

Detecção Automática de Microcomponentes SMT Ausentes em Placas de Circuito Impresso

Cleandro S. Rocha, Mathias A. G. Menezes, Felipe G. Oliveira
Instituto de Ciências Exatas e Tecnologia
Universidade Federal do Amazonas
Itacoatiara, Brasil
{cr.engsoftware,mathiasdemenezes,felipe.inad}@gmail.com

Abstract—This work presents a visual inspection approach to detect absence/presence of surface mount components (SMC) on printed circuit boards (PCB). We propose a methodology based on the combination of Machine Vision and Machine Learning to detect component absence, with more quality and precision, using noised digital images acquired directly from PCB industrial production line. The applicability of method was tested for automatic visual inspection in motherboards, where the demand of these components is high. The results obtained demonstrates the robustness of our methodology in images with high levels of gaussian and salt and pepper noise, obtaining 97.25% of hit rate.

Resumo—Este trabalho apresenta uma abordagem de inspeção visual para detectar ausência/presença de microcomponentes de superfície (SMC) em placas de circuito impresso (PCB). Propõe-se uma metodologia baseada na combinação de Visão de Máquina e Aprendizagem de Máquina para detectar componentes ausentes, com mais qualidade e precisão. Nesta abordagem considera-se a ocorrência intensa de ruídos obtidos pelo processo de captura de imagens diretamente da linha de produção das PCB's. Os resultados obtidos demonstram que a metodologia é robusta e apropriada para o sistema real de inspeção visual industrial, sendo obtidos 97.25% de taxa de acerto.

Keywords—Visão de Máquina; Aprendizado de Máquina; Inspeção Industrial; Controle de Qualidade;

I. INTRODUÇÃO

Atualmente as indústrias buscam cada vez mais a competitividade. No entanto, para alcançar esta competitividade as indústrias precisam garantir a qualidade de seus produtos, bem como o aumento da produtividade [1].

A principal maneira para se garantir a competitividade, assegurando a qualidade da produção, é implementar um processo de inspeção que realize um rigoroso controle de qualidade, minimizando a taxa de erros enquanto maximiza a produção. A automatização do processo de inspeção promoveria um aumento significativo nos níveis de qualidade da indústria, sendo impossível alcançar estes níveis sem a automatização. Isso ocorre pois os sistemas de inspeção não estão suscetíveis a cansaço, decaimento da acuidade visual, distrações, dentre outros fatores que podem impactar diretamente na qualidade das inspeções [2].

Os resultados proporcionados por sistemas automáticos de inspeção visual são almejados por qualquer empresa que deseje competir por um determinado mercado, tais como: *i*) Aumento da lucratividade; *ii*) Redução de desperdícios; e *iii*) Melhoria da qualidade dos produtos finais [3].

O uso do processo de inspeção visual convencional, considerando um operador humano treinado, apresenta efetividade entre 80% a 90% dos casos. Porém, após a primeira meia hora de trabalho, a acuidade visual do operador humano diminui significativamente, para a análise de um único tipo de defeito [1]. Na Figura 1, pode ser visualizado um exemplo de inspeção visual humana de placas de circuito impresso (PCB - Printed Circuit Board), onde o operador humano deve percorrer visualmente todos os componentes da placa em busca de diversos tipos de defeitos.



Figura 1. Inspeção visual convencional de placas mãe de computadores.

Melhorias no controle de qualidade têm sido alcançadas por meio da inspeção automática com uso das tecnologias de visão de máquina [3]. Tendo a automatização do processo de inspeção de placas de circuito impresso se mostrado uma maneira eficiente de controle de qualidade, uma vez que garante a inspeção de 100% do volume produzido, não tem interrupção, não diminui a velocidade da linha de produção, mantém o fluxo de produção consistente e o volume inspecionado aumenta consideravelmente [4].

Nesse contexto, este trabalho aborda o problema de detecção da ausência (ou da presença) de microcomponentes de superfícies em dispositivos que utilizam a tecnologia (SMT - Surface Mount Technology), como as placas mãe de com-

putadores pessoais, também chamadas de placas de circuito impresso (PCB - Printed Circuit Board).

O objetivo principal deste trabalho é o desenvolvimento de uma abordagem baseada em Visão Computacional para a identificação da ausência de microcomponentes, garantindo assim a velocidade, precisão e flexibilidade do controle de qualidade com competitividade dos produtos da empresa.

Este texto está organizado em seis seções. A seção seguinte descreve os sistemas de inspeção visual automáticos e suas aplicações no contexto deste trabalho. A Seção 3 oferece uma visão geral do estado da arte por meio dos principais trabalhos relacionados com a inspeção de componentes eletrônicos. A metodologia desenvolvida é mostrada na Seção 4. A seção 5 mostra os resultados experimentais e, por fim, na Seção 6 são apresentadas as conclusões deste trabalho.

II. INSPEÇÃO AUTOMÁTICA DE PLACAS DE CIRCUITO IMPRESSO

As placas de circuito impresso (PCBs) são compostas por diversos tipos de componentes agrupados densamente em posições específicas, sendo alguns destes componentes muito pequenos. Os componentes são do tipo SMT, ou seja, são fixados na superfície da placa por meio de soldas em um processo de inserção automática, o que frequentemente provoca falhas na fixação dos componentes, conforme Figura 2. Dessa forma, um processo automatizado de inspeção de PCBs surge como uma ferramenta efetiva para aprimorar o controle de qualidade das empresas [5]. A Figura 2 mostra um segmento de uma placa de circuito impresso apresentando componentes ausentes que são indicados pelas setas.




Figura 2. Segmento de placa de circuito impresso apresentando ausência de microcomponentes.

Os sistemas automatizados de inspeção baseados em Visão de Máquina são aplicados sobre os processos de manufatura, fazendo uso de câmeras e iluminação especiais para realizar a captura de imagens de PCBs em linhas de montagem, mesmo para esteiras em alta velocidade. As imagens são digitalizadas

em tempo real e encaminhadas para programas desenvolvidos especificamente para processar as imagens das PCBs, conforme Figura 3. Estes programas realizam medições com precisão e detectam falhas contidas nas PCBs monitoradas, favorecendo a implementação de ações corretivas, manuais ou automatizadas, para os produtos que apresentaram falhas [6].

A Figura 3 ilustra um exemplo típico de linha de produção industrial com inspeção automática por meio de Visão de Máquina, apresentando um controle de câmera conectado a um computador que realiza o processamento das imagens.




Figura 3. Linha de produção manufaturada com inspeção automatizada por meio de um sistema de visão de máquina [7].

Neste trabalho é proposta uma abordagem para a detecção da ausência/presença de microcomponentes (SMT) em placas de circuito impresso. Pois a ausência de componentes é uma das principais causas de falhas nas placas de circuito impresso ao saírem dos fornos de inserção das modernas linhas de produção [1].

A literatura científica é muito rica em exemplos de sistemas de inspeção visual para placas de circuito impresso [8], [9], [10], [11], [12]. A maior parte desses trabalhos tratam problemas relativos a identificação de trilhas de soldas ou a identificação de componentes mal posicionados. A seção seguinte destaca os trabalhos relacionados com a identificação da ausência de componentes e oferece uma visão geral do estado da arte.

III. TRABALHOS RELACIONADOS

O trabalho proposto por [10] apresenta um sistema para inspeção visual automática, visando detectar componentes ausentes em placas de circuito impresso. A ferramenta LabVIEW foi utilizada para o desenvolvimento do programa. O sistema proposto pelos autores considera o uso de uma imagem da placa de referência e uma imagem da placa de teste, sendo aplicadas técnicas para extração de ruídos e realce de bordas nas imagens. Em seguida é empregada a técnica de *template matching*, onde as regiões dos componentes (das placas de

referência e de teste) são extraídas e sobrepostas considerando a variação no brilho e na forma dos componentes. Por fim é computado o percentual de acerto, para cada componente, considerando o casamento do componente x presente na placa de referência com o componente correspondente y da placa de teste.

Os experimentos realizados fizeram uso da imagem de uma única placa de referência e quinze imagens de placas de teste. Cada placa contém 28 componentes a serem analisados, totalizando 420 componentes inspecionados em todo o processo experimental. Onde alguns componentes foram testados somente quinze vezes, o que é estatisticamente insuficiente para determinar a efetividade da abordagem. Além disso, os autores não apresentam qualquer percentual final de acertos em seus resultados.

Em [11] os autores propõem uma abordagem para inspeção visual automática de componentes ausentes e componentes desalinhados em placas de circuito impresso. A detecção de falhas proposta pelo autores baseia-se na subtração de *background*, onde é utilizada a técnica recursiva *Mixture of Gaussian - MOG* para modelar o fundo da placa de referência e posteriormente realizar a comparação entre as placas de teste. A técnica MOG é utilizada no processo de aprendizagem do fundo da placa, sendo utilizadas cem imagens com variações no fundo da placa durante a etapa de treinamento. Como medida de tomada de decisão foi aplicada a distância de Mahalanobis para determinar se um dado *pixel* pertence ao *background* ou ao *foreground*. Se muitos *pixels* pertencem ao fundo da placa, o componente é definido como ausente ou desalinhado.

Nos experimentos, os autores consideraram dois tipos de componentes, capacitores cilíndricos e circuitos integrados, obtendo uma taxa de acerto de 92.60% de acurácia para a detecção de capacitores ausentes e 94.40% de acurácia para a detecção de circuitos integrados ausentes. Os autores não mencionam a quantidade de componentes que foram inspecionados nos experimentos. Além de utilizarem componentes de dimensão muito maior do que os microcomponentes abordados no presente trabalho.

No trabalho de [12] também foi proposta uma abordagem para a inspeção visual automática de placas de circuito impresso visando a detecção de componentes ausentes. A metodologia realiza a leitura da placa de referência, recorta as regiões contendo os componentes a serem inspecionados, redimensiona as regiões dos componentes, converte as regiões para tons de cinza, extrai os histogramas de cada região e normaliza os histogramas. Cada componente é representado por seu respectivo histograma, e esse conjunto de histogramas é fornecido como entrada para a etapa de treinamento da Rede Neural por meio do algoritmo *back propagation*.

Os experimentos realizados pelos autores consideram a análise de microcomponentes, embora não tenha sido mencionado no artigo qual tipo de componente. O total de componentes inspecionados no processo de experimentação foi 30 componentes, sendo essa quantidade estatisticamente insuficiente para determinar a efetividade da abordagem. A

acurácia total obtida pelo método foi de 93.33% de acerto.

IV. METODOLOGIA

A Metodologia adotada neste trabalho é dividida em quatro etapas principais, que podem ser contempladas na Figura 4. As etapas são:

- A. Aquisição das Imagens;
- B. Pré-Processamento das Imagens;
- C. Extração de Características;
- D. Classificação da Presença/Ausência de Microcomponentes.

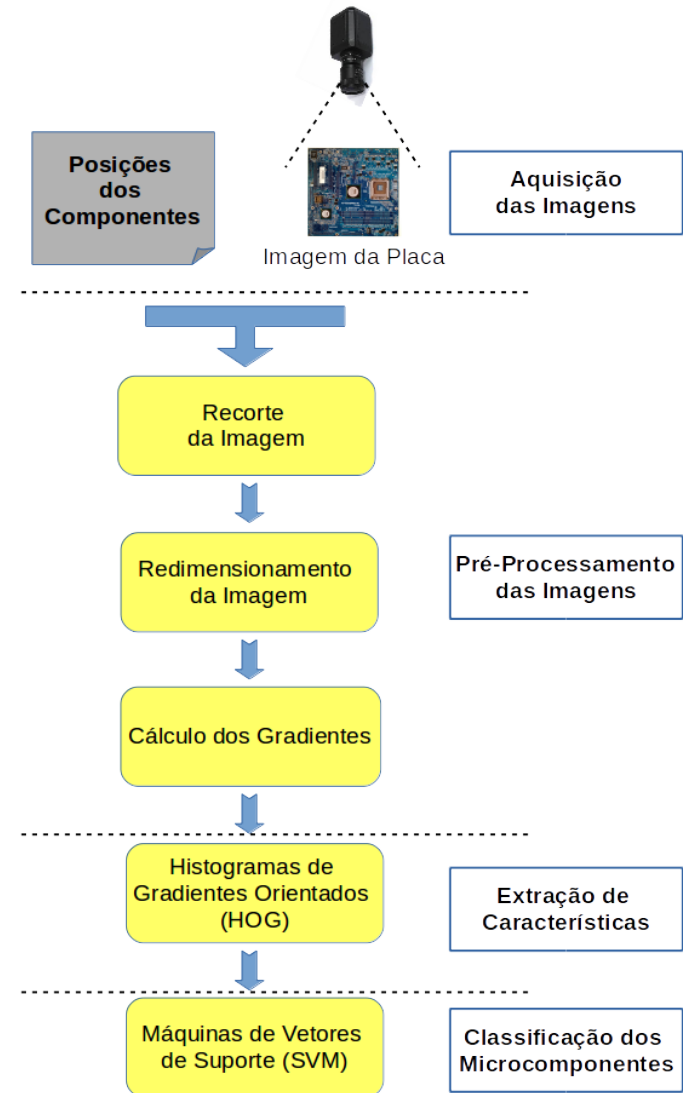


Figura 4. Modelagem da Metodologia Proposta.

A Figura 4 apresenta uma visão geral sobre o processo de detecção automática de microcomponentes ausentes em PCBs. A presente abordagem considera que as posições dos componentes são conhecidas, podendo ser obtidas ou por definição manual (para uma única placa) ou durante o projeto de criação da placa.

Inicialmente, um conjunto de imagens de PCBs de referência é capturado, de onde são extraídas regiões contendo os componentes a serem analisados. Para cada região, a mesma será redimensionada e será computado o gradiente de primeira ordem. Posteriormente, será extraído um vetor de características para cada região, considerando o descritor HOG (*Histogram of Oriented Gradients*). Após a computação dos vetores de características dos componentes das PCBs de referência, estes vetores serão passados como entrada para o processo de treinamento supervisionado, por meio do classificador SVM (*Support Vector Machine*).

Após a etapa de treinamento serão capturadas imagens das PCBs de teste, e para cada imagem, são extraídas as regiões contendo os componentes a serem analisados, sendo as regiões redimensionadas e computados os gradientes. Em seguida, serão computados os vetores de características de cada componente da placa de teste, por meio do descritor HOG, e cada vetor de características será submetido ao classificador SVM, que irá determinar a qual classe o componente pertence, ausente ou presente.

A. Aquisição das Imagens

Esse processo consiste na captura de um conjunto de imagens coloridas de PCBs, em formato RGB. Para isso deve ser utilizado um *setup* experimental composto por uma estrutura que irá conter a PCB monitorada. Esta estrutura dispõe de um sistema de iluminação e uma câmera digital conectada a um computador, como pode ser observado na Figura 5. De modo que, cada imagem capturada pela câmera seja encaminhada para o computador e seja posteriormente processada [4].




Figura 5. *Setup* Experimental utilizado no processo de aquisição de imagens.

A Figura 5 apresenta o *setup* experimental criado para realizar o procedimento controlado de aquisição de imagens. A estrutura do *setup* dispõe de uma base que pode ser removida para a fixação da placa. Adicionalmente, o *setup* dispõe de um sistema de iluminação com duas luminárias de LED, visando controlar a variação de luminosidade no momento da captura. E também dispõe de uma câmera fixada na parte superior da estrutura com total campo de visão da PCB, estando a câmera conectada a um computador.

B. Pré-Processamento das Imagens

A etapa de Pré-processamento consiste em preparar as imagens dos componentes para a aplicação da técnica de extração de características. Para isso, a imagem do componente é redimensionada para a resolução 128×64 pixels, no intuito de satisfazer as restrições de sobreposição de grades de células consideradas no descritor HOG, conforme [13].

Em seguida, são calculados os gradientes de primeira ordem da imagem. O cálculo dos gradientes identifica mudanças significativas nos níveis de cinza da imagem, enfatizando contornos, silhuetas e um pouco de textura da imagem. Este cálculo considera bordas horizontais e verticais, e para isso são necessárias duas máscaras. As máscaras utilizadas foram, gradiente horizontal $[-1 \ 0 \ 1]$ e gradiente vertical $[1 \ 2 \ 1]^T$, que correspondem ao operador de Sobel [14].

C. Extração de Características

Nessa etapa serão extraídas as principais características presentes na imagem do componente, sendo criado um vetor de características para cada componente, ou seja, será criada uma representação para cada imagem de cada componente. Para a etapa de extração de características deste trabalho foi utilizado o descritor HOG, que calcula histogramas de gradientes em uma grade densa com sobreposição de blocos [15].

O descritor HOG foi escolhido para esta etapa pois consegue descrever a variação de luminosidade, o arranjo estrutural das superfícies e a relação entre as regiões vizinhas de maneira rápida e eficiente. Considerando que descritores locais demandam muito esforço computacional e descritores baseados em cor e forma agregam informações menos discriminativas do que descritores baseados em textura.

Os passos utilizados para a computação do descritor HOG foram:

- Dividir a imagem em pequenas regiões de dimensão 8×8 pixels, denominadas células. Cada célula contém 64 pixels, que serão considerados na construção do histograma da orientação dos gradientes [13];
- Para cada célula será computado um histograma com 9 bins, igualmente divididos entre 0 e 180 graus. Cada pixel da célula tem sua contribuição, para o cálculo do histograma, ponderada pela sua magnitude do gradiente. Para evitar o efeito *aliasing* o peso de cada pixel é interpolado de modo a contribuir com os 8 bins do histograma [13];
- Normalização local dos histogramas, por meio da criação de blocos que são compostos por um conjunto de 2×2 células, ou seja, 16×16 pixels. Há uma sobreposição de 8 pixels entre os blocos, permitindo que cada célula esteja presente em 4 blocos diferentes, exceto para as células dos cantos e das bordas, que estão presentes em um bloco e dois blocos, respectivamente. Com isso, cada célula é normalizada com relação a diferentes blocos, aparecendo mais vezes no vetor de características final [13];
- Concatenação de todos os blocos presentes na imagem do componente, após a normalização, em um único vetor resultante. Para a imagem do componente com 128×64 pixels, existem 15×7 blocos. Cada bloco possui 2×2 células e cada

célula contém um histograma de 9 *bins*, sendo a dimensão da imagem definida para que haja a sobreposição entre os blocos, conforme [13], [15]. Com isso, a dimensão do vetor de características final é $15 \times 7 \times 2 \times 2 \times 9 = 3780$ [13].

D. Classificação da Presença/Ausência de Microcomponentes

A tarefa de classificação pode ser compreendida como o processo de atribuir, a uma determinada informação, o rótulo da classe a qual ela pertence. Uma classificação pode ser supervisionada ou não-supervisionada [16].

Em uma classificação supervisionada existe a presença de um professor externo, o qual fornece um conjunto de exemplos (também chamado de modelo), para que a máquina possa aprender sobre o domínio do problema e posteriormente realizar previsões com base no conhecimento aprendido na fase de treinamento. Já em uma classificação não-supervisionada não existe a presença de um professor externo, ou seja, não existe um conjunto de exemplos previamente definido para que a máquina possa aprender sobre o domínio do problema, sendo necessário então uma medida de qualidade como forma de prever as classes de cada informação [16].

Neste trabalho foi utilizado o classificador supervisionado SVM, sendo a sua atuação dividida em duas fases: treinamento e classificação. Durante a fase de treinamento foi fornecido um conjunto de D exemplos de treino $\{x_i, y_i\}$, onde $x_i \in R$ corresponde ao vetor de características do i -ésimo componente e $y_i \in \{-1, 1\}$ corresponde a qual classe pertence o i -ésimo componente, ausente ou presente. D é linearmente separável se existe um hiperplano que separa os objetos das classes -1 e 1 [16].

Para selecionar o conjunto de treinamento e teste foi utilizada a técnica Validação Cruzada, onde o conjunto de dados é dividido em k subconjuntos de tamanhos iguais. Posteriormente, cada subconjunto é usado para teste e os demais para treinamento. Sendo a etapa anterior repetida k vezes. Para aproveitar ao máximo os dados da base, foi utilizado o método *leave one out*, onde k é igual a quantidade de componentes da base [16].

Dessa forma, neste trabalho, o conjunto de vetores de características é passado como entrada para o processo de treinamento do SVM, que irá encontrar um hiperplano que separe os conjuntos de componentes ausentes e presentes de modo que, ao fornecer um componente que não passou pela etapa de treinamento o classificador irá determinar a qual classe o componentes pertence [16]. Para isso foi considerado um *kernel* linear e a constante $C = 1$, onde a constante C controla a relação entre os erros ocorridos na fase de treinamento e a margem de separação entre os dois grupos.

V. EXPERIMENTOS

Para a realização da captura de imagens foi utilizada a câmera digital de um *smartphone* Motorola Moto X, segunda geração, com 13 megapixels. Os experimentos foram executados em um *notebook* Sony Vaio, com processador Intel I5, com 4 Gigabytes de memória RAM. A metodologia apresentada

neste trabalho foi desenvolvida na plataforma Matlab, fazendo uso da *toolbox* de processamento de imagens.

Foram conduzidos alguns experimentos para avaliar a efetividade da abordagem proposta para a detecção automática de microcomponentes SMT ausentes em placas de circuito impresso. Para isso, foi proposta uma base de imagens de microcomponentes presentes e ausentes, que pode ser dividida em três partes: Parte *i*), imagens sem a presença de ruídos artificiais; Parte *ii*), imagens com a presença de ruído Gaussiano, considerando as seguintes variações de densidade de ruído 0.02, 0.04, 0.06, 0.08 e 0.1; e Parte *iii*), imagens com a presença de ruído Sal e Pimenta, considerando as seguintes variações de densidade de ruído 0.02, 0.04, 0.06, 0.08 e 0.1.

A Parte *i*), contém 500 imagens de microcomponentes SMT do tipo resistor (R), 500 imagens de microcomponentes SMT do tipo capacitor (C) e 500 imagens de microcomponentes SMT ausentes, totalizando 1500 imagens de dimensão 40×15 *pixels*, conforme Figura 6. As Partes *ii*) e *iii*), contém cinco variações de densidade de ruído, cada uma. Onde cada variação de ruído é composta por 1500 imagens de microcomponentes presentes e ausentes, conforme a disposição da Parte *i*).

A base de imagens de componentes proposta totaliza 16500 imagens e está disponível no link: sites.google.com/site/detcompsibgrapi16.




Figura 6. Exemplo de microcomponentes que compõem a base de imagens proposta. Na coluna (a) são apresentados microcomponentes do tipo resistor. A coluna (b) expõe microcomponentes do tipo capacitor. Por fim, a coluna (c) mostra a ausência de microcomponentes.

A Figura 6 apresenta alguns exemplos de componentes que compõem a base de testes. Na primeira coluna, são apresentados exemplos de microcomponentes SMT do tipo

resistor, na coluna central são apresentados exemplos de microcomponentes SMT do tipo capacitor e na última coluna são apresentados exemplos de microcomponentes SMT ausentes.

O primeiro experimento consiste em avaliar a acurácia da metodologia considerando as imagens dos componentes em condições naturais de captura, ou seja, sem a presença de ruídos artificiais e com iluminação controlada. Em seguida, a robustez da metodologia será avaliada frente à presença de ruídos artificiais em imagens reais. Para isso, foram adicionados ruídos Gaussianos e Sal e Pimenta para simular ambientes reais em condições críticas de aquisição de imagens. Os ruídos artificiais supracitados foram selecionados pois apresentam distribuição linear e não-linear, respectivamente. O propósito do segundo experimento consiste em representar ambientes em processo de captura de imagens sem a presença de iluminação controlada, onde é possível analisar a acurácia da abordagem para estes ambientes.

Para a avaliação da abordagem, com a adição de ruído Gaussiano e ruído Sal e Pimenta, foram consideradas as variações de densidade de ruído: 0.02, 0.04, 0.06, 0.08 e 0.1.

É válido destacar que a abordagem proposta consegue detectar a presença/ausência de microcomponentes, especificados neste trabalho, em placas de circuito de tipos variados sem a necessidade de novo treinamento, desde que a cor da placa seja a mesma. Caso a nova placa apresente outra cor é necessário realizar novamente o processo de treinamento, para que a qualidade da classificação seja preservada.

VI. RESULTADOS E DISCUSSÃO

Após a execução dos experimentos e análise dos dados resultantes, observou-se que, para o primeiro experimento, a abordagem proposta neste trabalho obteve um percentual total de 97.25% de acertos, um percentual de acertos de 96.80% para componentes ausentes e um percentual de acertos de 97.70% para componentes presentes, considerando a base de imagens sem a presença de ruído artificial. Os demais experimentos consideram a inserção de ruído artificial. Inicialmente foi avaliado o desempenho da metodologia frente a inserção de ruído Gaussiano, variando a densidade de ruído de 0.02 até 0.10, como pode ser visto na Figura 7.

Observando a Figura 7 é possível constatar que a inserção de ruído Gaussiano impacta a capacidade de detecção das ausências de microcomponentes, porém, mesmo com o ruído inserido a taxa de acerto ainda continua superior aos resultados obtidos pelos trabalhos relacionados.

Em seguida foi avaliado o desempenho da metodologia frente a inserção de ruído Sal e Pimenta, variando a densidade de ruído de 0.02 até 0.10, como pode ser visto na Figura 8.

Observando a Figura 8 é possível constatar que a inserção de ruído Sal e Pimenta impactou com maior intensidade a capacidade de detecção das ausências de microcomponentes, pois distribuição de ruído segue um modelo não linear.

As Figuras 9, 10 e 11 apresentam uma região de uma placa de circuito impresso, sem a presença de ruído artificial, com a presença de ruído Gaussiano com densidade de ruído de 0.1 e com a presença de ruído Sal e Pimenta com densidade de




Figura 7. Gráfico evidenciando a relação entre Taxa de Acerto e Densidade de Ruído Gaussiano.




Figura 8. Gráfico evidenciando a relação entre Taxa de Acerto e Densidade de Ruído Sal e Pimenta.

ruído de 0.06, respectivamente. Nos experimentos, a abordagem proposta conseguiu apresentar resultados superiores aos trabalhos relacionados em todas as variações de densidade de ruído Gaussiano, sendo a última variação de ruído Gaussiano apresentada na Figura 10. Na experimentação com ruído Sal e Pimenta, a abordagem proposta passou a apresentar resultados inferiores aos trabalhos relacionados a partir da densidade de ruído 0.06, que pode ser visualizada na Figura 11.

Após a apresentação da metodologia proposta e dos resultados obtidos, é possível identificar as principais diferenças entre o presente trabalho e as abordagens encontradas na Literatura.

Em [10], a detecção de componentes ausentes é baseada na técnica *Template Matching*, onde cada componente da placa de referência é comparado com o componente correspondente na placa de teste, considerando a informação de forma e brilho.




Figura 9. Região de uma placa de circuito impresso sem a presença de ruído artificial.




Figura 11. Região de uma placa de circuito impresso com densidade de ruído Sal e Pimenta de 0.06.




Figura 10. Região de uma placa de circuito impresso com densidade de ruído Gaussiano de 0.1.

No trabalho proposto por [11], é utilizada a subtração de regiões como forma de evidenciar as compatibilidades entre o componente de referência e o componente de teste. Para mensurar o grau de similaridade entre os componentes, e com isso detectar a presença/ausência de componentes, é usada em [11] a distância de Mahalanobis. O processo de comparação adotado nos trabalhos supracitados realiza a comparação entre componentes correspondentes, tornando-se vulnerável pois a variação de posicionamento no processo de inserção pode ocasionar uma baixa na taxa de compatibilidade entre os com-

ponentes. Como exemplo, considere um componente presente (válido) mal posicionado na placa de referência, este pode ocasionar incompatibilidades com os componentes presentes nas placas de teste, já que só há um componente de referência para esta posição. Na abordagem proposta nesse trabalho são utilizados vários componentes com variação de posicionamento na etapa de treinamento, favorecendo a compreensão do modelo de componente presente, já que a comparação não baseia-se somente na análise de uma única amostra.

Em [12], foi proposta uma abordagem onde é extraído um histograma de cor de cada região da imagem contendo um componente. Em seguida, o conjunto de histogramas é fornecido para o treinamento de uma Rede Neural e com isso é possível realizar a classificação dos componentes como presente ou ausente. A abordagem proposta no presente trabalho é semelhante à de [12], pois extrai um vetor de características baseado no descritor HOG, para cada componente. Em seguida o conjunto de descritores é fornecido como entrada para o processo de treinamento do classificador SVM. A principal diferença entre as duas abordagens consiste na capacidade de descrição da informação a ser considerada no trabalho. Em [12] é considerado somente a informação de intensidade, podendo não agregar tanta informação quanto uma descrição que utiliza textura. A descrição baseada em textura contem informações sobre a distribuição espacial e a variação de luminosidade, além de descrever o arranjo estrutural das superfícies e as relações entre as regiões vizinhas.

Considerando os experimentos realizados, o trabalho proposto por [10], analisou 420 componentes, sendo alguns componentes testados apenas 15 vezes, o que não fornece consistência estatística suficiente à abordagem, além disso, o trabalho não apresentou qualquer percentual de acertos. Em

[11], foram analisados dois tipos de componentes, capacitores cilíndricos e circuitos integrados. Os percentuais de acerto foram, 92.60% para capacitores cilíndricos e 94.40% para circuitos integrados, que apresentam dimensão muito maior do que os microcomponentes considerados na presente pesquisa. Na pesquisa proposta por [12], foram analisados 30 componentes, sem mencionar o tipo, obtendo a acurácia total de 93.33% de acerto. Porém a análise de apenas 30 componentes não permite consolidar estatisticamente os resultados. Enquanto que no presente trabalho foram considerados 1500 componentes, divididos em 500 componentes do tipo resistor, 500 componentes do tipo capacitor e 500 componentes ausentes. Com acurácia total de 97.25% de acerto, acurácia de 96.80% de acerto para componentes ausentes e acurácia de 97.70% de acerto para componentes presentes. Além disso, o presente trabalho também analisou a robustez da abordagem frente à presença de ruído artificial, evidenciando a qualidade da proposta.

VII. CONCLUSÕES

Este trabalho apresentou uma abordagem baseada em Visão Computacional para a detecção da ausência ou presença de microcomponentes SMT em placas de circuito impresso. A metodologia fez uso do descritor HOG, para a criação de vetores de características no intuito de representar cada componente a ser avaliado. Adicionalmente, a metodologia também aplicou o classificador supervisionado SVM para determinar se os componentes estão presentes ou ausentes na PCB.

Devem ser destacados como contribuição deste trabalho: *i)* a proposição e disponibilização de uma base de imagens de microcomponentes para avaliação da ausência de microcomponentes; *ii)* o uso do descritor HOG, que favoreceu a operação de classificação dos componentes pois o descritor reduz a variância a iluminação e sombreamento; *iii)* a utilização da fase de treinamento, por meio da técnica SVM, que agregou confiabilidade à abordagem proposta. Pois, com o referido classificador, é possível utilizar componentes de referência de diversas placas distintas e não apenas de uma única placa de referência.

Para a avaliação da robustez e viabilidade desse método foram realizados vários testes com a adição de ruídos Gaussianos e Sal e Pimenta, buscando verificar a efetividade da abordagem frente a uma grande concentração de ruído nas imagens. Os resultados obtidos garantem a viabilidade da utilização desta abordagem no processo de manufatura de placas de circuito impresso. Os experimentos foram realizados em placas reais obtidas diretamente da linha de produção.

A concretização do trabalho amplia consideravelmente as possibilidades de aplicação da visão de máquina, por meio do descritor HOG, e da aprendizagem de máquina, por meio do SVM, para diversos outros tipos de inspeção industrial. Como trabalhos futuros pretende-se adequar a metodologia em ambientes de inspeção visual real e expandir a quantidade de problemas a serem inspecionados pela abordagem automática.

AGRADECIMENTOS

Os autores agradecem à Fundação de Amparo à Pesquisa do Estado do Amazonas (FAPEAM) pelo suporte financeiro.

REFERÊNCIAS

- [1] E. M. Taha, E. Emary, and K. Moustafa, "Automatic optical inspection for pcb manufacturing: a survey," *International Journal of Scientific and Engineering Research*, vol. 5, no. 7, pp. 1095–1102, 2014.
- [2] J. E. See, "Visual inspection: A review of the literature (report sand2012-8590)," *Albuquerque, NM: Sandia National Laboratories*, 2012.
- [3] P. S. Malge and R. S. Nadaf, "A survey : Automated visual pcb inspection algorithm," *International Journal of Engineering Research Technology (IJERT)*, vol. 3, no. 1, 2014.
- [4] M. Borthakur, A. Latne, and P. Kulkarni, "A comparative study of automated pcb defect detection algorithms and to propose an optimal approach to improve the technique," *International Journal of Computer Applications*, vol. 114, no. 6, pp. 27–33, March 2015.
- [5] S. A. Rizvi, K. B. Neelima, and T. Saravanan, "Image processing based defect detection of printed circuit board," *International Journal for Research in Applied Science Engineering Technology (IJRASET)*, vol. 3, no. 4, April 2015.
- [6] A. Singh, M. G. Vayada, and V. H. Nayak, "Automatic detection of pcb defects," *International Journal for Innovative Research in Science Technology (IJIRST)*, vol. 1, no. 6, November 2014.
- [7] J. L. S. Pio and M. F. Campos, "Visão de máquina." *nais da IV Feira Internacional da Zona Franca de Manaus*, 2004.
- [8] P. P. Londe and S. A. Chavan, "Automatic pcb defects detection and classification using matlab," *International Journal of Current Engineering and Technology*, vol. 4, no. 3, June 2014.
- [9] M. Mogharrebi, S. Sahran, M. C. Ang, and A. S. Prabuwono, "Vision based inspection system for missing footprint detection on printed circuit boards," *Journal of Theoretical and Applied Information Technology*, vol. 84, no. 1, June 2016.
- [10] M. H. R. and A. D. B., "Fault detection of assembled pcb through image processing using labview," *International Journal of Engineering Research Technology (IJERT)*, vol. 5, no. 5, May 2016.
- [11] K. Sundaraj, "Pcb inspection for missing or misaligned components using background subtraction," *WSEAS Trans. Info. Sci. and App.*, vol. 6, no. 5, pp. 778–787, May 2009. [Online]. Available: <http://dl.acm.org/citation.cfm?id=1558801.1558809>
- [12] H. Soebhakti and F. I. Hariadi, "Automatic optical inspection to detect missing components in surface mount assemblies," *IEEE International Conference on Electronics Technology and Industrial Development*, October 2013.
- [13] N. Dalal and B. Triggs, "Histograms of oriented gradients for human detection," in *2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)*, vol. 1, June 2005, pp. 886–893 vol. 1.
- [14] R. C. Gonzalez and R. E. Woods, *Digital Image Processing (3rd Edition)*. Upper Saddle River, NJ, USA: Prentice-Hall, Inc., 2006.
- [15] D. L. Cosmo, "Detecção de Pedestres Utilizando Descritores de Orientação do Gradiente e Auto Similaridade de Cor," Master's thesis, Universidade Federal do Espírito Santo, Espírito Santo, 2014.
- [16] K. Faceli, *Inteligência Artificial: Uma abordagem de aprendizado de máquina*. Grupo Gen-LTC, 2011.