossensíveis que convertem a radiação solar em uma diferença de potencial nos terminais da junção P-N<sup>2</sup>. A ligação elétrica desses terminais resulta na circulação de corrente contínua. As células fotovoltaicas mais promissoras em termos de custo e relativa alta eficiência são aquelas fabricadas com Silício (Empresa de Pesquisa Energética, 2012).

As câmeras termográficas são utilizadas para obtenção de imagens térmicas de painéis fotovoltaicos principalmente para localizar defeitos. Uma boa classificação e avaliação das anomalias detectadas requerem uma sólida compreensão da tecnologia solar, o conhecimento do sistema inspecionado e medições elétricas adicionais. O uso de imagens térmicas facilita o monitoramento do sistema fotovoltaico ajudando a manter a boa funcionalidade dos módulos, o que resulta em um maior tempo de vida útil do equipamento, o que gera um retorno financeiro maior.

Utilizando-se imagens termográficas, é possível observar áreas quentes em um módulo fotovoltaico e as partes do painel onde estão mais quentes do que outras. De acordo com a forma e o local de um determinado ponto “mais quente”, é possível identificar várias falhas diferentes, como por exemplo, se um módulo inteiro está mais quente do que o habitual. Isso possibilita verificar indícios de problemas de interconexão, problemas em diodos de derivação quando pontos quentes estão em uma área concentrada nas células do painel, problemas de curtos-circuitos internos ou incompatibilidades de células.

Em uma imagem térmica, problemas de efeito de sombreamento e rachaduras nas células aparecem como pontos quentes. As imagens térmicas obtidas com ou sem carga e as condições de curto-circuito podem dar informações valiosas com respeito ao painel, o que permite a identificação de anomalias. É importante ressaltar que uma correta identificação da falha deve ser acompanhada por uma inspeção visual dos módulos e de testes de medição.

A Fig. 1 mostra imagens termográficas em células solares com defeitos de derivação em testes de medições LIT (do inglês: *Lock-in Thermography for Shunt Detection*), realizadas com o sistema SolarCheck em (a) 10 Hz e (b) 200Hz, por meio de estimulação onda senoidal (FLYR Systems, 2015a). O Sistema SolarCheck é adequado para testes de medições LIT em um ambiente de produção, bem como num cenário de investigação e desenvolvimento (FLYR Systems, 2015b).




Figura 1 - Imagens termográficas de derivações em células solares defeituosas em testes de medições LIT (do inglês: *Lock-in Thermography for Shunt Detection*), realizadas com o sistema SolarCheck em (a) 10 Hz e (b) 200Hz, por meio de estimulação onda senoidal (FLYR Systems, 2015a).

## 3. REDES NEURAIAS ARTIFICIAIS

No presente trabalho, buscou-se modelar uma RNA para detecção de pontos de aquecimento em imagens termográficas de painéis solares por meio da ferramenta computacional MATLAB (MATrix LABoratory, licença acadêmica para pesquisa nº 70.820). Três modelos de RNA foram utilizados: ABNET (do inglês: *AntiBody NETwork*) (Castro, Von Zuben e Deus Júnior, 2003), PSOM (Deus Júnior, Castro e Portugheis, 1999) (do inglês: *Non Parametric Self-Organizing Map*) e MLP (do inglês: *Multilayer Perceptron*) (Haykin, 2009). É importante ressaltar que a complexidade de uma rede ABNET e uma rede PSOM geralmente é inferior à de uma rede MLP.

### 3.1 Perceptrons de Camadas Múltiplas (MLP)

Há mais de quarenta e cinco anos, Minsky e Papert (1969), demonstraram que um único perceptron (PER) é incapaz de representar ou aproximar eficientemente diversas funções como, por exemplo, a função lógica XOR. Entretanto, Deus Júnior (2002) propõe a utilização de um PER para representar uma não linearidade  $f(R)$  relativamente complexa do ponto de vista de sua equação matemática, conforme publicado em Deus Júnior (2002). Por outro lado, a

história revela o desenvolvimento de novas estruturas que fossem capazes de representar e aproximar as funções que não eram atendidas pela estrutura desenvolvida por Roseblatt (1958) (Haykin, 2009).

Entre essas estruturas, destacam-se as RNA de camadas múltiplas ou perceptron com camadas múltiplas (MLP). Cybenko (1989) demonstrou rigorosamente que apenas uma única camada escondida seria suficiente para aproximar funções contínuas através de RNA. Outros pesquisadores também contribuíram nesse sentido (Hornik, 1989). Entretanto, a utilização do algoritmo de retro propagação do erro (do inglês: *backpropagation*) para treinamento das redes MLP e que utiliza a minimização do erro quadrático médio, acabaram por contribuir para a solução de muitos problemas e não somente para a aproximação de funções (Haykin, 2009). Assim, nesse trabalho, é utilizada uma rede MLP com uma única camada para detecção de anomalia em painéis fotovoltaicos, provocados por defeitos de derivação em testes de medições LIT. Os nós da rede respondem à entrada por meio da função de ativação tangente hiperbólica (sigmoide bipolar).

A principal função do processo de aprendizagem por meio do algoritmo de treinamento *backpropagation* é codificar um mapeamento de entrada-saída através do ajuste dos pesos sinápticos da rede MLP.

O perceptron de camadas múltiplas é treinado de maneira supervisionada em duas fases. A primeira fase é representada pela propagação do sinal que parte da entrada e segue em direção à saída. A outra fase consiste na retro propagação do erro que se baseia na comparação da resposta obtida pela rede e a resposta desejada, sendo que essa diferença é utilizada no caminho reverso para atualizar os pesos da rede. Assim, no treinamento da rede MLP, espera-se que a rede possa obter informações suficientes sobre o passado para se generalizar o futuro.

### 3.2 Rede ABNET

A rede ABNET (do inglês: *AntiBody NETwork*) é uma rede neural booleana competitiva, baseada em princípios do sistema imunológico de reconhecimento e resposta a microrganismos e moléculas imperceptíveis aos mecanismos sensoriais (Castro, Von Zuben e Deus Júnior, 2003).

Resumidamente, a rede ABNET baseia-se em processos de crescimento (inserção de novas classes na saída da rede), poda (remoção de classes pré-estabelecidas na saída) e atualização de pesos. Desta forma, a rede consegue identificar a presença de padrões redundantes.

O processo de reconhecimento de padrões por uma rede ABNET exige o uso de dados de entrada binários. Castro, Von Zuben e Deus Júnior (2003) demonstram que uma rede ABNET possui uma arquitetura de baixa complexidade e é capaz de solucionar problemas de reconhecimento de padrões binários específicos. A Fig. 2 apresenta um esquema para a poda e crescimento da rede ABNET que deve ser implementado pelo algoritmo de treinamento (Castro, Von Zuben e Deus Júnior, 2003).

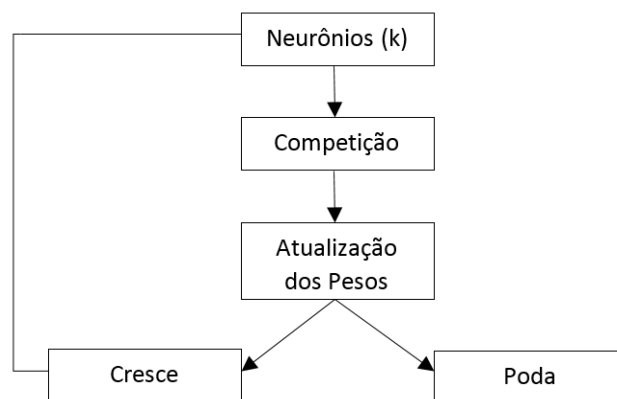


Figura 2 - Principais passos do algoritmo de aprendizagem da rede ABNET (Castro, Von Zuben e Deus Júnior, 2003).


### 3.3 Rede PSOM

A rede PSOM (do inglês: *Non Parametric Self-Organizing Map*) é uma rede de arquitetura não paramétrica que apresenta algumas mudanças no algoritmo de treinamento para os mapas auto organizáveis (SOM), propostos originalmente por Kohonen (Haykin, 2009).


A rede PSOM, assim como a ABNET, possui um algoritmo de treinamento fundamentado em um procedimento de poda, que tem por objetivo final a redução da dimensão topológica do mapa gerado.

A Fig. 3 apresenta uma comparação das arquiteturas típicas para SOM (estrutura bidimensional) e PSOM (estrutura unidimensional), com vizinhos do nó  $j$ ,  $NE_j$  ( $N_c$ ) publicados por Deus Júnior, Castro e Portugheis (1999).

O processo de reconhecimento de padrões de uma rede PSOM permite a utilização de valores de entrada não binários, o que de certa forma o torna mais vantajoso que a rede ABNET no reconhecimento de imagens com cor. E a rede PSOM possui uma arquitetura menos complexa do que a rede MLP. Isso é possível graças aos algoritmos de poda do algoritmo de treinamento das redes ABNET (Castro, Von Zuben e Deus Júnior, 2003) e PSOM (Deus Júnior, Castro e Portugheis, 1999) que promovem a retirada de unidades que não são representativas.



(a)



(b)

Figura 3 - Arquiteturas típicas com vizinhos do nó  $j$ ,  $NE_j(N_c)$ , para (a) estrutura bidimensional (SOM) e (b) estrutura unidimensional PSOM (Castro, Von Zuben e Deus Júnior, 2003).

### 3.4 Validação Cruzada

O processo de validação cruzada é uma ferramenta estatística padrão que serve de orientação para o bom treinamento de uma RNA (Stone, 1974) (Stone, 1978). Assim, o conjunto de dados é dividido em dois grupos (Haykin, 2009): (1) Grupo de Estimção (GE), representado por cerca de 80% das amostras; e (2) Grupo de Teste (GT), representado por aproximadamente 20% das amostras. Após o treinamento das redes ABNET, PSOM e MLP, as mesmas foram testadas por meio dos padrões do GT. Para evitar “memorização”, as redes foram treinadas por meio da contagem de épocas. Dá-se o nome de “uma época” à uma única apresentação aleatória dos padrões do GE durante à fase de treinamento.

### 3.5 Reconhecimento de Padrões

A divisão do espectro de técnicas na análise de imagens é realizada em três áreas: (1) processamento de baixo nível; (2) processamento de nível intermediário; e (3) processamento de alto nível. Assim, o processamento de alto nível é utilizado no trabalho onde o reconhecimento de padrões envolve o reconhecimento e a interpretação (Gonzalez, 1992).

Uma RNA realiza o processo de reconhecimento de padrões à medida que as entradas vão sendo repetidamente apresentadas com a respectiva categoria a que pertencem. Desta forma, a cada grupo de entradas, a rede é treinada para poder prever uma saída.

Após o reconhecimento de padrões na fase de treinamento, a validação ocorre na fase de teste, onde as entradas do GT são apresentadas para a rede, que agora possui elementos suficientes para reconhecer a classe à que pertence.

O reconhecimento de padrão realizado por uma rede neural é naturalmente estatístico, de tal forma que os padrões podem ser representados por pontos em um espaço multidimensional, dividido em regiões associadas a cada uma das classes (Haykin, 2009).

A complexidade da arquitetura de uma rede neural para reconhecimento de imagens complexas como a mostrada na Fig. 1 tende a ser elevada. Buscando o caminho da otimização, uma grande vantagem pode ser adquirida incluindo um estágio de pré-processamento das imagens seguido da própria modelagem da RNA (Bishop, 1995). Dessa forma, a maioria das aplicações utilizando redes neurais requer que os dados de entrada de um padrão passem por um pré-processamento para se obter o resultado esperado através da menor complexidade de arquitetura possível.

## 4. PROPOSTAS DE REDE ABNET, REDE PSOM E REDE MLP PARA DETECÇÃO DE ANOMALIAS EM PAINÉIS FOTOVOLTAICOS

### 4.1 Banco de Imagens

No caso em estudo, foram utilizadas as duas imagens termográficas complexas apresentadas na Fig. 1 para gerar um pequeno banco de imagens composto por 120 (cento e vinte) imagens de 16 x 16 *pixels* representativas (FLYR Systems, 2015a).

Para se reduzir a complexidade da arquitetura das redes neurais que seriam implementadas, as imagens passaram por um pré-processamento, onde foram extraídas amostras de pontos específicos das imagens originais do painel fotovoltaico, evidenciando a presença ou não de anomalias nas células.

Esse grupo de imagens foi submetido à classificação, o qual gerou um banco de imagens para representação de duas classes de padrões de imagens: imagens sem defeitos na célula fotovoltaica (classe C1); e imagens com defeitos na célula fotovoltaica (classe C2).

Dessa maneira, formou-se um banco de imagens composto por 60 (sessenta) imagens para cada classe. Esse banco de imagens foi dividido em um Grupo de Estimação (GE) e um Grupo de Teste (GT), utilizados para treinamento e validação das redes por meio de validação cruzada, respectivamente. A Fig. 4 apresenta cinco amostras de imagens correspondentes ao GE e GT, apresentadas apenas para ilustrar o banco de imagens.

As redes MLP, PSOM e ABNET utilizaram o banco de imagens completo com as classes C1 e C2. No caso da rede ABNET, o banco de imagens ainda passou por um processo de binarização utilizando o método de Otsu (Blanchet, 2006).



Figura 4 - Amostras do banco de imagens do (a) Grupo de Estimação (GE) e do (b) Grupo de Teste (GT).

## 4.2 Proposta de Rede ABNET

Buscando uma minimização da complexidade da arquitetura da RNA, o banco de imagens binarizadas foi utilizado no treinamento da rede ABNET, iniciado com 256 entradas e 1 (um) neurônio na única camada de saída.

A rede ABNET convergiu seu treinamento para duas saídas efetivas, representadas pelas classes C1 e C2. Analisando a matriz de pesos, verificou-se que a rede ABNET treinada possui 256 neurônios (valor de pesos binários igual a 1).

A Fig. 5 apresenta a estrutura final da rede ABNET onde 96 (noventa e seis) padrões do GE foram utilizados para o treinamento da rede, representando as classes C1 e C2. A representação da rede ABNET na Fig. 5 é muito peculiar: uma rede simples com 256 entradas convergindo em duas classes na camada de saída.

O GT composto por 24 (vinte e quatro) imagens foi apresentado para a rede ABNET, o que levou à taxa de acerto de 87,5% (oitenta e sete e meio por cento) na fase de testes da rede.

É importante ressaltar que a rede ABNET é uma rede com representação binária. Portanto, ela é extremamente sensível a variações de qualquer processo de binarização, como o método de Otsu (Blanchet, 2006).




Figura 5 - Representação da rede ABNET, após o treinamento para detecção de anomalia em painéis fotovoltaicos.

## 4.2 Proposta de Rede PSOM

De forma a minimizar a complexidade da arquitetura da RNA e a convergência do algoritmo de treinamento da rede PSOM, foram utilizadas apenas 2 (duas) amostras representativas de 16 x 16 pixels (256 entradas) para cada classe (C1, C2).

Um pré-processamento das imagens foi necessário para transformação das imagens coloridas do banco de imagens para representação em escala de cinza, sendo que os valores entre -1 e +1 foram utilizados para representar as imagens da classe C1 e C2.

A rede PSOM treinada iniciou-se com um número inicial de 20 saídas ( $N_c = 4$ ), sendo que durante o treinamento da rede ocorreram-se podas de neurônios. Ao final, a rede PSOM convergiu para uma configuração com 2 (duas) saídas, representando cada uma das classes C1 e C2.

A Fig. 6 apresenta o mapeamento das duas saídas pela rede PSOM após a realização do processo de poda durante o treinamento e convergência da rede PSOM.




Figura 6 - Representação das saídas da rede PSOM para as classes C1 e C2, após o treinamento para detecção de anomalia em painéis fotovoltaicos.

O treinamento da rede PSOM gerou uma matriz de pesos conectando as 256 entradas às 2 (duas) saídas. Assim, foram apresentados 24 padrões do GT para classificação da rede PSOM, sendo que a taxa de acerto foi de 87,5%. E para o GE, a rede PSOM apresentou uma taxa de acerto igual a 91,7%.

## 4.2 Proposta de Rede MLP

Redes MLP podem ser utilizadas para resolver problemas de classificação de padrões (Haykin, 2009). Assim, a Fig. 7 apresenta a estrutura da rede MLP treinada. Como pode ser observado, além das 256 entradas, há uma nova entrada se comparada com a rede ABNET e rede PSOM que é a representação do *bias*.




Figura 7 - Representação da rede MLP para detecção de anomalia em painéis fotovoltaicos.

Utilizando uma taxa de aprendizado  $\alpha = 0,01$  e um momento igual a  $\mu = 0,7$ , a arquitetura da rede MLP foi obtida na fase de treinamento ao se apresentar aleatoriamente 96 (noventa e seis) padrões do GE das classes C1 e C2.

Para a simulação, foram utilizados 2 (dois) neurônios para a camada escondida para convergência do algoritmo de treinamento *backpropagation* com um erro quadrático médio igual a  $2,0 \times 10^{-6}$  e número máximo de épocas de treinamento igual a 200.000 épocas.

Após o treinamento da rede MLP, foram apresentadas as 24 amostras do GT para a rede MLP, obtendo-se uma taxa de acerto igual a 96,0%.

Dessa forma, pode-se observar o potencial que uma rede MLP pode ter em relação à rede ABNET e PSOM. Além disso, a rede MLP é mais sensível à variação de problemas na captura de imagens. Ademais, possuem duas novas entradas para treinamento futuro de uma rede MLP utilizando um novo banco de imagens sensíveis à variação de temperatura local e umidade, por exemplo.

Portanto, a rede MLP apresenta um grande potencial para detectar anomalias em painéis fotovoltaicos. Entretanto, as redes ABNET e PSOM também possuem seu espaço de atuação, como será mostrado na próxima Seção.

#### 4. SOLUÇÃO PRÁTICA PARA IMPLEMENTAÇÃO DAS REDES ABNET, PSOM E MLP UTILIZANDO RASPBERRY PI 2

A complexidade da arquitetura da rede ABNET treinada é igual a 256 conexões. Para a rede PSOM, a número de conexões necessário é igual a 512. E para a rede MLP, o número de conexões é igual a 520. A Tab. 1 apresenta o número de conexões para cada rede treinada, bem como uma comparação para a complexidade da RNA e sua respectiva representação binária.

Tabela 1 - Complexidade para resolver o problema de anomalia em painéis fotovoltaicos.

RNA	Número de Conexões	Complexidade da RNA	Representação Binária
ABNET	256	Baixa	Sim
PSOM	512	Alta	Não
MLP	520	Alta	Não

Uma solução prática para implementação das redes ABNET, PSOM e MLP pode ser realizada utilizando Raspberry Pi 2 (Upton e Halfacree, 2014). Essa tecnologia utiliza um microcomputador de baixo custo, que serve como uma perfeita alternativa para promover uma interligação entre novos dispositivos para aquisição de imagens com um processo de identificação automático de anomalia em células de painéis fotovoltaicos. Como o processo pode ser patenteado, os autores preferem não divulgar o diagrama com detalhes da implementação.

#### 5. CONCLUSÃO

Os resultados obtidos durante o trabalho apontam que tanto redes MLP como PSOM são boas alternativas para se detectar anomalia em painéis fotovoltaicos, uma vez que o reconhecimento de padrões de imagens com diferentes níveis de cor oferece um nível de representação ajustado por um pré-processamento adequado para cada rede. Por outro lado, uma rede ABNET é muito mais simples, mas exige uma boa captura de imagens e o pré-processamento de imagens por meio da binarização de Otsu (Blanchet, 2006).

Por meio de validação cruzada, a taxa de acertos para a classificação dos padrões do GT da rede ABNET foi de 87,5%. O mesmo valor foi encontrado para a rede PSOM. E para a MLP, a taxa de acerto foi de 96,0%. Os resultados mostram corroboram para a utilização da rede ABNET, uma vez que a rede MLP e PSOM são mais complexas. Entretanto, à medida que novas informações, como temperatura e umidade, possam também ser obtidas, a rede MLP pode se tornar mais atrativa.

O principal ganho no uso das redes ABNET, PSOM e MLP na detecção de anomalia em painéis fotovoltaicos pode ser apontado para a deflagração antecipada de manutenções preventivas de limpezas dos módulos.

É importante ressaltar que um banco de imagens será construído em breve por meio do Projeto de Pesquisa e Desenvolvimento (P&D) em andamento. Portanto, espera-se que os estudos iniciais para a utilização das redes ABNET, PSOM e MLP utilizando Raspberry Pi 2 (Upton e Halfacree, 2014) possam gerar um novo pedido de patente de Modelo de Utilidade (MU) na detecção de anomalias em painéis fotovoltaicos.

#### REFERÊNCIAS

- C. M. Bishop, *Neural networks for pattern recognition*. 1st ed., Oxford: Clarendon Press, 1995.  
 E. Upton, G. Halfacree. *Raspberry Pi user guide*. 3rd ed. Hoboken, New Jersey: John Wiley & Sons, 2014.  
 F. J. Rosenblatt, “The Perceptron: A probabilistic model for information storage and organization in the brain”, *Psychological Review*, vol. 65, pp. 386–408, Jun. 1958.  
 FLIR Systems, “FLIR Solution Series: Solar Cell Development”, FLIR Systems, Inc., MoviTHERM, Automation Technology GmbH, Irvine, CA, USA. Disponível em: <<http://infraredsys.com/research.pdf>>. Acesso em: 25 ago. 2015.

- FLIR Systems, “MoviTHERM Solar-Check system”, FLIR Systems, Inc., MoviTHERM, Automation Technology GmbH, Irvine, CA, USA. Disponível em: < <http://www.movitherm.com/solar-check-ndt-solar-cells.html>>. Acesso em: 25 de ago. 2015.
- G Blanchet, M Charbit, Digital signal and image processing using Matlab. 4th ed. London: Iste, 2006.
- G. A. de Deus Júnior, L. N. de Castro, J. Portugheis, “Mapa Auto-Organizável Não-Paramétrica (PSOM) Aplicado À Decisão De Lógica Majoritária”, SBAI, pp. 100-155, 1999.
- G. A. de Deus Júnior, “Sistemas FFH-CDMA Codificados”, Ph.D. diss., Universidade Estadual de Campinas, Campinas, SP, Brasil, 2002.
- K Hornik, M Stinchcombe, H White, “Multilayer feedforward networks are universal approximators”, Neural networks, vol 2, pp. 359-366, May 1989.
- L. N. de Castro, F. J. Von Zuben, G. A. de Deus Júnior, “The construction of a Boolean competitive neural network using ideas from immunology”, Neurocomputing, vol 5, pp. 51-85, 2003.
- M. Minsky, P. Seymour. Perceptrons, Oxford, England: M.I.T. Press, 1969.
- M. Stone, “Cross-validation: A review,” Statistics: A Journal of Theoretical and Applied Statistics, vol. 9, pp. 127–139, 1978.
- M. Stone, “Cross-validators choice and assessment of statistical predictions”, Journal of the Royal Statistical Society, vol. B36, pp. 111–133, 1974.
- R. C. Gonzalez and R. E. Woods Processamento de Imagens Digitais. São Paulo: Editora Edgard Blücher Ltda., 1992.
- S. S. Haykin, Neural networks and learning machines. 3rd ed., Upper Saddle River: Pearson Education, 2009.
- M. Simon and E. L. Meyer, “Detection and analysis of hot-spot formation in solar cells,” Solar Energy Mater. Solar Cells, vol. 94, no. 2, pp. 106–113, 2010.

#### **ANOMALY DETECTION IN PHOTOVOLTAIC PANELS USING ABNET, PSOM AND MLP**

**Abstract.** *This paper main goal is to detect anomalies in photovoltaic panels installed in power generation systems using thermographic images. It was used image processing techniques and pattern recognition by means of artificial neural network with supervised and adaptive training. In order to implement the anomaly detection system it was selected from the tutorial "Solar Cell Development" by FLIR systems, thermographic images of photovoltaic cells with defects. The language of technical computing, MATLAB®, was used to make the preprocessing of all the collected images and it was also used for the training of an ABNET network, a PSOM network and a MLP network. Through the cross-validation method, the hit rate of the ABNET's network and PSOM's network was 87.5% and for the MLP the hit rate was 96.0%. The results corroborate for the use of these neural networks on a bank of images that will be created through a Research and Development Project (R&D) in progress.*

**Key words:** *Photovoltaic panels, Artificial Neural Networks, Pattern Classification.*