

SISTEMA DE INSPEÇÃO VISUAL AUTOMÁTICA APLICADO À DETECÇÃO DE DEFEITOS EM AÇOS LAMINADOS¹

Luiz Alberto de Oliveira Martins²

Flávio Luis Cardeal Pádua³

Paulo Eduardo Maciel de Almeida³

Marco Aurélio Bueno Carone⁴

Resumo

Este trabalho descreve o desenvolvimento de um sistema de inspeção visual automática para detecção de defeitos em aços laminados usando técnicas de Visão Computacional e Redes Neurais Artificiais. Diferentemente de muitas técnicas comuns que são frequentemente baseadas em estimativas manuais e que lidam com tempo significativo e restrições financeiras, é apresentado um sistema automático baseado em técnicas de análise de imagens para classificação dos defeitos com formas geométricas bem definidas e a combinação de uma técnica de extração de características com um modelo de Rede Neural Artificial para classificação dos defeitos com formas geométricas de maior complexidade. Para isto, foram consideradas imagens reais extraídas de filmagens realizadas em uma linha de laminação de aços da siderúrgica ArcelorMittal para detecção de seis tipos de defeitos: solda laminada, grampo, furo de identificação, esfoliação, oxidação e marca de ondulação ou repuxado. O sistema desenvolvido foi validado com sucesso, atingindo uma taxa média de acerto de 87% na classificação dos defeitos.

Palavras-chave: Visão computacional; Redes neurais; Inspeção; Aço laminado.

AUTOMATED VISUAL INSPECTION SYSTEM APPLIED TO ROLLED STEEL DEFECTS DETECTION

Abstract

This work addresses the development of an automated visual inspection system for rolled steel defects detection, by using Computer Vision techniques and Artificial Neural Networks. Unlike most common techniques, which are frequently based on manual estimations that lead to significant time and financial constraints, it presents an automatic system based on image analysis techniques for classification of defects with well-defined geometric shapes and the combination of a feature extraction technique with an Artificial Neural Network model for classification of defects with geometric shapes more complex. So, images extracted from real-world video streams realized in a rolled mill line of ArcelorMittal industry were considered for detecting six types of defects: rolled welding, clamp, identification hole, exfoliation, oxidation and wave-form mark. The system was successfully validated, achieving overall classification accuracy of 87%.

Key words: Computer vision; Neural networks; Inspection; Rolled steel.

¹ *Contribuição técnica ao 14º Seminário de Automação de Processos, 6 a 8 de outubro de 2010, Belo Horizonte, MG.*

² *Mestre, Engenheiro de Automação. ArcelorMittal Inox Brasil.*

³ *Doutor, Professor. Centro Federal de Educação Tecnológica de Minas Gerais (CEFET/MG).*

⁴ *Estudante de Engenharia. Centro Federal de Educ. Tecnológica de Minas Gerais (CEFET/MG).*

1 INTRODUÇÃO

A garantia da qualidade do produto final, em grande parte das indústrias siderúrgicas, tem sido feita por inspeção visual. A inspeção realizada por pessoas está sujeita a várias falhas, dentre elas: 1) As pessoas alternam-se na atividade, não havendo um padrão de julgamento durante a atividade de inspeção; 2) As pessoas estão sujeitas ao cansaço e desatenção, o que pode permitir a falha na detecção de algum defeito; e 3) O local de inspeção nem sempre é propício para realização desta atividade por pessoas.

Embora as pessoas que trabalham nesta atividade tenham maiores habilidades para encontrar e classificar desvios de qualidade de superfície em um material, o aumento de velocidade das linhas de produção tem tornado esta tarefa difícil ou impossível. Portanto, novas ferramentas como, por exemplo, sistemas de inspeção AVI (*Automated Visual Inspection*) baseados em visão de máquina, têm sido desenvolvidos para detectar e classificar defeitos em superfícies de materiais como plástico, metal, madeira e têxtil.

Comercialmente, há muitos sistemas de inspeção visual desenvolvidos para detectar e classificar defeitos em superfícies. Entretanto, este problema continua sendo um assunto de pesquisa bastante explorado devido às peculiaridades de cada produto e de cada processo envolvido.

Especificamente, este trabalho aborda o problema de detecção e classificação de defeitos em aços laminados por meio do uso de técnicas de Visão Computacional e Redes Neurais Artificiais. Assim sendo, o problema pode ser definido como se segue:

Dada uma sequência de imagens de uma lâmina de aço em uma linha de produção siderúrgica, obtidas por uma câmera estacionária calibrada em condições estáveis de luminosidade, deseja-se identificar automaticamente os seguintes defeitos comumente encontrados no processo produtivo: esfoliação, marca de ondulação ou repuxado, oxidação, solda laminada, grampo e furo de identificação, conforme mostra a Figura 1.

A literatura aborda diversos tipos de técnicas para solução de problemas de inspeção. De uma maneira geral, os trabalhos abordados realizam os passos típicos de um sistema de reconhecimento de padrões: pré-processamento, extração de características e classificação.⁽¹⁾ Dentre as técnicas relacionadas destaca-se o uso de Análise de Componentes Principais – PCA^(2,3) para extração de características e de Mapas Auto-Organizáveis – SOM⁽⁴⁻⁷⁾ para classificação.

2 MATERIAL E MÉTODOS

2.1 Análise de Componentes Principais (PCA)

Basicamente, o princípio fundamental desta ferramenta consiste em encontrar um novo sistema de coordenadas para representar o conjunto de dados original de forma que eles apresentem a máxima variabilidade sobre os novos eixos.

Eixos relacionados a pequenos valores de variância são desconsiderados por não possuírem muita informação referente aos dados tratados. Desta forma, o conjunto de dados original pode ser representado em um espaço com dimensão menor do que a anteriormente utilizada, eliminando-se assim informações redundantes.

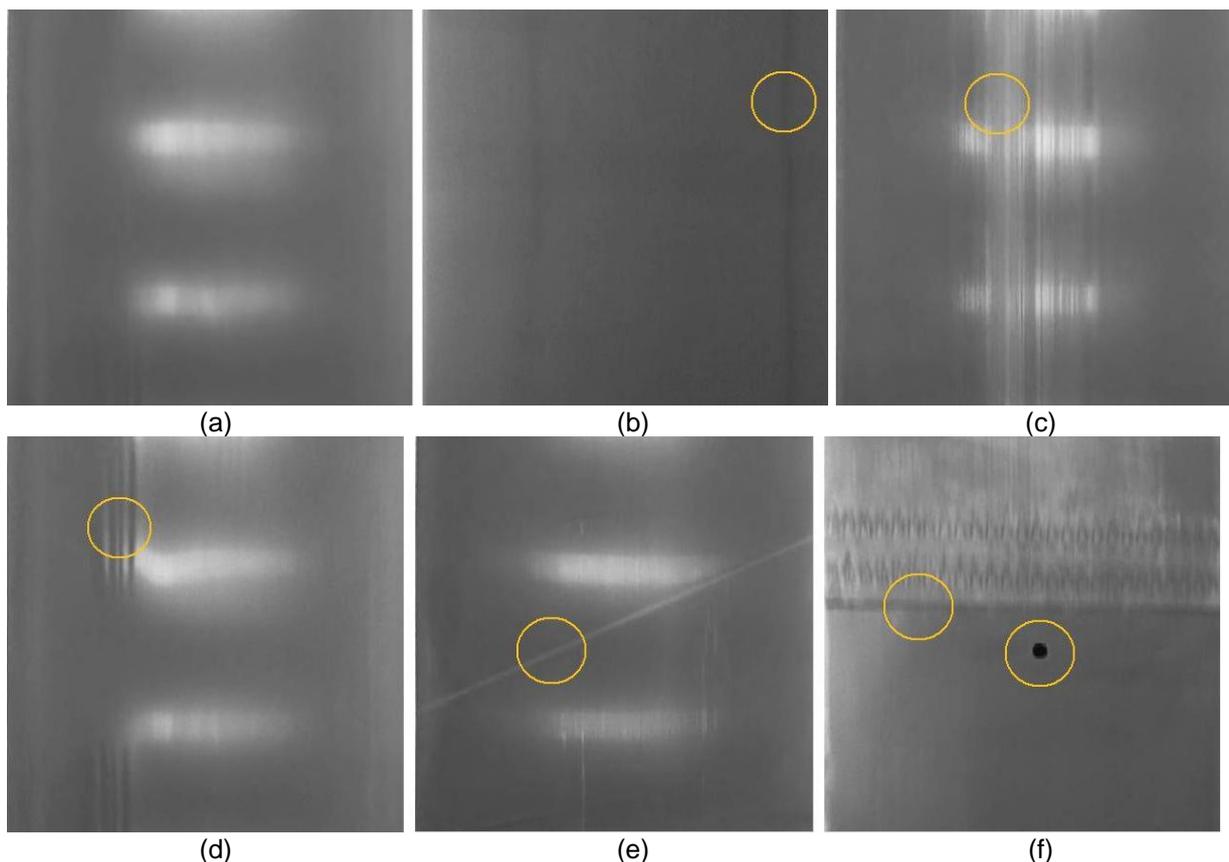


Figura 1. (a) Aço laminado sem defeito e com os defeitos marcados com o círculo amarelo: (b) oxidação, (c) esfoliação, (d) marca de ondulação ou repuxado, (e) solda laminada e (f) grampo com furo de identificação.

Considere p imagens de padrões, representadas por vetores coluna x_i , $i = 1 \dots p$, da seguinte forma:

$$x_i = [x_1^i, x_2^i, \dots, x_m^i]^T, \quad (1)$$

onde m corresponde ao número total de pixels da imagem.

Assuma também que estes padrões possuam média zero, ou seja, $E[x_i] = 0$, $\forall i$.

Este conjunto de padrões pode ser agrupado numa única matriz X dada por:

$$X = [x_1 \ x_2 \ \dots \ x_p]. \quad (2)$$

Considere também um novo sistema de coordenadas representado pelos vetores v_1 , v_2 , ..., v_p , ou matricialmente:

$$V = [v_1 \ v_2 \ \dots \ v_p]. \quad (3)$$

Estabelecendo-se que este novo sistema deva ser ortonormal, tem-se que a representação de X neste novo sistema de coordenadas pode ser dada por \hat{X} , da seguinte maneira:

$$\hat{X} = V^T X. \quad (4)$$

Como os vetores que formam X têm média zero, a matriz de covariância de \hat{X} é dada por:

$$\sigma^2 = V^T E[XX^T] V. \quad (5)$$

Fazendo-se $R = E[XX^T] \cong \frac{1}{p} XX^T$, a matriz co-variância pode ser reescrita como:

$$\sigma^2 = V^T R V. \quad (6)$$

Para se determinar qual matriz V de maior covariância a ser utilizada, pode-se aplicar a decomposição em valores singulares em R , ou seja:

$$R = USV^T. \quad (7)$$

Como R é simétrica, tem-se que $U=V$, ou seja, $R = VSV^T$. Portanto, tem-se que:

$$S = V^T RV, \quad (8)$$

onde a matriz S irá apresentar em sua diagonal principal os valores singulares de $V^T RV$ e zero nas outras posições.

Comparando as Equações (6) e (8) fica evidente que a matriz S , ou seja, a matriz contendo os valores singulares de R , é a matriz procurada.

Uma vez que R representa a matriz de correlação entre todas as coordenadas dos vetores x_i , a transformação aplicada em R pela Equação (8) é tal que a diagonaliza, passando a representá-la em um novo sistema ortogonal. Isto é muito interessante, pois permite afirmar que, neste novo sistema de coordenadas dado pela base V , cada coordenada j de um vetor x_i apresentará variância máxima com relação ao eixo v_j e zero em relação aos demais. É exatamente esta informação que a técnica necessita para realizar a redução de dimensão. Por exemplo, poder-se-ia usar apenas os k primeiros vetores de V para representar a nova base:

$$V_k = [v_1 \ v_2 \ \dots \ v_k] \quad (k < m) \quad (9)$$

Neste caso, a representação de X em um sistema de menor dimensão seria então:

$$\hat{X}_k = V_k^T X. \quad (10)$$

2.2 Mapas Auto-Organizáveis (SOM)

O principal objetivo do mapa auto-organizável (SOM) é transformar um padrão de sinal incidente de dimensão arbitrária em um mapa discreto uni ou bidimensional e realizar esta transformação adaptativamente de uma maneira topologicamente ordenada⁽⁸⁾.

Na rede SOM, os neurônios se organizam em uma grade ou reticulado, geralmente bidimensional, podendo algumas vezes ser unidimensional. A grade bidimensional tem a forma de uma superfície plana, onde os neurônios de saída estão organizados em linhas e colunas.⁽⁹⁾ Os neurônios são conectados aos neurônios adjacentes por uma relação de vizinhança, ditando a topologia, ou estrutura, do mapa.⁽¹⁰⁾ A topologia, apresentada por uma rede SOM, pode apresentar os formatos de vizinhança retangular e hexagonal. A definição do formato mais adequado depende do problema abordado e da distribuição de seus dados.

A rede SOM é treinada iterativamente. Em cada passo de treinamento, um vetor de amostras x do conjunto de dados de entrada é escolhido randomicamente e as distâncias entre ele e todos os vetores de pesos da rede SOM são calculadas usando alguma medida de distância. O neurônio, cujo vetor de peso m_c está próximo ao vetor de entrada x , é chamado de unidade de melhor correspondência BMU (*Best-Matching Unit*) e definido pela equação:

$$\|x - m_c\| = \min_i \{\|x - m_i\|\}, \quad (11)$$

onde o módulo da distância é tipicamente uma medida euclidiana.

O cálculo desta distância, pelo algoritmo utilizado, não considera valores desconhecidos e aplica uma máscara a valores de pesos associados às variáveis. Com isso, a medida de distância torna:

$$\|x - m_c\|^2 = \sum_{k \in K} w_k (x_k - m_k)^2, \quad (12)$$

onde K é o conjunto de variáveis desconhecidas (não faltantes) do vetor de amostra x ; x_k e m_k são os k -ésimos componentes dos vetores de amostras e peso; e w_k é o k -ésimo valor da máscara.

Após encontrar o BMU, os vetores de peso da rede SOM são atualizados de forma que o BMU é movido para próximo do vetor no espaço de entrada. Os vizinhos topológicos do BMU são tratados similarmente. Este procedimento de adaptação estende o BMU e seus vizinhos topológicos em direção ao vetor de amostras conforme mostra a Figura 2. Este algoritmo, baseado no conceito de vizinhança do BMU é comumente chamado de *Winner-Takes-All*, pois o neurônio BMU é o que recebe proporcionalmente a maior atualização de pesos da rede.

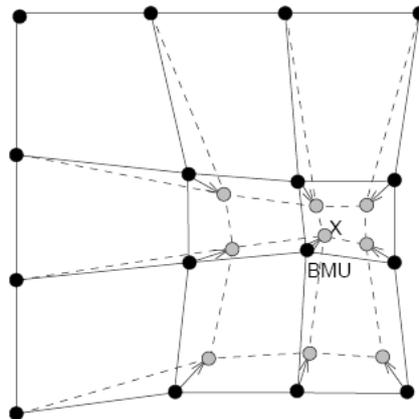


Figura 2. Atualização do BMU e seus vizinhos em direção à amostra de entrada marcada com x .⁽¹⁰⁾

A regra de atualização da rede SOM para o vetor de pesos da unidade i é:

$$m_i(t+1) = m_i(t) + \alpha(t)h_{ci}(t)[x(t) - m_i(t)], \quad (13)$$

onde $x(t)$ é um vetor de entrada randomicamente definido do conjunto de dados no tempo t , $h_{ci}(t)$ é o núcleo da vizinhança da unidade vencedora c e $\alpha(t)$ a taxa de aprendizagem no tempo t . O núcleo da vizinhança é uma função não acumulativa do tempo e da distância da unidade i à unidade vencedora c . Isto define a região de influência que as amostras de entrada têm na rede SOM.

O treinamento usualmente é feito em duas fases. Na primeira fase, relativamente são usados uma taxa de treinamento α_0 e raio de vizinhança σ_0 grandes. Na segunda fase ambos, taxa de aprendizagem e raio de vizinhança, são menores que no início. Este procedimento tem como objetivo primeiro sintonizar a SOM aproximadamente ao mesmo espaço de dados da entrada e então executar uma sintonia fina do mapa de características.

3 RESULTADOS

Para os experimentos deste trabalho foi instalada uma câmera digital em uma sala de inspeção de uma linha de laminação da siderúrgica ArcelorMittal. A câmera foi conectada a um computador que armazenava diariamente vídeos do aço laminado. Destes vídeos, foram selecionados aqueles representativos dos defeitos abordados. O programa Matlab foi utilizado para realização dos ensaios e, após a definição da melhor estratégia, foi desenvolvido um produto em C++ usando a biblioteca OpenCV.

Em linhas gerais, podemos dividir o funcionamento do sistema em três partes: a entrada, o sistema de inspeção e a saída, conforme mostra a Figura 3. A entrada refere-se basicamente à etapa de aquisição de imagens e suas disponibilizações para o sistema de inspeção. O sistema de inspeção aplica as técnicas dos campos de Visão Computacional e Redes Neurais Artificiais para o processamento da imagem e apresenta à saída as imagens de entrada retificadas com os defeitos detectados e classificados por regiões.

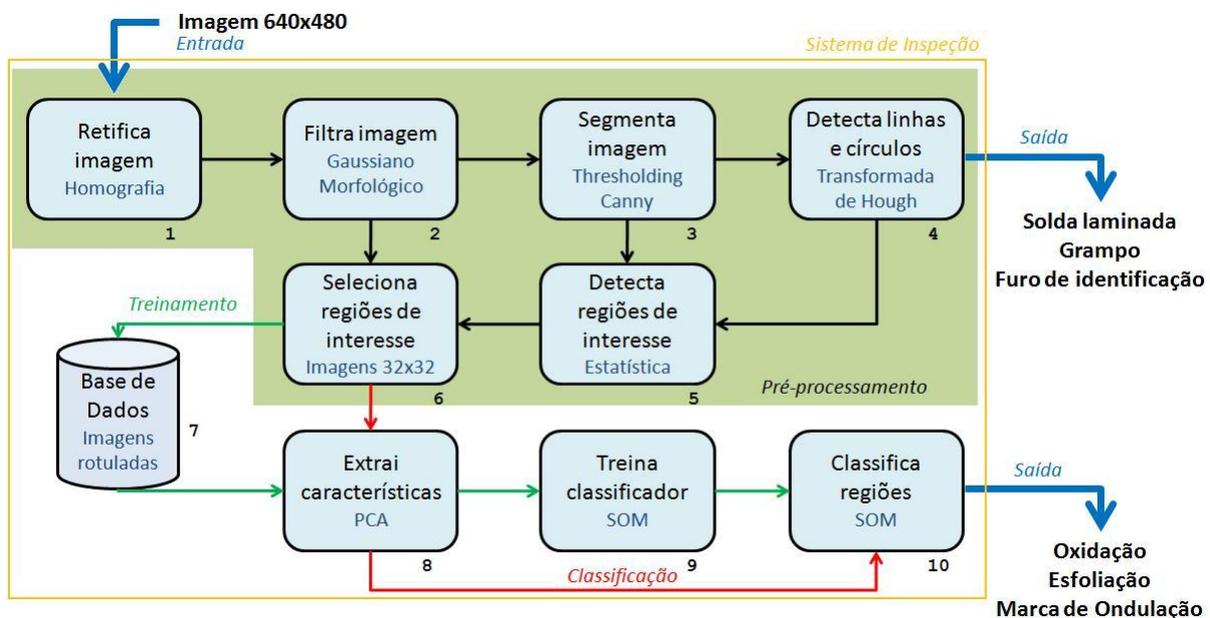


Figura 3. Diagrama de blocos do sistema de inspeção visual automática para classificação de defeitos em aços laminados.

O processo de inspeção pode ser dividido em três etapas: pré-processamento, treinamento e classificação. Ele inicia-se com a operação de retificação da imagem (bloco 1) recebida na entrada, que tem como finalidade eliminar as distorções radial e tangencial da lente da câmera além de alterar a perspectiva da imagem de forma que a posição do defeito no aço laminado possa ser identificada de forma precisa. Para esta atividade são utilizadas técnicas de calibração de câmera.

Após a retificação da imagem, a próxima operação consiste em eliminar os ruídos existentes, causados pela variação de luminosidade ou quaisquer outras fontes indesejadas de ruído durante a aquisição das imagens. Para esta operação são aplicados filtros gaussianos e morfológicos à imagem retificada de forma a apresentar como resultado uma imagem em tons de cinza destacando, sobretudo, as variações acentuadas nos níveis de cinza da superfície do aço laminado.

Após a filtragem, a imagem é submetida à operação de segmentação (bloco 3). A segmentação é realizada aplicando uma limiarização na imagem filtrada obtendo-se, então, uma imagem binária. Por meio da imagem binária é possível distinguir a mesa de inspeção do aço laminado. Utilizando-se em seguida um método de detecção de bordas, a posição do aço dentro da mesa é identificada, criando-se assim um mecanismo que possibilita medir automaticamente a largura da tira.

A seguir, a imagem binária resultante é submetida à operação de detecção de linhas e círculos (bloco 4). Esta operação basicamente é executada com a aplicação da transformada de Hough, conforme mostra a Figura 4. Por meio desta técnica, três tipos de defeitos podem já ser classificados e isolados das etapas posteriores: solda laminada, caracterizado por uma reta diagonal à borda da tira; grampo, caracterizado por uma reta perpendicular à borda da tira; e furo de identificação, caracterizado por um círculo de raio fixo e posicionado no centro da tira.

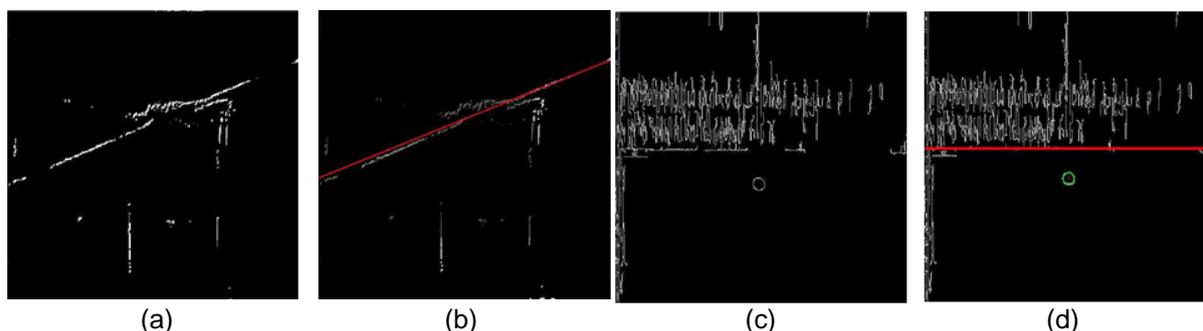


Figura 4. Detecção de retas e círculos usando a Transformada de Hough para classificação dos defeitos: (a)(b) solda laminada e (c)(d) grampo com furo de identificação.

A operação de detecção das regiões de interesse (bloco 5) consiste na aplicação de uma grade sobre a imagem binarizada (bloco 3), conforme mostra a Figura 5. Cada região da grade é definida como uma sub-imagem de tamanho 32x32 pixels. Para o passo posterior (bloco 6) são enviadas as posições das regiões da grade onde a quantidade de pixels não nulos encontra-se acima de um limiar estipulado e desde que as mesmas não contenham partes de retas ou círculos detectadas (bloco 4).

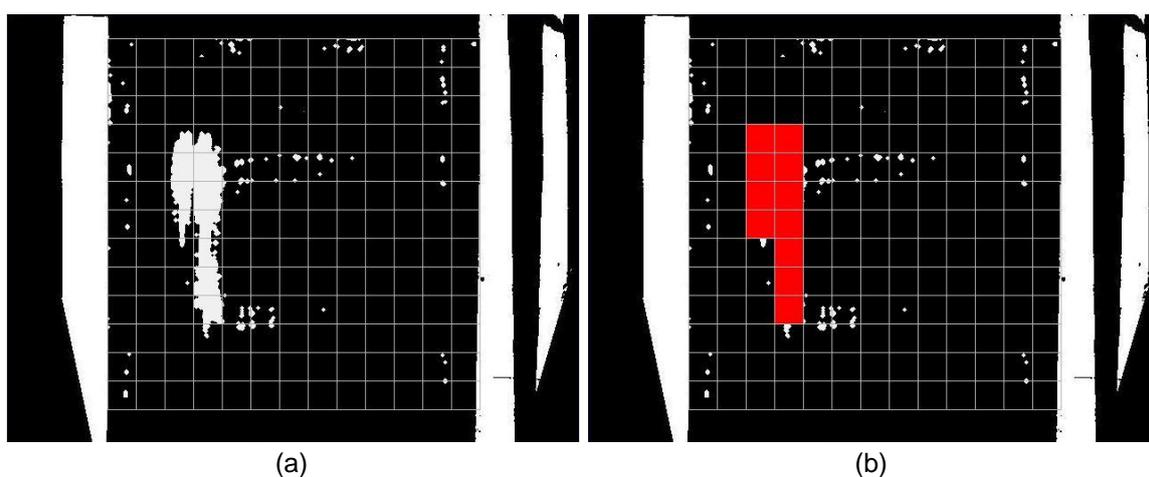


Figura 5. Imagem retificada com: (a) uma grade retangular particionando-a em sub-imagens e (b) as posições das sub-imagens contendo defeito.

A operação de seleção das regiões de interesse (bloco 6) recebe a localização das regiões da grade (bloco 5) a serem testadas para selecionar na imagem filtrada

(bloco 2) as sub-imagens 32x32 que serão usadas pelo sistema. Esta operação finaliza a etapa aqui definida de pré-processamento. O resultado final desta etapa é a disponibilização de sub-imagens para as etapas de treinamento e classificação.

Para fase de treinamento, inicialmente as sub-imagens são armazenadas em uma base de dados (bloco 7) onde elas são identificadas e selecionadas conforme os defeitos a serem testados: marcas de ondulação, esfoliação e oxidação.

Uma vez constituída a base de dados, a etapa de treinamento inicia-se com a operação de extração de características (bloco 8) utilizando-se a técnica PCA. Esta operação desempenha um papel fundamental, buscando representar os detalhes principais de cada tipo de defeito por meio de um conjunto reduzido de dados.

Já com as características extraídas, as amostras (sub-imagens ou regiões da grade) são utilizadas para treinar o classificador baseado em rede SOM (bloco 9).

Uma vez efetuado o treinamento do classificador, as regiões definidas na etapa de pré-processamento (bloco 6) podem ser classificadas. A etapa de classificação, tal como a de treinamento, conta com a operação de extração de características (bloco 8) além da própria operação de classificação (bloco 10). Esta etapa é executada *on line*, ou seja, as regiões aptas da grade são submetidas diretamente ao extrator e classificador, que entrega o resultado à fase de saída.

3.1 Detecção de Retas e Círculos

Os experimentos realizados para detectar retas e círculos e, conseqüentemente, os defeitos solda laminada, grampo e furo de identificação, utilizam a técnica de transformada de Hough. Para os experimentos foram selecionadas 300 imagens do tamanho 640x480 pixels e divididas em seis grupos de 50 imagens representando cada classe de defeito. Destas imagens, foram extraídas as partes referentes à área total da grade, conforme mostrado na Figura 5(a), compondo assim um conjunto com 300 amostras de teste para os experimentos.

Os defeitos solda laminada e grampo caracterizam-se por apresentar uma reta imaginária diagonal ou horizontal, respectivamente, ao longo da extensão da imagem de teste. Já o defeito furo de identificação caracteriza-se pela presença de um círculo centralizado e de raio definido, ao longo da extensão da imagem de teste. Portanto, pode-se definir uma região de busca deste círculo dentro da imagem.

A Tabela 1 mostra os resultados, em termos de exatidão da classificação, dos defeitos solda laminada, grampo e furo de identificação, baseada na detecção de retas diagonais, retas horizontais e círculos, respectivamente.

Tabela 1. Exatidão da classificação dos defeitos: solda, grampo e furo, baseada na detecção de retas e círculos

Grupos de amostras	Exatidão para diagonais (%)	Exatidão para horizontais (%)	Exatidão para círculos (%)
Solda	96,00	100,00	100,00
Grampo	100,00	86,36	98,00
Furo	100,00	100,00	100,00
Oxidação	100,00	100,00	100,00
Repuxado	100,00	100,00	100,00
Esfoliação	100,00	100,00	94,00
<i>Médio</i>	99,33	97,73	98,67

3.2 Extração de Características e Classificação

A partir da posição das regiões com defeito, foi montada uma base de dados com 5400 amostras (sub-imagens 32x32 pixels) extraídas das imagens em níveis de cinza do tamanho 640x480 pixels. Estas amostras foram distribuídas, conforme a classe de defeito correspondente, em três grupos: esfoliação, oxidação e marca de ondulação ou repuxado.

Após a composição dos grupos de amostras, cada amostra foi convertida em um vetor coluna e associada a uma matriz representativa deste grupo. Cada matriz foi então submetida à técnica PCA para extração de características, resultando em novas matrizes contendo as características representativas das amostras.

Dentro da técnica foram consideradas as seis componentes principais de maior magnitude. Desta forma, o resultado apresentado foi uma matriz de características contendo os seis valores de parâmetros para cada amostra.

As matrizes de cada grupo foram reunidas em uma única matriz PCA contendo as características das 5400 amostras. Essa matriz teve a ordem das amostras alteradas, formando-se oito combinações para os ensaios com a rede SOM. De cada combinação, foram utilizados dois terços das amostras (3600) para treinamento e o restante (1800) para os testes da rede.

A rede SOM foi treinada com cada uma das oito combinações da matriz PCA. Este modelo de rede é tipicamente baseado em aprendizagem não supervisionada que coloca os vetores protótipos em uma grade de baixa dimensão (bi-dimensional) de forma ordenada (categorização). Por ser de aprendizagem não supervisionada, não há a necessidade de rotulação das amostras de entrada, pois o próprio algoritmo da rede tende a agrupá-las conforme suas afinidades. Porém, as amostras de entrada em cada combinação foram rotuladas para que, após o treinamento da rede, as classes dos neurônios de saída pudessem ser definidas.

As amostras de treinamento e seus respectivos rótulos foram colocados em uma estrutura de dados para o início do treinamento. Foi utilizada uma arquitetura de rede com um mapa de saída de forma retangular do tamanho 20x20. A rede foi então iniciada. Primeiramente, o algoritmo utilizado realiza uma tentativa de iniciação linear do mapa da rede com os dois maiores autovetores e, não sendo possível este cálculo, é então usada a iniciação randômica. Após a iniciação, a rede SOM foi treinada em duas fases: um primeiro treinamento grosseiro e então um ajuste fino.

Após o treinamento, os neurônios de saída foram identificados pela votação da maioria das amostras que ele agrupou, ou seja, em que ele foi vencedor. No caso de igualdade, a identificação foi definida conforme o neurônio de saída mais próximo. A Figura 6(a) mostra o mapa da rede onde os quadrados de cor azul, verde e vermelha representam o mapeamento para amostras do defeito esfoliação, oxidação e marca de ondulação ou repuxado, respectivamente. As regiões mostradas em preto identificam os neurônios que não foram vencedores. A Figura 6(b) apresenta a disposição das amostras em um espaço PCA tridimensional, nas cores definidas anteriormente para os respectivos defeitos, juntamente com arranjo da grade de neurônios de saída, na cor preta.

Após o treinamento e identificação dos neurônios de saída, iniciaram-se então os testes para medir o desempenho da rede. As amostras de teste também foram rotuladas, submetidas à rede e classificadas conforme a identificação do neurônio que agrupou cada uma delas (neurônio vencedor). A comparação entre o rótulo da amostra de teste e a sua classificação por meio do neurônio vencedor determinou a exatidão de classificação da rede.

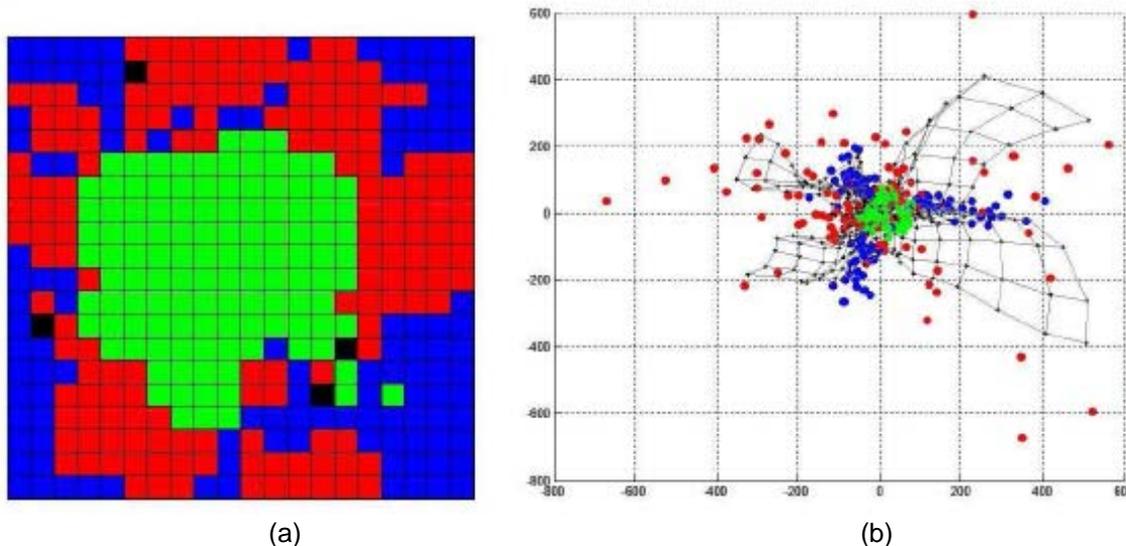


Figura 6. (a) Mapa de saída da rede SOM de tamanho 20x20 com os agrupamentos de saída (neurônios vencedores) identificados nas cores vermelho (repuxado), verde (oxidação) e azul (esfoliação). (b) Representação tridimensional de parte dos dados de entrada (amostras) em um espaço PCA e do mapa 20x20 da rede.

A Tabela 2 apresenta os resultados em termos de exatidão de classificação da rede. A coluna *Comb.* desta tabela identifica a combinação da matriz PCA utilizada para o treinamento. As colunas *Esfoliação*, *Oxidação* e *Repuxado* apresentam os resultados de exatidão para os respectivos defeitos. Por fim, a coluna *Global* apresenta os resultados de exatidão da rede para todos os tipos de defeitos.

Tabela 2. Exatidão da classificação dos defeitos: esfoliação, oxidação e marca de ondulação ou repuxado

Comb.	Exatidão para esfoliação (%)	Exatidão para oxidação (%)	Exatidão para repuxado (%)	Global (%)
A1	50,62	98,33	78,55	75,06
A2	45,38	96,00	79,09	72,56
A3	50,92	95,50	81,64	75,17
A4	52,77	95,67	80,55	75,56
A5	62,00	98,00	78,00	78,89
A6	68,00	97,50	76,55	80,44
A7	67,85	94,33	78,18	79,83
A8	67,69	97,33	74,55	79,67
<i>Médio</i>	58,15	96,58	78,39	77,15

O sistema de inspeção apresenta então em sua saída, para todos os casos, a imagem original em tamanho 640x480 pixels retificada com regiões de tamanho 32x32 pixels, contendo os defeitos detectados e classificados, marcadas em cores distintas conforme mostra a Figura 7.

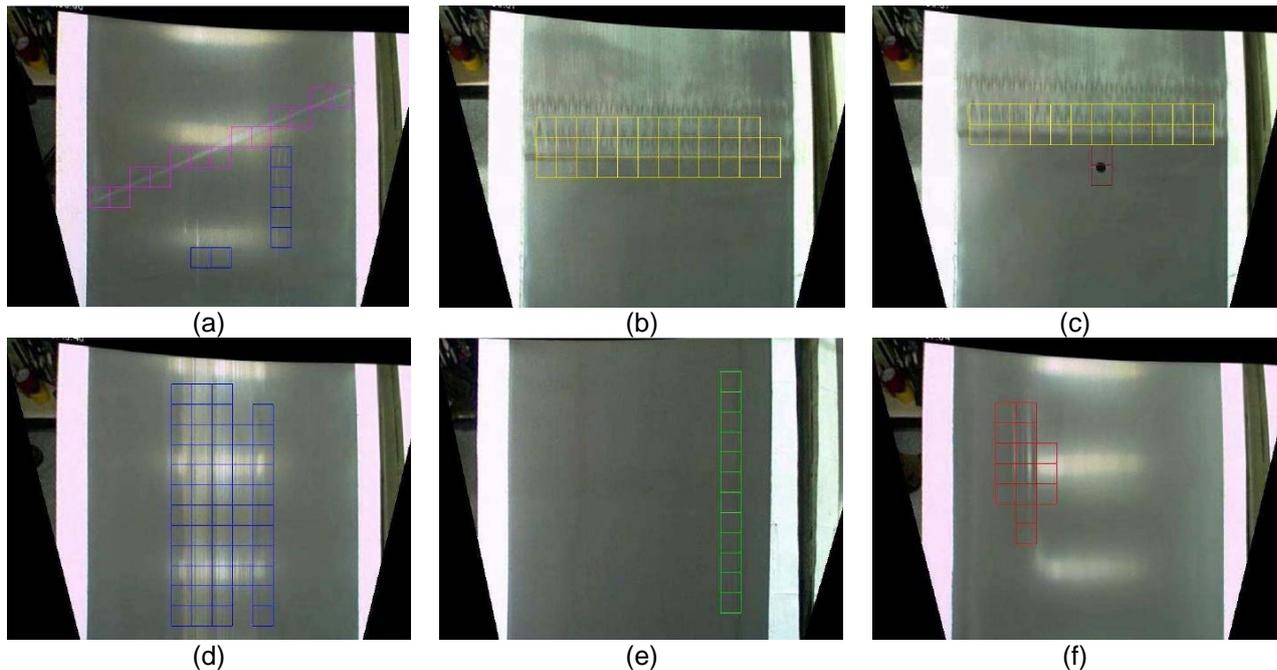


Figura 7. Imagem retificada com as regiões com defeitos detectados e classificados: (a) solda laminada, (b) grampo, (c) grampo com furo de identificação, (d) esfoliação, (e) oxidação e (f) marca de ondulação ou repuxado

4 DISCUSSÃO

O presente trabalho apresentou um sistema de inspeção visual automática para detecção e classificação de defeitos em aços laminados, baseado em técnicas de Visão Computacional e Redes Neurais Artificiais.

Por meio da detecção de retas diagonais, horizontais e círculos, utilizando a transformada de Hough, o sistema pôde classificar os defeitos: solda laminada, grampo e furo de identificação. Para estes experimentos foram utilizadas 300 imagens de teste e avaliadas a exatidão de classificação destes defeitos, conforme mostrado na Tabela 1.

Os valores de exatidão mantiveram-se em torno de 98%, justificados pelo ajuste de limiarização e pelas características geométricas bem definidas de cada defeito (a probabilidade de reta diagonal em imagens de grampo é muito baixa).

Os demais defeitos: oxidação, esfoliação e marca de ondulação ou repuxado foram classificados seguindo os passos típicos de um sistema de reconhecimento de padrão. A Análise de Componentes Principais – PCA é uma técnica robusta e amplamente utilizada para redução de dimensionalidade ou extração de características, motivo pelo qual foi considerada neste trabalho. A característica de auto-organização da rede SOM torna-a apropriada para o agrupamento de classes. Esta característica foi explorada para torná-la um classificador com flexibilidade para definir os componentes do grupo e rótulos das classes. O sistema de classificação, utilizando a técnica PCA e a rede SOM, apresentou uma exatidão global média de classificação de 77%.

Considerando os resultados para os seis tipos de defeitos, temos um valor médio de exatidão global de 87%. A combinação destas técnicas evidencia, então, o grande potencial deste sistema para aplicação na inspeção visual automática em um ambiente real, ou seja, uma linha de laminação de aços.

5 CONCLUSÃO

O sistema foi validado com sucesso para classificação de defeitos em imagens obtidas de filmagens de aço laminado processado em uma linha de laminação.

As soluções atuais adquiridas para inspeção em siderúrgicas são importadas e têm alto custo financeiro. A inspeção visual humana tem as limitações impostas por condições pessoais e ambientais, além de um custo mensal para empresa. Estes fatores motivam o desenvolvimento de sistemas para inspeção visual automática de defeitos.

Como continuação deste trabalho, pretende-se implementar técnicas para aperfeiçoamento do processo de classificação do sistema desenvolvido e aplicá-lo, ainda este ano, para detecção de defeitos em tempo real em uma linha de laminação da ArcelorMittal.

Agradecimentos

Os autores agradecem o CEFET-MG pela disponibilização da infra-estrutura para o desenvolvimento do trabalho e a siderúrgica ArcelorMittal Timóteo por permitir a utilização de informações da planta industrial neste trabalho.

REFERÊNCIAS

- 1 JAIN, A. K.; DUIN, R. P.; MAO, J. (2000). Statistical pattern recognition: A review. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 22, n. 1.
- 2 KANG, G. wen; LIU, H. bing. (2005). Surface defects inspection of cold rolled strips based on neural network. *Proceedings of Fourth International Conference on Machine Learning and Cybernetics*, p. 5034–5038.
- 3 KUMAR, A.; SHEN, H. C. (2002). Texture inspection for defects using neural networks and support vector machines. *IEEE ICIP 2002*, v. 3, p. 353–356.
- 4 ALVES, W. A. L.; ARAÚJO, S. A. de and LIBRANTZ, A. F. H. (2006). Reconhecimento de padrões de texturas em imagens digitais usando uma rede neural artificial híbrida. *Exacta*, v. 4, n. 2, p. 325–332, 2006.
- 5 IIVARINEN, J. et al. (2004). Content-based retrieval of surface defect images with PicSOM. *International Journal of Fuzzy Systems*, v. 6, n. 3, p. 160–167.
- 6 KAUPPINEN, H.; SILVEN, O.; PIIRAINEN, T. (1999). Self-organizing map based user interface for visual surface inspection. *Proc. 11th Scandinavian Conference on Image Analysis*, p. 801–808.
- 7 MAENPAA, T.; TURTINEN, M.; PIETIKAINEN, M. (2000). *Real-Time Surface Inspection by Texture*. Finland.
- 8 HAYKIN, S. (2001). *Redes Neurais: Princípios e Prática*. Editora Bookman, 2ª. Ed., Porto Alegre-RS.
- 9 BRAGA, A. P.; CARVALHO, A. P. L. F.; LUDEMIR, T. B. (2000). *Redes Neurais Artificiais: Teoria e Aplicações*. Rio de Janeiro, RJ: LTC – Livros Técnicos e Científicos Editora S. A., 2000.
- 10 VESANTO, J.; HIMBERG, J.; ALHONIEMI, E.; PARHANKANGAS, J. (2000). *SOM Toolbox for Matlab 5*. Helsinki University of Technology, Finland.