

SISTEMA BASEADO EM REDE SOM PARA INSPEÇÃO VISUAL AUTOMÁTICA DE DEFEITOS EM AÇOS LAMINADOS

Luiz A. O. Martins, Flávio L. C. Pádua e Paulo E. M. de Almeida

Laboratório de Sistemas Inteligentes, Centro Federal de Educação Tecnológica de Minas Gerais (CEFET-MG), Av. Amazonas, 7675, Nova Gameleira, CEP 30510-000, Belo Horizonte
luizalberto@lsi.cefetmg.br; cardeal@lsi.cefetmg.br; pema@lsi.cefetmg.br

Abstract – This work addresses the problem of automated visual inspection of rolled steel surface defects, by using image analysis techniques and Artificial Neural Networks. Unlike most common techniques, which are frequently based on manual estimations that lead to significant time and financial constraints, we present an automatic system based on (i) the well-known robust feature extraction technique: Principal Component Analysis (PCA) for parameterizing shape and appearance of defects and, (ii) the Artificial Neural Network model: Self-Organizing Map (SOM) for classification purposes. Three common rolled steel surface defects were considered in this work: exfoliation, oxidation and wave-form defects. The system was successfully validated with real-world video streams acquired at a cold rolled mill line of a steelmaking industry, achieving overall classification accuracy of 77% and demonstrating its high potential to be applied in real scenarios.

Keywords – computational intelligence, self-organizing maps, automated visual inspection, rolled steel

Resumo – Este artigo descreve o problema de inspeção visual automática de defeitos de superfície de aços laminados usando técnicas de análise de imagens e Redes Neurais Artificiais. Diferentemente de muitas técnicas comuns que são frequentemente baseadas em estimações manuais e que lidam com tempo significativo e restrições financeiras, é apresentado um sistema automático baseado em (i) a tão conhecida e robusta técnica de extração de características: Análise de Componentes Principais (*Principal Component Analysis* – PCA) para parametrização da forma e aparência dos defeitos e, (ii) o modelo de Rede Neural Artificial: Mapas Auto-Organizáveis (*Self-Organizing Map* - SOM) para propósitos de classificação. Três defeitos de superfície em aços laminados foram considerados neste trabalho: esfoliação, oxidação e marca de ondulação ou repuxado. O sistema desenvolvido foi validado com sucesso utilizando imagens de filmagens de aço laminado processado em uma linha de laminação de uma indústria siderúrgica, atingindo uma exatidão de classificação global de 77% e demonstrando seu grande potencial para aplicação em cenários reais.

Palavras-chave – inteligência computacional, mapas auto-organizáveis, inspeção visual automática, aço laminado

1. Introdução

A automação de um processo produtivo é um fator decisivo para garantir ganhos de qualidade e produtividade em uma indústria siderúrgica. Dentro deste contexto, a inspeção em pontos-chaves na cadeia produtiva necessita, cada vez mais, de embutir os comportamentos inteligentes de pessoas que realizam esta atividade em sistemas computacionais, compondo assim a inteligência e a experiência humana à velocidade de processamento de uma máquina.

A ocorrência de problemas em um processo industrial é inevitável. Oscilações em variáveis de um processo industrial como, por exemplo, temperatura, vazão, pressão e velocidade, podem ocasionar defeitos no produto processado em uma linha de produção. Portanto, é necessária a inspeção do produto final para identificação dos defeitos existentes e tomada de ações corretivas de forma a garantir a sua qualidade. A garantia da qualidade do produto final, em grande parte das indústrias, tem sido feita por inspeção visual. Em uma indústria siderúrgica, geralmente, a garantia da qualidade do produto é realizada por meio de inspeções visuais nas linhas finais de laminação de aço. 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) Algumas vezes, é necessária a parada ou redução da velocidade do processo, para uma análise mais criteriosa do produto.

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. A detecção e classificação de uma gama de defeitos não eram possíveis até a utilização de sistemas baseados em câmeras. Estes sistemas capturam as imagens de defeitos e os classificam, conforme suas características, em classes de defeitos similares. A velocidade, consistência e certas capacidades de análise de uma máquina de visão compensam alguma fraqueza desta em relação às pessoas. As imperfeições em uma superfície de um aço laminado variam tanto em extensão da área quanto ao tipo do defeito e alguns destes defeitos são particulares de uma linha de produção. Há vários tipos de defeitos em aços laminados reconhecidos em um processo de laminação. Os mais relevantes e considerados neste trabalho são:

- *Oxidação* (Figura 1(a)): defeito superficial caracterizado pela aparência de óxidos na superfície metálica. Os óxidos apresentam-se na lâmina (ou tira) de aço como uma mancha escura tendendo ao preto. Têm aspecto variável tanto em área quanto em intensidade de cor, podendo apresentar-se como manchas em pequenas áreas isoladas (pontos), áreas de maior abrangência ou como manchas contínuas (faixas). Geralmente são causados por distúrbios no tratamento metalúrgico como variação da atmosfera do forno e do processo de decapagem, além de condições de armazenamento e transporte;
- *Esfoliação* (Figura 1(b)): defeito superficial caracterizado pela aparência de uma superfície áspera em forma de faixa com comprimento e largura variáveis e orientada na direção de laminação. Geralmente, este defeito é causado por transporte do material em processos iniciais de laminação onde a placa de aço sofre arranhões. Também pode ser causado durante o processo de laminação devido à sujeira ou desajustes dos elementos rotativos da linha;
- *Marca de ondulação ou repuxado* (Figura 1(c)): defeito de forma caracterizado por apresentar ondulações localizadas em parte do material no sentido de laminação. O defeito pode ser identificado pelo tato, uma vez que apresenta irregularidades no relevo. Geralmente ocorre em áreas bem definidas e é causado por desalinhamento e oscilações de velocidade e tração do aço no processo de laminação;

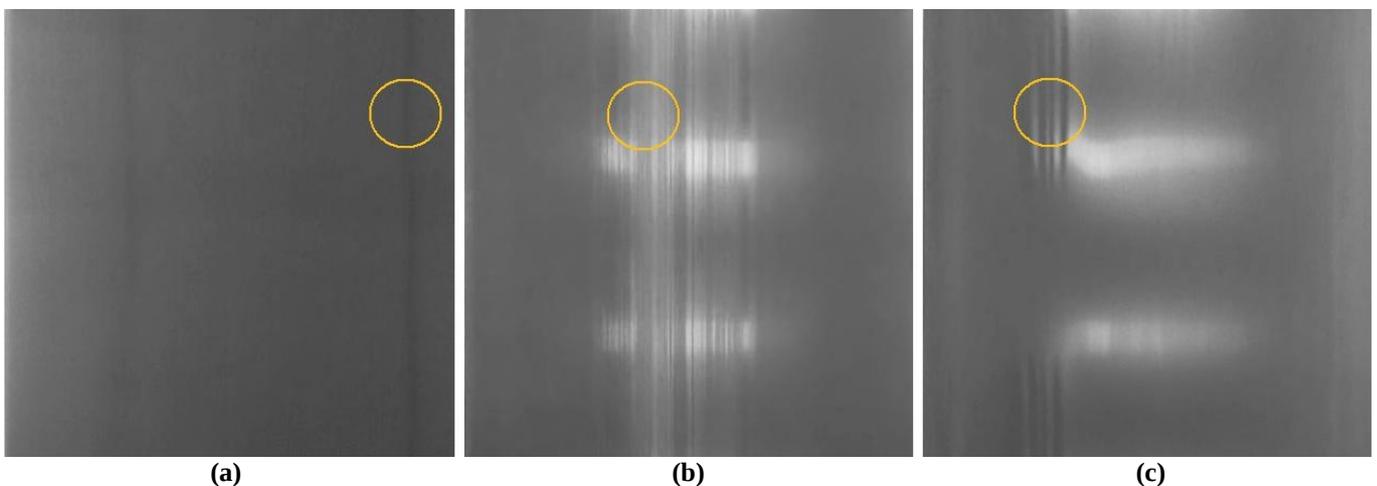


Figura 1 – Defeitos comumente encontrados em aços laminados: (a) oxidação, (b) esfoliação e (c) marca de ondulação ou repuxado.

Quando há um conjunto de dados grande para ser processado por um algoritmo e contendo pouca informação, ele pode ser transformado em um conjunto reduzido de características que melhor o represente. Transformar o conjunto de dados de dimensão maior em um conjunto de características de dimensão menor é chamado de extração de características. Se as características extraídas forem

cuidadosamente escolhidas espera-se que esse conjunto represente a parte relevante da informação para se executar a tarefa desejada ao invés de se usar o conjunto completo de dados. A técnica estatística PCA [1] é robusta e bastante utilizada em aplicações de reconhecimento de imagens como extrator de características.

As redes neurais artificiais têm sido amplamente utilizadas em aplicações de classificação e recuperação de imagens [2]. O uso dos modelos neurais para estas atividades está diretamente relacionado à suas principais características: a capacidade de aprender e de generalizar a informação aprendida. Outra característica importante das redes neurais é a capacidade de auto-organização, em que a rede atribui um padrão de entrada a uma classe dentre um conjunto de classes conhecidas.

Uma estrutura popular de rede neural denominada SOM (*Self-Organizing Maps*) apresenta esta capacidade de auto-organização. Também chamada de SOFM (*Self-Organizing Feature Maps*) ou Mapas de Kohonen [3], ela é tipicamente uma rede baseada em aprendizagem não supervisionada que coloca os vetores protótipos em uma grade de baixa dimensão de forma ordenada.

Este trabalho descreve então uma estratégia para classificar defeitos em aços laminados utilizando a técnica PCA como extrator de características e a rede SOM para classificação. Para isto foram utilizados a ferramenta *SOM Toolbox for Matlab 5* [4] e amostras dos defeitos em um aço laminado, conforme mostra a Figura 2, extraídas de filmagens realizadas em uma linha de laminação.

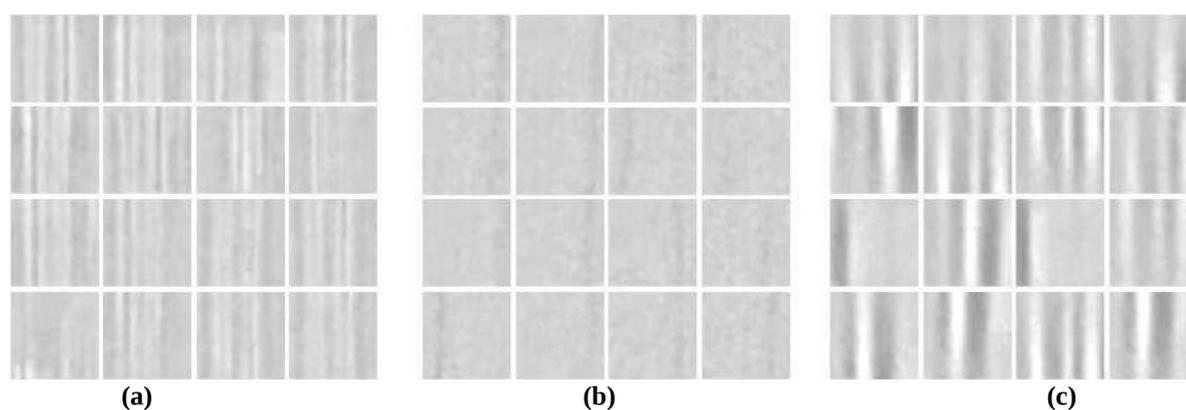


Figura 2 – Amostras em tamanho 32x32 pixels de defeitos em aços laminados: (a) oxidação, (b) esfoliação e (c) marca de ondulação ou repuxado.

Há diversos trabalhos publicados, dentre os quais pode-se citar [7-10], que utilizam rede SOM quer seja para extração de características e redução de dimensionalidade ou para categorização e classificação associados a outros métodos. Há também várias propostas de redes derivadas da rede SOM, como em [11-13], para atender eficientemente alguma necessidade específica. Isto confirma a praticidade deste tipo de rede neural, motivo pelo qual a estamos considerando neste trabalho.

Este artigo está organizado como se segue: a seção 2 apresenta uma breve descrição da técnica estatística PCA utilizada para extração de características dos padrões. A seção 3 apresenta a rede SOM, utilizada para classificação destes padrões e a seção 4 descreve em detalhes o sistema de classificação desenvolvido e os experimentos conduzidos, além de analisar os resultados obtidos. A seção 5 sumariza este relato e indica os novos passos a serem seguidos no desenvolvimento do projeto de pesquisa em questão.

2. 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 sobre os dados com os quais se está lidando. 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.

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, \dots, 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 $R = E[XX^T] \approx \frac{1}{p} XX^T$, a matriz covariância pode ser reescrita como:

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

Para se determinar qual matriz V deve ser utilizada de forma que a covariância seja a maior possível, 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, $R = VSV^T$. Fazendo-se as operações necessárias:

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

onde a matriz S irá apresentar em sua diagonal principal os valores singulares de $V^T R V$ 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, poderia-se usar apenas os k primeiros vetores de V para representar a nova base:

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

A representação de X neste novo sistema de coordenadas de menor dimensão seria então:

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

3. 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 [5].

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 [6]. Os neurônios são conectados aos neurônios adjacentes por uma relação de vizinhança, ditando a topologia, ou estrutura, do mapa. A topologia, apresentada por uma rede SOM, pode apresentar os formatos de vizinhança retangular e hexagonal, conforme mostra a Figura 3. A definição do formato mais adequado depende do problema atacado e da distribuição de seus dados.

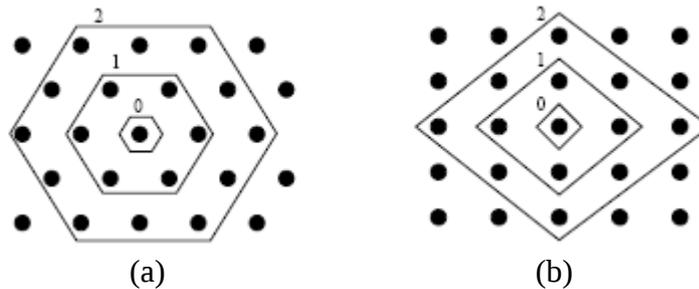


Figura 3 – Vizinhos discretos (tamanhos 0, 1 e 2) da unidade central na disposição: (a) hexagonal e (b) retangular [3].

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 está próximo ao vetor de entrada x , é chamado de unidade de melhor correspondência BMU (Best-Matching Unit), denotado na equação (1) por c :

$$\|x - m_c\| = \min_i \{ \|x - m_i\| \}, \quad (1)$$

onde o módulo da distância é tipicamente uma medida euclidiana.

A computação desta distância, utilizada pelo *toolbox*, não considera no cálculo os valores faltantes e aplica uma máscara a valores de pesos associados às variáveis. Com isso, a medida de distância torna:

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

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

$$m_i(t+1) = m_i(t) + \alpha(t) h_{ci}(t) [x(t) - m_i(t)], \quad (3)$$

onde $x(t)$ é um vetor de entrada randomicamente definido do conjunto de dados de entrada 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.

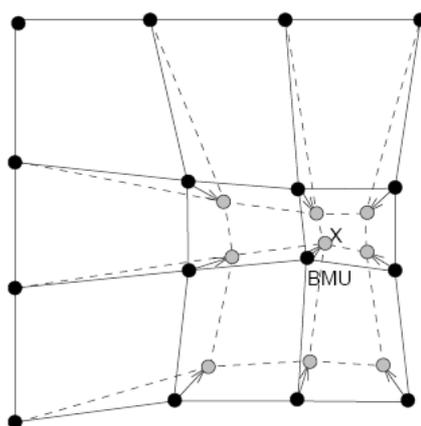


Figura 4 – Atualização do BMU e seus vizinhos em direção à amostra de entrada marcada com x. Adaptado de [3].

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 objetivos primeiro sintonizar a SOM aproximadamente ao mesmo espaço de dados da entrada e então executar uma sintonia fina do mapa de características.

4. Sistema de Classificação

Para o desenvolvimento deste sistema foram selecionadas imagens de 640x480 pixels de filmagens de tiras de aço em uma linha de laminação com o objetivo de classificar os defeitos detectados em três classes: esfoliação, oxidação e marca de ondulação ou repuxado.

Após a etapa de pré-processamento, na qual foi realizada uma transformação de perspectiva para dispor o objeto de interesse dentro da imagem (aço laminado) de forma regular, conforme mostra a Figura 5(a), a imagem foi convertida para escala de cinza, conforme mostra a Figura 5(b), devido às cores não serem consideradas como características de classificação do defeito. O objeto de interesse dentro da imagem foi então segmentado e, sobre a parte referente ao aço laminado, estabeleceu-se uma grade retangular, conforme mostra a Figura 5(c), com regiões representando uma sub-imagem de 32x32 pixels. Por meio do método de limiarização, foram então definidas as regiões contendo os defeitos, conforme mostra a Figura 5(d).

A partir da posição de cada região com defeito, foi então montada uma base de dados com 5400 amostras (sub-imagens 32x32 pixels referente às regiões contendo defeito) extraídas das imagens em níveis de cinza do tamanho 640x480 pixels. Estas amostras foram distribuídas em nove grupos, conforme mostra a Tabela 1, sendo: três para o defeito esfoliação (E1, E2 e E3), três para o defeito oxidação (O1, O2 e O3) e outros três para o defeito marca de ondulação ou repuxado (R1, R2 e R3).

Tabela 1 – Agrupamento das amostras para o treinamento do classificador.

	<i>Esfoliação</i>			<i>Oxidação</i>			<i>Repuxado</i>		
<i>Grupos</i>	E1	E2	E3	O1	O2	O3	R1	R2	R3
<i>Qtde. por Grupo</i>	650	650	650	600	600	600	550	550	550
<i>Qtde. por Classe</i>	1950			1800			1650		
TOTAL	5400								

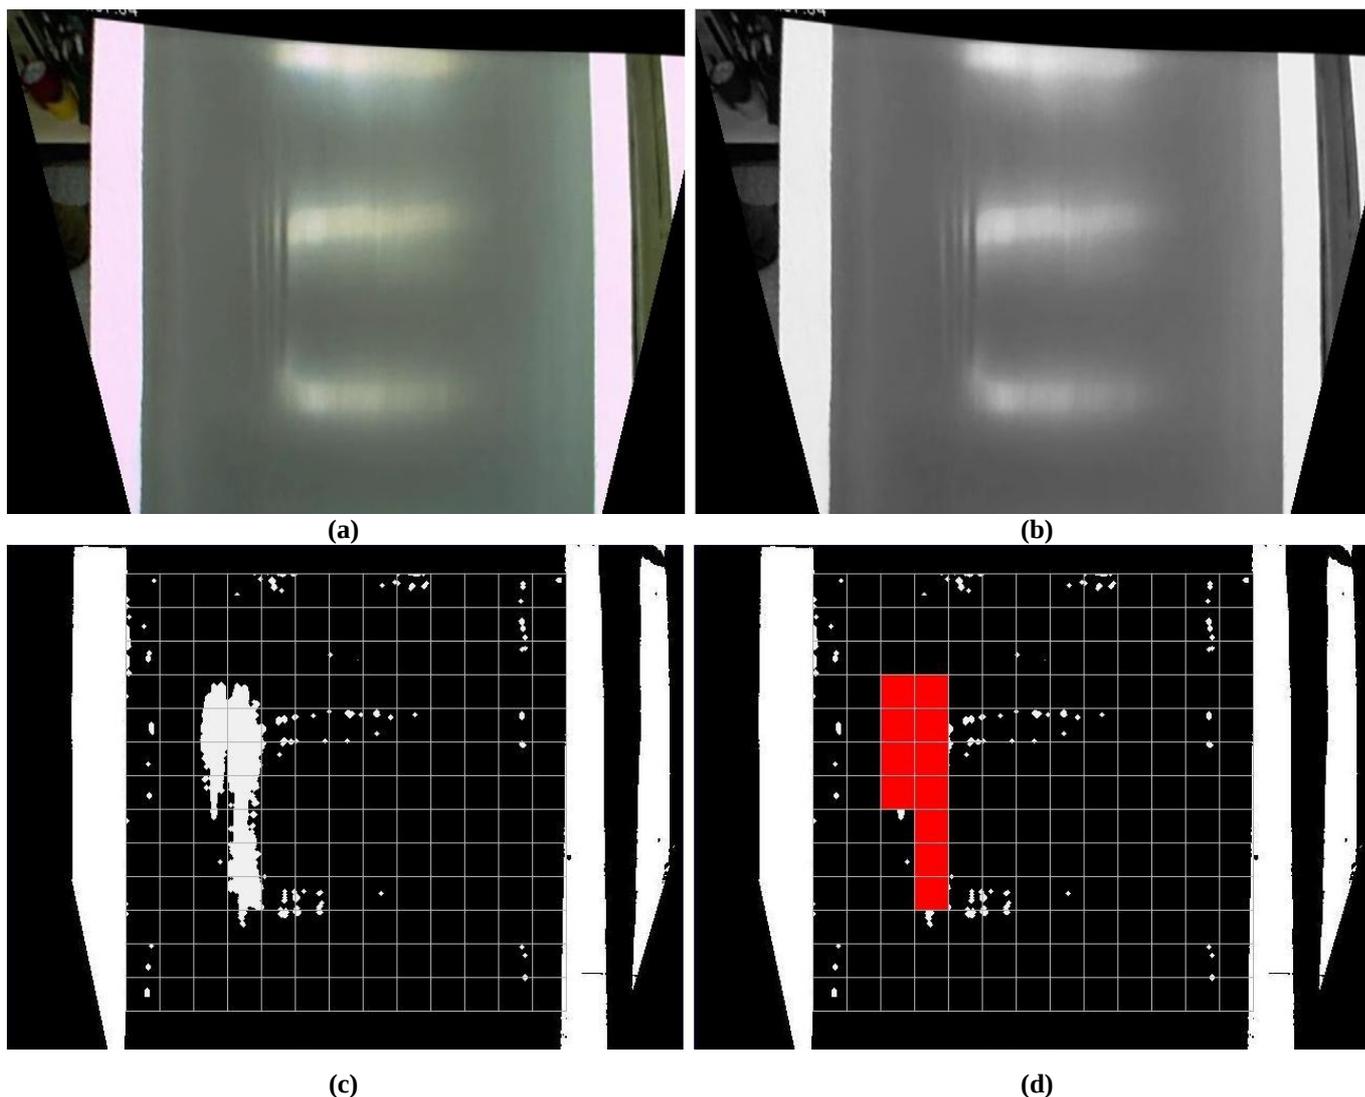


Figura 5 – Imagem contendo o objeto de interesse (aço laminado): (a) com uma transformação de perspectiva; (b) em escala de cinza; (c) com uma grade retangular particionando-a em sub-imagens; e (d) com as regiões contendo defeito.

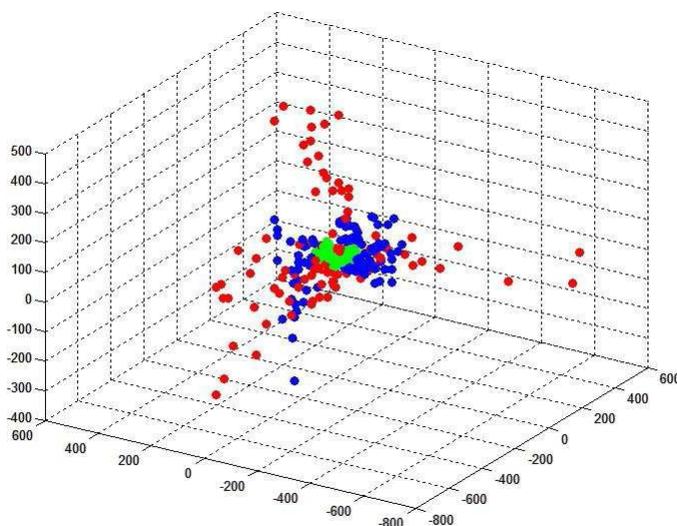


Figura 6 – Espaço PCA tridimensional contendo 300 amostras dos defeitos de esfoliação (azul), oxidação (verde) e marca de ondulação ou repuxado (vermelho). Neste caso, apenas as três componentes principais de maior magnitude, calculadas pela técnica PCA, estão sendo consideradas.

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.

Após a extração de características para cada grupo de amostras, mostrados na Tabela 1, formou-se uma matriz PCA, envolvendo todos os grupos e contendo as características das 5400 amostras. Essa matriz teve a ordem das suas amostras definida aleatoriamente, formando-se oito combinações para serem utilizadas nos ensaios com a rede SOM. De cada combinação, foram utilizados dois terços das amostras (3600) para realização do treinamento e o restante (1800) para os testes das redes.

Cada uma das oito combinações da matriz PCA foi submetida ao treinamento da rede SOM. A rede SOM é tipicamente uma rede baseada 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.

Após a rotulação, as amostras de treinamento e seus respectivos rótulos foram colocados em uma estrutura de dados para o início do treinamento da rede. Para configuração da rede SOM definiu-se um tamanho 20x20 para o mapa de saída e a forma retangular. A rede foi então iniciada. O algoritmo do *toolbox* realiza primeiramente 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. Em caso de igualdade, a rotulação foi feita conforme o neurônio de saída mais próximo. A Figura 7(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 7(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.

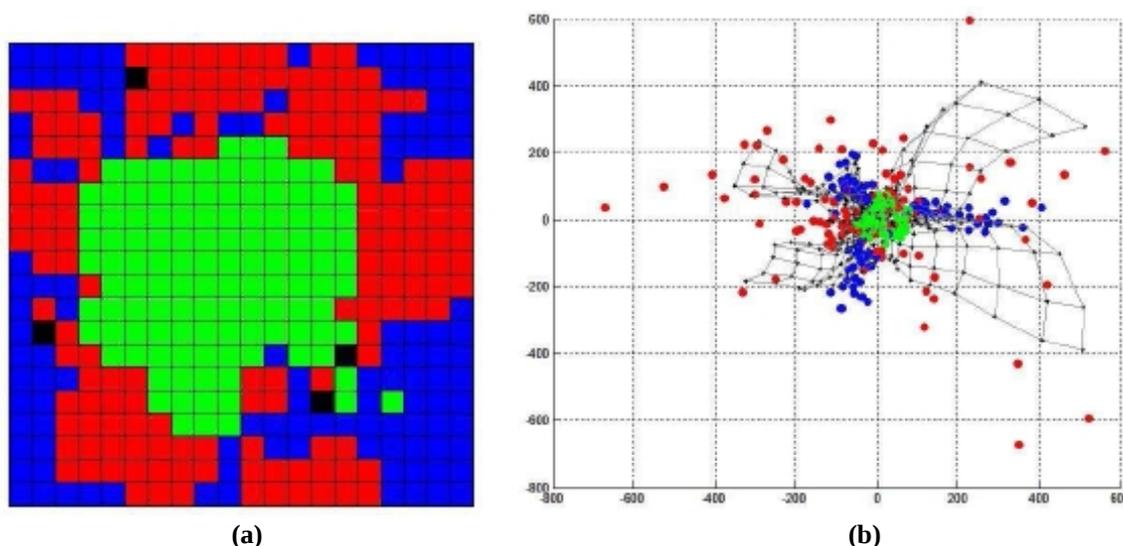


Figura 6 – (a) Mapa de saída da rede SOM de tamanho 20x20 com os agrupamentos de saída (neurônios vencedores) identificados nas cores vermelho (repuxado), verde (oxidação) e azul (esfoliação). (b) Representação tridimensional de parte dos dados de entrada (amostras) em um espaço PCA e do mapa 20x20 da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

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.

A Tabela 2 apresenta os resultados em termos de exatidão de classificação da rede. A coluna *Combinação* desta tabela identifica a combinação da matriz PCA utilizada para o treinamento ($A =$ amostras de treinamento, $1..8 =$ número da combinação). As colunas *Esfoliação*, *Oxidação* e *Repuxado*, com a quantidade de amostras entre parênteses, apresentam os resultados de exatidão para os respectivos defeitos. Por fim, a coluna *Global*, também com a quantidade de amostras em parênteses, apresenta os resultados de exatidão da rede para todos os tipos de defeitos.

Tabela 2 – Resultados da exatidão de classificação.

<i>Combinação</i>	<i>Esfoliação (650)</i>	<i>Oxidação (600)</i>	<i>Repuxado (550)</i>	<i>Global (1800)</i>
A1	50,6154	98,3333	78,5455	75,0556
A2	45,3846	96,0000	79,0909	72,5556
A3	50,9231	95,5000	81,6364	75,1667
A4	52,7692	95,6667	80,5455	75,5556
A5	62,0000	98,0000	78,0000	78,8889
A6	68,0000	97,5000	76,5455	80,4444
A7	67,8462	94,3333	78,1818	79,8333
A8	67,6923	97,3333	74,5455	79,6667
<i>Médio</i>	58,1539	96,5833	78,3864	77,1459

Os resultados apresentam uma exatidão global de classificação de 80% para o melhor caso e de 75% para o pior caso. O sistema apresenta melhor eficiência na classificação do defeito oxidação e pior na do defeito esfoliação. O sistema de classificação, utilizando a técnica PCA e a rede SOM, apresentou então em sua saída a imagem original em tamanho 640x480 pixels retificada com regiões de tamanho 32x32 pixels, contendo os defeitos detectados, marcadas em cores distintas de acordo com a classificação realizada, conforme mostra a Figura 8.

5. Conclusão

O presente trabalho apresentou uma avaliação da estratégia de classificação para os defeitos esfoliação, oxidação e marca de ondulação (ou repuxado) em aços laminados, baseada na técnica PCA para extração de características e na rede SOM para classificação. Para esta experiência foram utilizadas 5400 sub-imagens de aço laminado.

De uma maneira geral, este trabalho apresenta o desenvolvimento do sistema aplicando os passos típicos para 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. A combinação destas técnicas evidencia o grande potencial deste sistema para aplicação na inspeção visual automática em um ambiente real, ou seja, uma linha de laminação de aços.

Atualmente, as soluções 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.

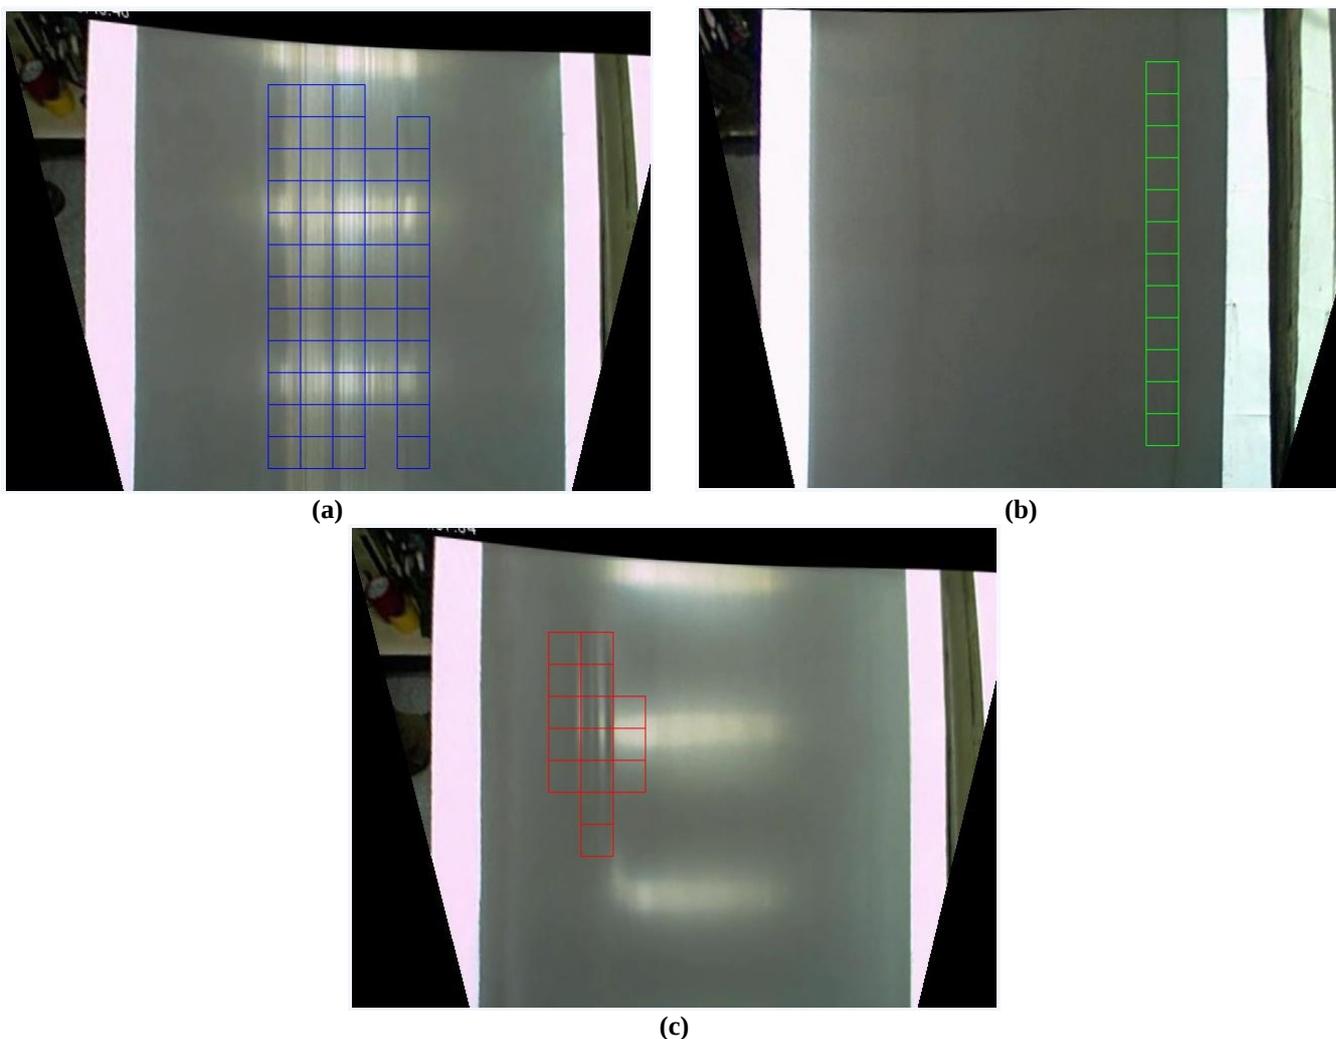


Figura 8 – Imagem de saída com os defeitos marcados e classificados: (a) esfoliação; (b) oxidação; e (c) marca de ondulação ou repuxado.

Como continuação deste trabalho, pretende-se implementar técnicas para aperfeiçoamento do processo de classificação do sistema desenvolvido e aplicá-lo, o mais breve possível, em um ambiente industrial para validar a eficácia, eficiência e escalabilidade do sistema.

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

Referências

- [1] J. Shlens, A Tutorial on Principal Component Analysis, **University of California**, 2(2005), 1-13.
- [2] M. R. G. Meireles, P. E. M. Almeida, M. G. Simões, A Comprehensive Review for Industrial Applicability of Artificial Neural Networks, **IEEE Transactions on Industrial Electronics**, 50(2003), 585-601.
- [3] T. Kohonen, The Self-Organizing Map, **Proceedings of the IEEE**, 78(1990), 1464-1480.
- [4] J. Vesanto, J. Himberg, E. Alhoniemi, J. Parhankangas, Self-organizing map in Matlab: the SOM Toolbox, **Proceedings of the Matlab DSP Conference**, (1999), 35-40.
- [5] S. Haykin, Redes Neurais: Princípios e Prática, **Editores Bookman**, 2(2001), 483-519.
- [6] A. P. Braga, A. P. L. F. Carvalho, T. B. Ludermitz, Redes Neurais Artificiais: Teoria e Aplicações, **LTC Editora**, 2(2000), 98-111.
- [7] H. Kauppinen, O. Silvén, T. Piirainen, Self-Organizing Map Based User Interface for Visual Surface Inspection, **Proc. 11th Scandinavian Conference on Image Analysis**, (1999), 801-808.
- [8] W. A. L. Alves, S. A. Araújo, A. F. H. Librantz, Reconhecimento de Padrões de Texturas em Imagens Digitais Usando Uma Rede Neural Artificial Híbrida, **Revistas Científicas de América Latina y el Caribe, España y Portugal**, 4(2006), 325-332.
- [9] J. Iivarinen, R. Rautakorpi, J. Pakkanen, J. Rauhamaa, Content-Based Retrieval of Surface Defect Images with PicSOM, **International Journal of Fuzzy Systems**, 6(2004), 160-167.
- [10] M. Niskanen, H. Kauppinen, O. Silvén, Real-time Aspects of SOM-based Visual Surface Inspection, **Proc. SPIE**, 4664(2002), 123-134.
- [11] C. Grunditz, M. Walder, L. Spaanenburg, Constructing a Neural System for Surface Inspection, **IEEE International Joint Conference on Neural Networks**, 3(2004), 1881-1886.
- [12] S. Marinai, E. Marino, G. Soda, A comparison of clustering methods for word image indexing, **The 8th IAPR International Workshop on Document Analysis System**, (2008), 671-676.
- [13] J. M. Barbaho, A. D. D. Neto, J. A. F. Costa, M. L. A. Netto, Hierarchical SOM applied to image compression, **IEEE International Joint Conference on Neural Networks**, 1(2001), 442-447.