

Detection of Stressed Electronic Components in PV Inverter using Thermal Imaging

J. M. S. Callegari, L. S. Gusman, D. C. Mendonça, W. C. Amorim, I. S. L. Alves, H. A. Pereira Member, *IEEE*, F. A. C. Pinto

Abstract — Static power inverters emerged with the growth of renewable energy generation. These types of inverters have revolutionized the electrical energy conversion process, with advantages in terms of efficiency, volume, costs, among others. Static inverters are devices composed of inductors, capacitors, power semiconductors and signal microprocessor circuits. Several studies conclude that thermal stress is the main trigger for the degradation of its components, rapidly leading to reduced efficiency in the energy conversion process, economic losses and, in the worst case, system failure. In this sense, this work proposes an algorithm, based on thermal imaging processing, capable of detecting the overheated components in photovoltaic inverter. The algorithm is capable of presenting the temperature distribution in the inverter, detecting and diagnosing if some component has a temperature above the proper one for its normal functioning, evaluating several scenarios of active power processed by the inverter. The implemented classifier achieved a global exactness of 97.9% and a Kappa value of 0.974 on the image classification of a 1.5 kW photovoltaic inverter from PHB electronics.

Index Terms — Inverter, temperature, thermal stress, image processing.

I. INTRODUÇÃO

Nas últimas décadas, um grande aumento nos tipos de geração de energias renováveis, em especial a solar fotovoltaica e eólica, levou a um importante crescimento na aplicação de inversores estáticos para fins de conversão de energia. O inversor fotovoltaico (IFV) é um exemplo de inversor estático, responsável por realizar a interface entre o arranjo de painéis fotovoltaicos e o sistema elétrico de potência [1], [2].

Em um mercado marcado pela elevada competição, a minimização de custos, volume, peso e aumento da eficiência garantem aos IFVs maior competitividade e atratividade.

Grande parte destes requisitos podem ser avaliados pelas propriedades químicas e físicas de construção das chaves semicondutoras, além dos elementos indutivos e capacitivos presentes nos IFVs. Neste sentido, conceitos como confiabilidade e vida útil das chaves semicondutoras, capacitores e indutores são tópicos relevantes para o desenvolvimento de IFVs [3].

A confiabilidade de IFVs é um ponto de interesse dos fabricantes e dos investidores em energia solar fotovoltaica, uma vez que suas falhas representam essencialmente perdas econômicas devido a inoperância do sistema até sua substituição. Estudos de confiabilidade revelam que o aumento da temperatura de operação dos elementos do inversor é o fator desencadeador para causar desgastes e falhas destes componentes [3].

Dentre os componentes dos inversores, as chaves semicondutoras, capacitores e indutores lidam com condições de perda de energia, que impactam na temperatura de operação do inversor. Neste sentido, para prever falhas e fornecer regiões térmicas seguras de operação, a detecção de temperatura de elementos dos IFVs é uma etapa fundamental para garantir maior confiabilidade do inversor. Experimentos de campo mostram que os inversores são os equipamentos mais frágeis e susceptíveis a falha de todo o sistema fotovoltaico. De acordo com [4], cerca de 37% das falhas inesperadas ocorrem no inversor, sendo o estresse térmico o principal fator desencadeador [5]. Portanto, a análise e diagnóstico da temperatura de operação destes componentes são importantes para garantir a operação adequada do sistema.

A utilização da termografia infravermelha se destaca na detecção das condições térmicas de equipamentos elétricos, através da energia infravermelha emitida pela superfície do dispositivo. Desta forma, a estimativa da condição de operação do equipamento é realizada monitorando e registrando a distribuição térmica. Diversos trabalhos realizam estudos utilizando a termografia infravermelha. As referências [6], [7] propõem estudos de melhoramento de eficiência e uma melhor distribuição de carga térmica dentro dos dispositivos presentes em um IFV. As referências [8], [9], [10], [11] apresentam análises e controle térmico aplicados em sistemas de alta potência, como usinas eólicas e transformadores. As análises correlacionam a vida útil e confiabilidade dos dispositivos semicondutores com suas temperaturas de operação, validadas por imagens térmicas levantadas em laboratório.

Estudos relacionados com a estimativa do tempo de vida de elementos capacitivos, são apresentados em [12], considerando diferentes condições de operação balanceada e desbalanceada da rede elétrica. A referência [13] propôs análises considerando

J. M. S. Callegari, Centro Federal de Educação Tecnológica de Minas Gerais, Minas Gerais, Brasil, jm_callegari@hotmail.com.

L. S. Gusman, Centro Federal de Educação Tecnológica de Minas Gerais, Minas Gerais, Brasil, lucasgusman@yahoo.com.br

D. C. Mendonça, Centro Federal de Educação Tecnológica de Minas Gerais, Minas Gerais, Brasil, dayane.carmo.mend@gmail.com.

W. C. Amorim, Centro Federal de Educação Tecnológica de Minas Gerais,

Minas Gerais, Brasil, andwilliam14@hotmail.com.

I. S. L. Alves, Universidade Federal de Viçosa, Minas Gerais, Brasil, inglith_lage@yahoo.com.br

H. A. Pereira, Universidade Federal de Viçosa, Minas Gerais, Brasil, heverton.pereira@ufv.br

F. A. C. Pinto, Universidade Federal de Viçosa, Minas Gerais, Brasil, faepinto@ufv.br.

Corresponding author: Heverton Augusto Pereira

degradações dos dispositivos IGBTs com análise de camadas de imagens termográficas. As referências [14], [15] apresentam análises de câmeras termográficas infravermelhas como meio para detecção de falsificações em dispositivos semicondutores e identificação de defeitos em placas de circuito impresso. Neste sentido, as formas de inspeção humana de defeitos e falsificações são otimizadas por processamento de imagens térmicas.

Os trabalhos citados fazem uma análise individual dos dispositivos semicondutores, capacitores e sistemas eletrônicos de controle. Existe uma lacuna na literatura quanto à análise da distribuição de temperatura de um IFV, por meio do processamento de imagens térmicas aplicado à eletrônica de potência. Portanto, este trabalho busca preencher esta lacuna através de análises utilizando um IFV comercial. Os objetivos consistem em detectar os componentes presentes em um IFV, apresentar a sua distribuição de temperatura, efetuar medições das temperaturas de superfícies dos componentes e apresentar um diagnóstico de pontos quentes para tomada de decisão.

Assim, um estudo de identificação dos padrões de temperatura é realizado e, com base na categorização obtida, são detectados os componentes termicamente estressados.

O trabalho está dividido da seguinte forma: Seção II apresenta a descrição dos dispositivos utilizados: IFV e câmera térmica. A Seção III apresenta a metodologia para aquisição de imagens térmicas e os passos para desenvolvimento do algoritmo proposto. A Seção IV apresenta o estudo de caso. Os resultados e conclusões são mostrados nas Seções V e VI, respectivamente.

II. DESCRIÇÃO DO SISTEMA

Nesta seção, uma discussão detalhada sobre os dispositivos utilizados neste trabalho é apresentada.

A. Sistema Fotovoltaico

O IFV é responsável por extrair a máxima potência do arranjo de painéis fotovoltaicos e injetá-la na rede elétrica. A Fig 1(a) mostra o inversor comercial PHB 1500-NS e os dispositivos necessários para sua conexão à rede elétrica, enquanto a Fig 1(b) mostra sua estrutura interna. Trata-se de um inversor monofásico certificado, de potência nominal 1500 W e tensão mínima de entrada igual a 80 V. O controle do inversor é realizado por meio da instrumentação das medições de tensão e corrente, enviadas a um processador digital de sinais (do inglês, *digital signal processor* ou *DSP*). Devido a elevada frequência de operação deste microprocessador (60 MHz) e elevada taxa de amostragem (40 kHz) dos sinais dos sensores, esta região da placa pode aquecer significativamente, independentemente do nível de potência processada pelo inversor.

A Fig. 2(a) apresenta o esquemático do sistema fotovoltaico.

O arranjo de painéis fotovoltaicos é simulado utilizando a fonte de alimentação c.c. *Supplier FCCT 400-50-iF15451*, com função emulador de painel fotovoltaico. Através de sua interface, é possível traçar as curvas de determinado painel fotovoltaico apenas fornecendo alguns parâmetros de entrada, como tensão de circuito aberto (V_{oc}), tensão e corrente no ponto de máxima potência (V_{mp} e I_{mp} , respectivamente),

corrente de curto-circuito (I_{sc}) e parâmetros meteorológicos (irradiância solar G e temperatura ambiente T_a). O arranjo fotovoltaico emulado é conectado ao inversor monofásico.

O controle do inversor consiste em dois estágios: estágio c.c. elevador e estágio inversor c.c./c.a. O primeiro é mostrado na Fig. 2(b) sendo responsável por aumentar a faixa de operação do inversor e extrair a máxima potência do arranjo, por meio de um algoritmo de rastreamento de ponto de potência máxima (MPPT) [16]. O segundo estágio é mostrado na Fig. 2(c) e possui duas malhas de controle: a malha externa é responsável por controlar a tensão do barramento c.c. e também a potência reativa injetada [17]. Além disso, calcula a referência de corrente para a malha interna que é responsável por controlar a corrente injetada na rede [18].

B. Câmera FLIR C2

Qualquer corpo à uma temperatura maior que o zero absoluto emite energia, na forma de radiação, de acordo com a Lei de Planck [19]. Para temperaturas inferiores a 700 °C, esta emissão ocorre na faixa do infravermelho (fora do espectro visível). Neste sentido, dispositivos capazes de gravar imagens térmicas por meio da tradução de sinais no domínio da radiação infravermelha são necessários, como a câmera *FLIR C2*.

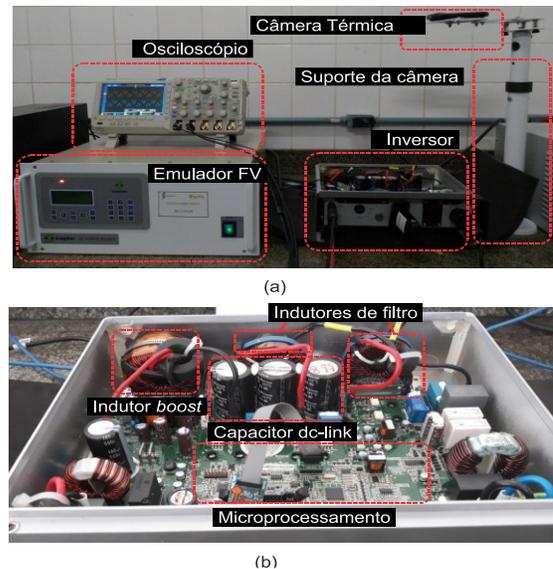


Fig 1. (a) Plataforma para aquisição das imagens térmicas dos componentes do inversor PHB 1500-NS. (b) Vista superior da estrutura interna do inversor.

Trata-se de uma câmera termográfica de resolução térmica 320 x 240 *pixels*, precisão ± 2 °C e capacidade de detectar temperatura de objetos na faixa de -10 °C à 150 °C, numa faixa espectral de 7,5 à 14 μm [20], [21]. Adicionalmente, as imagens de saída apresentam falsas cores, determinadas de acordo com a palheta de cores selecionada. Independente da palheta de cor, as regiões mais quentes são representadas por cores vivas, enquanto regiões mais frias são representadas por cores mortas (tons pastéis).

A imagem térmica possui três bandas e utiliza o sistema de cor aditivo *RGB*. As bandas *R* (vermelho, do inglês *red*), *G* (verde, *green*) e *B* (azul, *blue*) são combinadas para sensibilizar o sistema visual humano e dar sensação de cor. Os *pixels* de

cada banda possuem valores de 0 a 255, uma vez que a profundidade, ou resolução do *pixel*, é 8 *bits*. Além disso, para relacionar os valores medidos de temperatura à intensidade de cada *pixel*, o *software FLIR Tools* é utilizado.

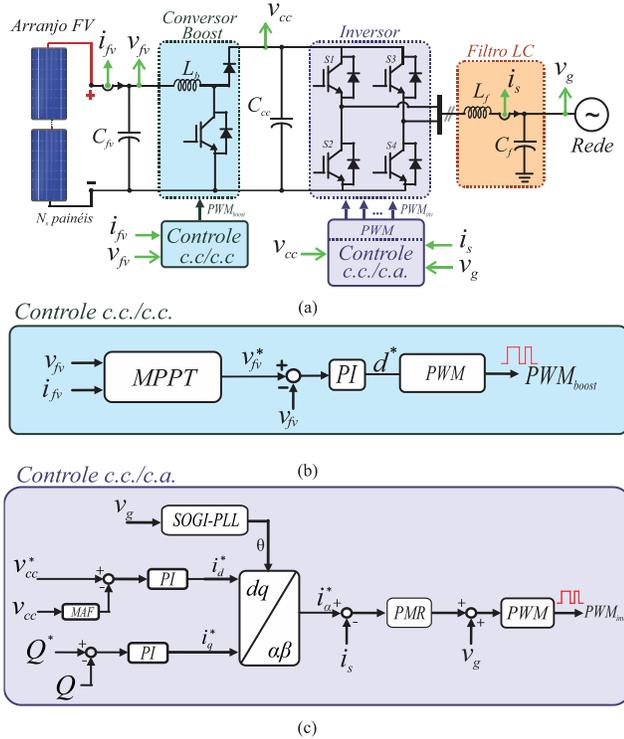


Fig. 2. (a) Sistema fotovoltaico conectado à rede. Estratégias de controle de estágio: (b) c.c. (c) c.c./c.a.

III. METODOLOGIA

A. Aquisição das Imagens Térmicas

A Fig. 3 apresenta o fluxograma das etapas de avaliação térmica do inversor. O primeiro passo será descrito nesta seção e consiste na aquisição das imagens utilizando a câmera *FLIR C2*. Nesta etapa, alguns cuidados foram tomados para obtenção das imagens térmicas, a saber:

- Ambiente de iluminação controlada;
- Posição fixa da câmera *FLIR C2* a uma altura de 55 cm em relação ao objeto, com auxílio de um suporte fixado;
- Posição fixa do inversor;
- As fotos térmicas foram tiradas após o inversor processar determinada condição de potência durante 30 min (até a temperatura atingir o regime estacionário);
- Um intervalo de 1h foi considerado entre os diferentes estudos de caso, para garantir que a temperatura dos inversores atinja a temperatura ambiente.

Para aquisição das imagens, os inversores foram sujeitos a diferentes níveis de potência ativa processada, que foi variada acrescentando painéis ao arranjo fotovoltaico através da fonte emuladora.

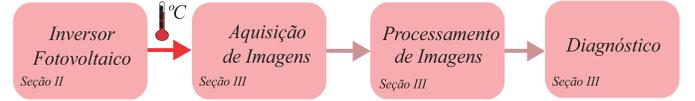


Fig. 3. Fluxograma das etapas para desenvolvimento do algoritmo.

B. Processamento de Imagens Digitais

A detecção automática de inversores sob elevadas temperaturas de operação tem ampla aplicabilidade na área de eletrônica de potência, especialmente vinculada à confiabilidade e vida útil destes dispositivos. Esta seção objetiva apresentar os conceitos básicos para construção de uma regra de decisão que irá discriminar *pixels* da imagem. Desta forma, a distribuição térmica por meio de uma classificação em cores é realizada e exibida a região com temperatura superior a um certo limiar crítico. Um algoritmo foi desenvolvido utilizando a linguagem de programação *Python* na plataforma *Jupyter Notebook*. Bibliotecas como *OpenCV* [22], *NumPy* [23] e *Openpyxl* [24] foram utilizadas.

A Fig. 4 apresenta o fluxograma de etapas de construção/treinamento do classificador e validação do algoritmo desenvolvido. O classificador é previamente treinado utilizando um banco de amostras retirado da imagem térmica.

Uma vez desenvolvido, testa-se o classificador e um diagnóstico de temperatura é fornecido ao final do algoritmo.

1) Treinamento dos Parâmetros dos Descritores

Nesta etapa, são definidos as classes, os descritores e o tipo de classificador. As bandas do espaço de cor *RGB* foram escolhidas como descritores, por dois motivos: (i) imagens térmicas possuem cores vivas, não sendo necessário trocar o espaço de cor *RGB* para *HSV* (matiz, saturação e valor, do inglês *hue, saturation and value*), *Lab* (luminosidade, valor vermelho/verde e valor azul/amarelo, do inglês *lightness, red/green value and blue/yellow value*) ou qualquer outro; e (ii) as características de temperatura dos componentes estão diretamente relacionadas com a cor dos *pixels* das imagens térmicas.

O treinamento consiste no recolhimento de amostras e cálculo dos parâmetros da função de densidade de probabilidade (FDP) $P(\vec{v}|c_k)$ da k -ésima classe (c_k), dada por:

$$P(\vec{v}|c_k) = \frac{e^{-\frac{1}{2}[(\vec{v}-\mu_{c_k})^T(\Sigma_{c_k})^{-1}(\vec{v}-\mu_{c_k})]}}{\sqrt{(2\pi)^N |\Sigma_{c_k}|}}, \quad (1)$$

onde μ_{c_k} e Σ_{c_k} são o vetor de média e a matriz de covariância de cada classe c_k , respectivamente. N é a ordem da matriz quadrada de covariância, cujo valor é igual ao número de descritores. \vec{v} é o vetor de entrada da imagem devidamente redimensionado, contendo informações de intensidade dos *pixels* nas bandas *R*, *G* e *B*.

Foram selecionadas seis classes de cor ($k \in \{1, \dots, 6\}$), conforme indicado na Fig. 4. Amostras de 20×20 *pixels* de cada classe foram tomadas. Um critério de predominância dos agrupamentos de cor na imagem térmica foi utilizado para escolha das classes, i.e., as cores azuis (claro e escuro), verde/amarelo, laranja, vermelho e branco. Os vetores de média

e matriz de covariância dos descritores R , G e B de cada amostra foram obtidos no processo de treinamento do classificador, conforme descrito em [25].

Após o treinamento supervisionado, o classificador de *Bayes* é utilizado de acordo com a seguinte regra:

$$P(\vec{v}|c_i)P(c_i) > P(\vec{v}|c_j)P(c_j), \quad (2)$$

onde $P(\vec{v}|c_i)$ e $P(\vec{v}|c_j)$ são calculadas por (1) com $\{i, j\} \in k$ e $i \neq j$. $P(c_i)$ e $P(c_j)$ são as probabilidades a priori das classes i e j ocorrerem, respectivamente. Além disso, esta probabilidade de ocorrência das seis classes foi considerada igual.

A regra de *Bayes* trata de uma abordagem estatística responsável por classificar um conjunto de dados a uma determinada classe, baseando-se na probabilidade deste dado ocorrer nesta classe [26]. Por exemplo, se o termo à esquerda da equação (2) for maior que o termo da direita, então o classificador designará o *pixel* da imagem de entrada à classe i .

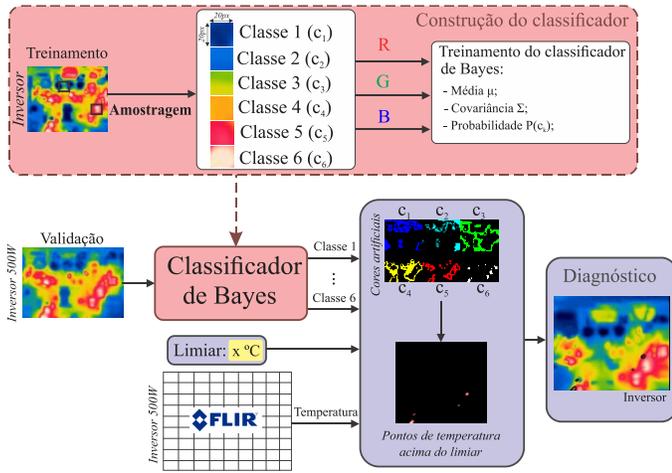


Fig. 4. Fluxograma do processo de treinamento do classificador e validação do algoritmo.

2) Validação e Características do Algoritmo

O algoritmo recebe as imagens térmicas do inversor operando sob diferentes níveis de injeção de potência, as matrizes de temperatura fornecidas pelo próprio *software* da câmera *FLIR C2* e um limiar de temperatura segura de operação dos inversores. De forma automática, o *script* realiza a classificação de cada imagem térmica de entrada em seis diferentes classes. Vale ressaltar que o classificador foi desenvolvido na etapa anterior com as amostras coletadas; neste passo, uma imagem térmica completa é aplicada ao classificador e não mais às amostras de treinamento.

A câmera *FLIR C2* realiza um autoajuste das cores em cada imagem térmica obtida. Por exemplo, se o ponto mais quente da imagem térmica estiver a 40°C, então a câmera atribui a cor branca a estes *pixels* e reduz a escala de cor a medida que a vizinhança apresenta menores temperaturas. Para obter resultados acurados, foi necessário recorrer à matriz de temperaturas de cada imagem térmica fornecidas pelo *software* da câmera e contornar este problema do autoajuste.

Posteriormente, a temperatura *pixel a pixel* de cada classe é determinada. Um limiar de temperatura de operação é configurado para o inversor, objetivando identificar componentes que podem sofrer degradação excessiva se operando acima de determinada temperatura. Um diagnóstico é dado ao final, apresentando os componentes termicamente estressados por meio de uma envoltória convexa aplicada em cada região de temperatura acima do limiar.

3) Desempenho do Classificador

A análise de qualidade da classificação se deu quantitativamente, através dos índices de exatidão global e *Kappa*, extraídos da matriz de confusão. A matriz de confusão é obtida por meio da aplicação do classificador desenvolvido em novas amostras de cada classe e são construídas a partir da tabulação cruzada entre os mapas gerados pelos classificadores com o mapa de referência [27]. A exatidão global EG e o coeficiente *Kappa* (K) são calculados, respectivamente, por (3) e (4):

$$EG = \frac{1}{n} \sum_{i=1}^k x_{ii} \times 100\%, \quad (3)$$

$$K = \frac{n \sum_{i=1}^k x_{ii} - \sum_{i=1}^k x_{i\oplus} x_{\oplus i}}{n^2 - \sum_{i=1}^k x_{i\oplus} x_{\oplus i}}, \quad (4)$$

onde n é o número de amostras coletadas, x_{ii} são os componentes da diagonal principal da matriz de confusão, k é o número de classes, $x_{\oplus i}$ e $x_{i\oplus}$ são as somas da coluna i e da linha i da matriz de confusão, respectivamente. O coeficiente *Kappa* utiliza todos os elementos da matriz de confusão no seu cálculo, indicando se a classificação está de acordo com os dados de referência, desconsiderando acertos ao acaso.

IV. ESTUDO DE CASO

Os parâmetros do painel utilizado, assim como a quantidade de painéis arranjados em série N_s e paralelo N_p para cada estudo de caso são mostrados na TABELA 1.

TABELA 1
PARÂMETROS DO ARRANJO FOTOVOLTAICO

Painel FSM100	Valor unit.	Valor por arranjo (N_s, N_p)		
		(5,1)	(10,1)	(15,1)
P_{max} (W)	100	500	1000	1500
V_{oc} (V)	22,5	112,5	225	337,5
I_{sc} (A)	5,52	5,52	5,52	5,52
V_{mp} (V)	18,6	93	186	279
I_{mp} (A)	5,21	5,21	5,21	5,21
G (W/m ²)		1000		
T_a (°C)		25		

As imagens térmicas obtidas que serão processadas, para cada caso, estão mostradas na Fig. 5.

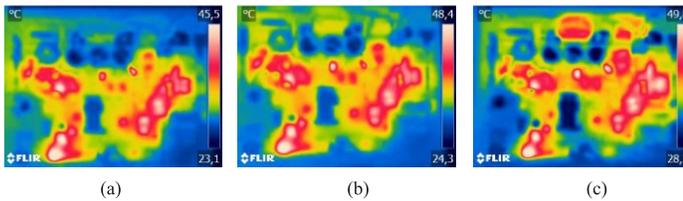


Fig. 5. Imagens térmicas do inversor PHB 1500-NS para potência processada de (a) 500 W; (b) 1000 W; (c) 1500 W.

As Fig. 5(a), (b) e (c) apresentam o comportamento térmico do inversor injetando 500 W, 1000 W e 1500 W na rede elétrica, respectivamente.

V. RESULTADOS

A metodologia desenvolvida neste trabalho foi validada para 3 imagens referentes ao inversor para os respectivos níveis de potência já descritos.

A. Processamento do Inversor PHB 1500-NS

O classificador foi utilizado para diferenciar 6 classes do tipo:

- Classe 1: Azul escuro;
- Classe 2: Azul claro;
- Classe 3: Verde-amarelo;
- Classe 4: Laranja;
- Classe 5: Vermelho;
- Classe 6: Branco.

A Fig. 6 indica como estão separadas essas 6 classes utilizando o classificador *Bayesiano* ao lado da imagem original, para cada condição de injeção de potência.

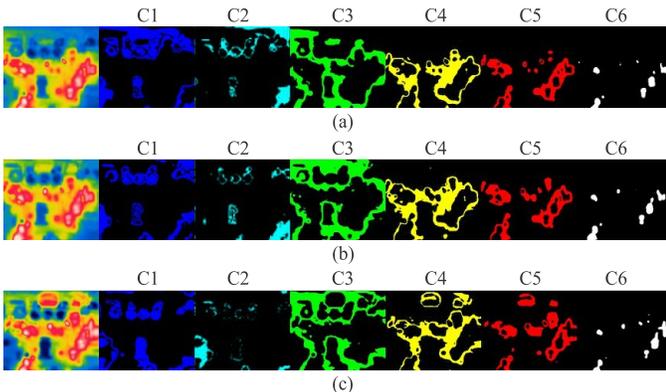


Fig. 6. Distribuição das classes separadas através do classificador de *Bayes* desenvolvido para o inversor em condições de: (a) 500 W, (b) 1000 W e (c) 1500 W.

Esta classificação tem um resultado qualitativo satisfatório, quando são associadas as posições classificadas com as respectivas posições na imagem original.

Em termos quantitativos, é interessante saber as faixas de temperatura ocupadas por cada classe individual. Na Fig. 7, encontra-se um histograma descrevendo o número de *pixels* associados a cada classe por determinada faixa de temperatura. Dado o bom projeto térmico do inversor, verifica-se uma distribuição na faixa de 20-50 °C [28], [29]. Nota-se, também,

como a distribuição tende a se deslocar mais à direita conforme a potência processada pelo inversor aumenta.

A Fig. 8 indica quais são as regiões, em cada classe, que apresentam partes do inversor que se encontram com temperaturas acima do limiar estabelecido de 45° C. Tais regiões foram contornadas através de uma região convexa que contenha todos os pontos. Este contorno obtido foi desenhado na imagem original de forma a envolver esta região e identificar os componentes que estão operando acima dessa temperatura. Tais componentes acima do limiar incluem os indutores de filtro e o circuito de instrumentação e microprocessamento.

Este limiar foi escolhido como um valor apropriado para a superfície dos componentes a uma operação de 1000 W.

Utilizando este limiar, é possível simular duas condições distintas: quando o inversor opera com capacidade abaixo ou acima desse ponto, simulando condições de folga e sobrecarga, respectivamente.

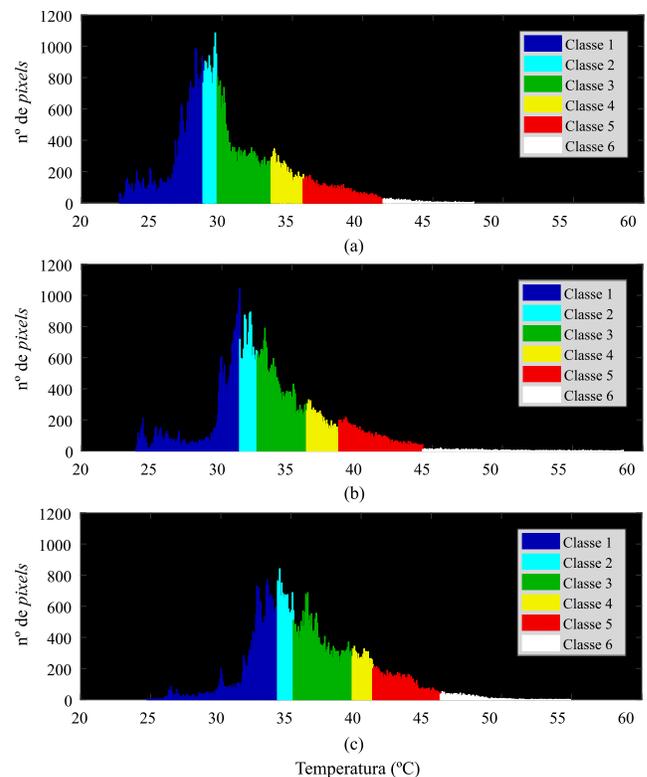


Fig. 7. Distribuição dos pixels para cada faixa de temperatura para cada classe do inversor PHB para potência de: (a) 500W, (b) 1000W e (c) 1500W.

Como visto na Fig. 8, operando abaixo da condição nominal, o inversor apresenta valores maiores que o crítico em seus circuitos de instrumentação.

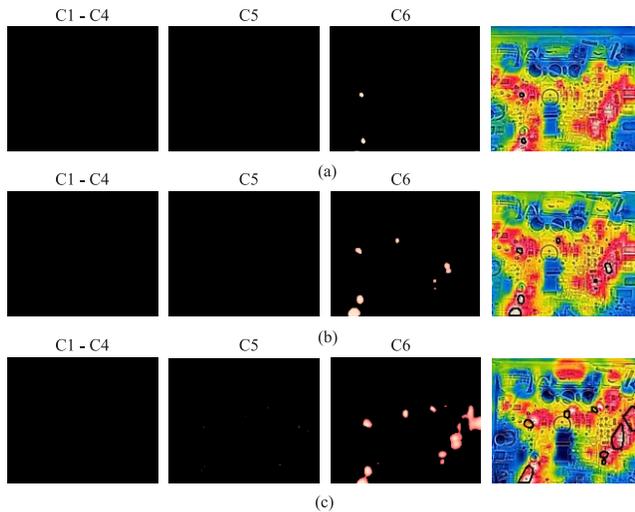


Fig. 8. Identificação dos pontos críticos de temperatura para cada classe do inversor PHB para potência de: (a) 500W, (b) 1000W e (c) 1500W.

Esta região do inversor aquece independentemente da condição de potência processada pelo inversor. No entanto, indiretamente, os circuitos de instrumentação podem sofrer maior aquecimento, devido a presença dos mecanismos de transferência de calor (condução e convecção) quando o inversor processa mais potência.

Para validação do desempenho do classificador, a matriz de confusão foi gerada com base nas classificações desenvolvidas para a imagem da Fig. 5(b). Foram escolhidas 6 amostras de tamanho 15×15 pixels, com exceção da amostra branca que tem tamanho inferior na imagem. Como há a certeza de que essas amostras são referentes à respectiva classe, pode-se contabilizar os erros do classificador.

Por meio da matriz da TABELA 2, pode-se calcular a EG de acordo com a diagonal principal. O valor de EG obtido foi de 97,9%, indicando que esta quantidade dos pontos da amostra foi corretamente atribuída para cada classe. Um parâmetro interessante a ser observado é o coeficiente *Kappa*, o qual subtrai da EG as classificações corretamente obtidas ao acaso.

Este parâmetro consegue distinguir um classificador bom de um totalmente aleatório, sendo calculado de acordo com o total da linha e coluna. Foi obtido um $K = 0,974$, indicando bom compromisso do classificador com as classes desejadas.

TABELA 2
MATRIZ DE CONFUSÃO PARA O INVERSOR PHB 1500-NS COM NÍVEL DE POTÊNCIA DE 1KW.

Classes	C1	C2	C3	C4	C5	C6	Total L.
C1	225	25	0	0	0	0	250
C2	0	200	0	0	0	0	200
C3	0	0	225	0	0	0	225
C4	0	0	0	225	0	0	225
C5	0	0	0	0	225	3	228
C6	0	0	0	0	0	207	207
Total C.	225	225	225	225	225	210	1335

VI. CONCLUSÃO

Este trabalho apresentou a análise de estresse térmico de componentes elétricos e eletrônicos de um inversor fotovoltaico via processamento de imagens térmicas. A análise térmica proposta revelou uma elevada distribuição de temperaturas nos indutores de filtro e circuitos de instrumentação e microprocessamento do inversor. Este fato foi agravado com o aumento de injeção de potência ativa, levando à extrapolação da temperatura de diversos componentes em relação ao limiar de temperatura recomendado.

Por fim, os testes utilizando coeficiente de *Kappa* e exatidão global para os classificadores desenvolvidos revelaram boa performance e elevada taxa de acerto na classificação, atingindo exatidão global de 97,9% e *Kappa* de 0,974 na classificação das imagens térmicas do inversor. Considerando o desempenho do classificador, valida-se a separação correta entre as classes de temperatura, como almejado por este trabalho. Além disso, a distinção das temperaturas críticas e sua identificação no circuito original fornecem um excelente parâmetro para diagnóstico do inversor.

O uso destas imagens térmicas é de grande relevância nos pontos de projeto do inversor fotovoltaico. Ao identificar os elementos com maior temperatura, ações de resfriamento local podem ser tomadas para garantir a segurança destes elementos específicos. Além disto, o conhecimento da distribuição de temperatura característica pode levar o projetista a construir a placa do conversor de forma a garantir distribuição uniforme de temperatura, otimizando a troca de calor com o ambiente.

AGRADECIMENTOS

Este estudo foi financiado em parte pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código Financeiro 001, Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG).

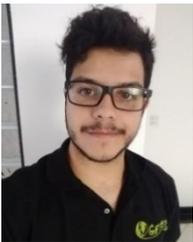
REFERÊNCIAS

- [1] Renewables 2018: Market analysis and forecast from 2018 to 2023, [Online]. Available: <https://www.iea.org/renewables2018/power/>. [Accessed May 2019].
- [2] F. C. Melo, R. R. Spaduto, L. C. G. Freitas, C. E. Tavares, J. R. M. Junior and P. H. O. Rezende, "Harmonic Distortion Analysis in a Low Voltage Grid-Connected Photovoltaic System," *IEEE Latin America Transactions*, vol. 13, pp. 136-142, 2015.
- [3] Y. Yang, A. Sangwongwanich and F. Blaabjerg, "Design for reliability of power electronics for grid-connected photovoltaic systems," *Trans. Power Electron. Appl.*, vol. 1, no. 92-103, p. 1, 2016.
- [4] A. Golnas, "PV system reliability: An operator's," *IEEE J. of Photovoltaics*, pp. 416-421, 2013.
- [5] P. Reigosa, "Smart derating of switching devices for designing more reliable pv inverters," *Master's thesis, Aalborg University*, 2014.

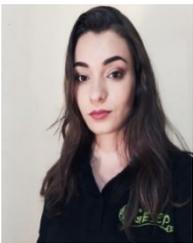
- [6] V. Sodan, S. Stoels, H. Oprins, S. Decoutere, F. Altmann, M. Baelmans and I. DeWolf, "Fast and distributed thermal model for thermal modeling of gan power devices," *IEEE Trans. on Compon., Packag. and Manuf. Technol.*, vol. 8, no. 10, pp. 1747-1755, 2018.
- [7] X. Perpiñà, M. Vellvehi, R. J. Werkhoven, J. Jakovenko, J. M. G. Kunen, P. Bancken, P. J. Bolt and X. Jordà, "Thermal management strategies for low- and high-voltage retrofit led lamp drivers," *IEEE Trans. on Power Electron.*, vol. 34, no. 4, pp. 3677-3688, 2019.
- [8] C. Batunlu and A. Albarbar, "Strategy for enhancing reliability and lifetime of dc-ac inverters used for wind turbines," *Microelectronics Reliability*, vol. 85, pp. 25-37, 2018.
- [9] F. Hahn, M. Andresen, G. Buticchi and M. Liserre, "Thermal analysis and balancing for modular multilevel converters in hvdc applications," *IEEE Trans. on Power Electron.*, vol. 33, no. 3, pp. 1985-1996, 2018.
- [10] Y. Ko, M. Andresen, G. Buticchi and M. Liserre, "Discontinuous-modulation-based active thermal control of power electronic modules in wind farms," *IEEE Trans. on Power Electron.*, vol. 1, no. 301-310, p. 34, 2019.
- [11] R. Silva, J. B. Filho, J. L. Jr. and J. Henríquez, "Thermal Modeling of a Capacitor Voltage Transformer Using CFD Techniques," *IEEE LATIN AMERICA TRANSACTIONS*, vol. 16, no. 8, pp. 2234-2239, 2018.
- [12] H. Wang, P. Davari, H. Wang, D. Kumar, F. Zare and F. Blaabjerg, "Lifetime estimation of dc-link capacitors in adjustable speed drives under grid voltage unbalances," *IEEE Trans. on Power Electron.*, vol. 34, no. 5, p. 4064-4078, 2019.
- [13] D. Chen, Y. Liu, W. Zhang, M. Zheng and S. Zhang, "Detection of igbt degradation in npc inverter based on infrared thermography," *Journal of Computational Methods in Sciences and Engineering*, vol. 8, no. 2, p. 459-468, 2018.
- [14] B. Kaur, A. Kaur and G. Kaur, "Application of image processing using computer in detection of defective printed circuit boards," *International Journal of Advanced Research in Computer Science*, vol. 8, no. 5, pp. 1043-1046, 2017.
- [15] N. Asadizanjani, M. Tehranipoor and D. Forte, "Counterfeit electronics detection using image processing and machine learning," *IOPscience - Journal of Physics*, 2017.
- [16] I. Houssamo, F. Locment and M. Sechilariu, "Maximum power tracking for pv system: Development and experimental comparison of two algorithms," *Renew. Energ.*, pp. 2381-2387, 2010.
- [17] H. Akagi, Y. Kanazawa and A. Nabae, "Instantaneous Reactive Power Compensators Comprising Switching Devices without Energy Storage Components," *IEEE Trans. on Ind. Appl.*, zols. IA-20, no. 3, pp. 625-630, 1984.
- [18] L. S. Xavier, A. F. Cupertino and H. A. Pereira, "Ancillary services provided by photovoltaic inverters: Single and three phase control strategies," *Computers & Electrical Engineering*, vol. 70, pp. 102-121, 2018.
- [19] J. W. Halliday and D. Resnick, *Fundamentos de Física 4*, LTC, 2016.
- [20] FLIR, "User's manual FLIR Cx series," *FLIR Systems*, 2017.
- [21] Thermography camera flir c2, [Online]. Available: <https://prod.flir.com.br/products/c2/>. [Accessed May 2019].
- [22] Opencv python tutorials, [Online]. Available: https://docs.opencv.org/3.0-beta/doc/py_tutorials/py_tutorials.html. [Accessed May 2019].
- [23] Numpy and scipy documentation, [Online]. Available: <https://docs.scipy.org/doc/>. [Accessed May 2019].
- [24] Openpyxl python tutorials, [Online]. Available: <https://openpyxl.readthedocs.io/en/stable/>. [Accessed June 2019].
- [25] S. C. d. Souza and C. Lopes, "Modelo de classificador por regra aplicado a detecção de pele baseado em discriminantes de cores," *Revista Multidisciplinar Pey Keyo Científico*, vol. 4, pp. 1-14, 2018.
- [26] H. Maia, "Uma proposta para detecção automática de câncer de pele baseado em características de forma, cor e textura," *Master's thesis, Universidade Federal Rural do Semi Árido*, 2015.
- [27] B. S. Oliveira and G. A. V. Mataveli, "Avaliação do desempenho dos classificadores isoseg e bhattacharya para o mapeamento de áreas de cana-de-açúcar no município de Barretos - SP," *Simpósio Brasileiro de Sensoriamento Remoto (SBSR)*, vol. 4, pp. 89-96, 2013.
- [28] U. C and F. Blaabjerg, "Asymmetric power device rating selection for even temperature distribution in NPC inverter," *IEEE Energy Conversion Congress and Exposition*, pp. 4196-4201, 2017.
- [29] M. Electric, "Power Module Reliability," [Online]. Available: www.mitsubishielectric.com/semiconductors/products/pdf/r. [Accessed 13 Fevereiro 2020].



João Marcus Soares Callegari é mestrando em Engenharia Elétrica pelo Centro Federal de Educação Tecnológica de Minas Gerais (CEFET-MG), na área de Eletrônica de Potência e Energias Renováveis. Possui graduação em Engenharia Elétrica pela Universidade Federal de Viçosa (UFV). Atualmente é integrante da Gerência de Especialistas em Sistemas Elétricos de Potência – GESEP, onde desenvolve trabalhos na área de confiabilidade e vida útil de dispositivos de potência e controle de conversores fotovoltaicos.



Lucas Soares Gusman é mestrando em Engenharia Elétrica pelo Centro Federal de Educação Tecnológica de Minas Gerais (CEFET-MG) na área de Eletrônica de Potência e Energias Renováveis. Possui graduação em Engenharia Elétrica pela Universidade Federal de Viçosa (UFV). Atualmente trabalha no estudo dos impactos de usinas fotovoltaicas no fator de potência, correção de fator de potência com inversores multifuncionais trifásicos, bancadas experimentais de algoritmos MPPT de conversores c.c. e coleta de dados meteorológicos para avaliação de vida útil de conversores.



Dayane do Carmo Mendonça graduou-se em Engenharia Elétrica pela Universidade Federal de Viçosa (UFV) em 2018. Possui ensino médio técnico em Eletrotécnica pelo Centro Federal de Educação Tecnológica de Minas Gerais (CEFET-MG), campus Leopoldina. Na UFV atuou como gerente de Qualidade na Empresa Júnior de Engenharia Elétrica (diElétrica). Atualmente, é mestranda do Programa de Pós-Graduação em Engenharia Elétrica do CEFET-MG e especialista do GESEP, onde desenvolve trabalhos e pesquisas na área de Sistemas Elétricos de Potência, com foco em Conversores Modulares Multiníveis e sistemas fotovoltaicos.



William Caires Silva Amorim possui graduação em Engenharia Elétrica pela Universidade Federal de Viçosa – UFV e mestrado em Engenharia Elétrica pela pelo Centro Federal de Educação Tecnológica de Minas Gerais (CEFET-MG). Atualmente é professor substituto do Departamento de Engenharia Elétrica da UFV e integrante do GESEP - Gerência de Especialistas em Eletrônica de Potência, onde desenvolve pesquisas na área de Conversores Modulares Multiníveis (MMC) aplicados em sistemas ES-STATCOM.



Inglith de Souza Lage Alves é mestranda em Engenharia Agrícola pela Universidade Federal de Viçosa (UFV), na área de Mecanização Agrícola com ênfase em Agricultura de Precisão. Possui graduação em Engenharia de Agrimensura e Cartográfica pela Universidade Federal de Uberlândia (UFU). Atualmente trabalha no desenvolvimento de sistemas de posicionamento com correção em tempo real para VANTs.



Heverton Augusto Pereira possui graduação em Engenharia Elétrica pela Universidade Federal de Viçosa – UFV, mestrado em Engenharia Elétrica pela Universidade Estadual de Campinas – UNICAMP e doutorado na Universidade Federal de Minas Gerais – UFMG, com realização de parte do doutorado na Universidade de Aalborg – Dinamarca (AAU). Desde 2009 é professor Adjunto II do Departamento de Engenharia Elétrica da Universidade Federal de Viçosa onde desenvolve pesquisas relacionadas a eletrônica de potência aplicada a fontes renováveis de energia solar fotovoltaica, e também qualidade da energia elétrica.



Francisco de Assis de Carvalho Pinto possui graduação em Engenharia Agrícola pela Universidade Federal de Viçosa (1990), mestrado em Engenharia Agrícola pela Universidade Federal de Viçosa (1992) e doutorado em Engenharia Agrícola - University of Illinois (2000). Atualmente é professor Associado da Universidade Federal de Viçosa. Tem experiência na área de Engenharia Agrícola, com ênfase em Visão Artificial, atuando principalmente nos seguintes temas: agricultura de precisão, visão artificial, processamento de imagens, simulação e máquinas agrícolas.