

SISTEMA DE CLASSIFICAÇÃO DE ANOMALIAS DE IMAGENS DE BARRAS DE AÇO

Letícia Pavesi Crea-Jr, UEPG, mor_tycia@yahoo.com.br
Marcelo dos Reis Mansano, UEPG, marcelormansano@yahoo.com.br
Maria Salete Marcon Gomes Vaz, UEPG e UFPR, salete@uepg.br

Resumo: Para um produto ser comercializado é necessário que ele atenda as especificações das normas. No processo de fabricação de barras de aço podem surgir más formações na constituição da liga, devido a problemas no resfriamento. Então, para atender as especificações é necessário um processo de controle de qualidade confiável e coerente. O presente artigo visa mostrar como é realizado o processo de análise da qualidade de barras de aço, a partir de imagens obtidas das barras. As imagens obtidas necessitam de um processamento para então serem liberadas para a utilização. Para tanto, um processo de classificação é realizado por uma Rede Neural. Há uma forte interação com o Banco de Dados para realização do processo, pois a análise das imagens das barras pelo sistema emite um parecer sobre sua qualidade, baseado nas imagens capturadas da barra.

Palavras-chave: Barras de aço, defeitos em aço, Sistema de automação.

CLASSIFICATION SYSTEM OF ABNORMALITIES ON STEEL BARS IMAGES

Abstract: To trade a product is necessary that the product fits some standards. In the process of makings steel bars some defects could appear in the alloy constitution due cooling problems. Then, to fit the standards a reliable and coherent quality control process is necessary. This article aims to show how the process of quality analyse of the steel bars is made, based on images of steel bars. The images need to be processed before beeing used. For that, a Neural Network makes a classification process. There is a strong interaction with the database to make the process because the system analysis of the images leads to the quality of the bar, based on the images taken of the bar.

Keywords: Steel bars, Steel flaws, Automation system.

1. INTRODUÇÃO

O aço é uma liga metálica que foi desenvolvida e vem sendo aprimorada para atender as necessidades específicas de determinadas aplicações, como construção civil, indústria automobilística, entre outras. Quando se comercializa um produto deve-se seguir determinadas normas e garantir que o produto final ofereça a segurança de que as propriedades e características especificadas sejam atendidas com segurança.

O objetivo deste trabalho foi criar de um sistema de detecção de anomalias em barras de aço, capaz de realizar funções estratégicas e de tomada de decisão, que se utiliza de dados fornecidos por um banco de dados.

2. PROCESSO DE CONTROLE DE QUALIDADE

Frequentemente, em itens mecânicos, as anomalias se localizam na região superficial das peças (SILVA E MEI, 2006), por isso são controlados os dois tipos de defeitos mais comuns na indústria de barras de aço, a trinca e a dobra.

A trinca e a dobra são defeitos longitudinais superficiais em barras de aço redondas. Ambos se distinguem pelo formato, pois a trinca possui forma regular, mas reta. Já a dobra tem sua forma irregular.

Ensaio são utilizados para a comprovação da qualidade de barras de aço, constatando se há falhas e defeitos em sua superfície. Dos ensaios que podem ser realizados, a técnica de líquido penetrante (SILVA E MEI, 2006) é o que se pretende aprimorar. Nesse ensaio uma barra fabricada é submersa num líquido, que tem a função de aderir à sua superfície, incluindo a penetração em qualquer ranhura existente. Então, o excesso de líquido é removido e a barra é exposta a uma iluminação específica. Essa iluminação tem a finalidade de refletir-se somente no líquido penetrante e destacar as regiões onde ele ainda se encontra aderido.

Como os defeitos são superficiais, as áreas danificadas refletem o líquido com maior intensidade e apresentam um formato característico. O ensaio ainda necessita que uma pessoa, dotada de conhecimento específico e experiência, analise a reflexão da iluminação nas barras, por meio da visualização. Ela terá que classificar a barra, como dotada ou não de defeito, e ainda decidir se o material deve ser descartado.

Para o aprimoramento do ensaio, quando a barra é exposta a iluminação é fotografada e a imagem é armazenada. O auxílio ocorre quando a imagem inserida é analisada e se algum defeito é encontrado, há uma notificação por parte do sistema, ao operador. É necessário ao funcionamento desse sistema: (i) um método de processamento para as imagens obtidas; (ii) um banco de dados para armazenar todos os dados envolvidos no processo; (iii) o desenvolvimento de um método para criar *conhecimento* para inserir na Rede Neural Artificial, nomeado de *Rotulador*; e (iv) uma Rede Neural Artificial que faça a análise das imagens e sua classificação.

3. MATERIAIS E MÉTODOS

Segundo GONZALES e WOODS (2000), o processamento de imagens digitais envolve procedimentos que são geralmente expressos em forma algorítmica. Assim, com exceção da aquisição e exibição de imagens, a maioria das funções de processamento de imagens pode ser implementada em software. Então, as imagens utilizadas precisam sofrer um processamento para alimentar uma Rede Neural que classifique de forma apropriada uma imagem inserida.

Como o processamento de imagens é caracterizado por solucionar problemas específicos, para se chegar a um método de classificação apropriado foram considerados os métodos de equalização de histograma, conversão para escala de cinza, subdivisão entre os canais RGB e os canais HSI. Também foi levantada a possibilidade de retirar da imagem somente a porção que continha a barra e ignorar a parte que continha o fundo no arquivo.

Para equalização de histograma foi utilizada uma imagem RGB, onde cada plano sofreu uma equalização de seus valores de intensidade. O resultado obtido quando se submete uma imagem e esse processo é uma imagem com suas características realçadas, que nem sempre resultarão em uma imagem que atenda as necessidades do problema.

O método de escala de cinza converte uma imagem digital colorida em uma imagem monocromática de níveis de cinza. Cada pixel da imagem possui um valor, então em uma única amostra de um espaço de cores o seu valor é convertido em uma escala que possui como extremos a cor preta e a branca. Uma imagem em escala de cinza é diferente de uma imagem binária, ou seja, cada pixel contém apenas a cor preta ou branca.

As imagens em escala de cinza resultam do cálculo da intensidade da luz em cada pixel, em cada faixa do espectro eletromagnético. Cada pixel de uma imagem com essa característica, possui oito bits (um byte), o que permite 256 intensidades possíveis.

Uma imagem RGB tem como informação armazenada em cada pixel três valores que correspondem aos componentes espectrais primários Vermelho (Red), Verde (Green) e ao Azul (Blue). Uma imagem nesse formato é constituída de três planos de imagem independentes. Se os canais da imagem são divididos, são geradas três imagens em escala de cinza, uma para cada cor, que contém o valor correspondente a aquela cor.

Numa imagem, a matiz é o atributo que descreve uma cor pura, já a saturação mostra quanto está essa cor pura diluída na luz branca. Os canais HSI, onde H representa a matiz ou cor, S a saturação e I a intensidade luminosa, pode-se analisar em separado como essas três características influem na composição da imagem colorida. Esses critérios são bastante úteis quando se utiliza o processamento de imagens.

O modelo de rede neural empregado foi o Mapa Auto-Organizável (SOM – Self-Organizing Maps), ou mapa de Kohonen. Nesse modelo os neurônios são distribuídos sobre uma grade e então são inseridas várias entradas na rede. Os neurônios alteram sua localização na grade, para que a reorganização da topologia corresponda a uma característica do padrão e após o treinamento seja formada uma topologia que contenha as classes encontradas nas entradas inseridas.

O processo de treinamento ou ensinamento de um novo SOM deverá ser precedido da rotulação de uma imagem que contenha uma das falhas (trinca ou dobra). Para isso, uma interface ao cliente será proposta, onde uma imagem, depois de carregada, será subdividida em partes menores. Cada subdivisão será rotulada inicialmente como pertencendo ao fundo da imagem, depois as que contiverem porções defeituosas, do tipo “trinca” ou “dobra”, serão assim rotuladas, já as subdivisões que contiverem somente porções de barra serão rotuladas como sendo “barra”. Ao fim deste procedimento será criado um arquivo de rótulos, referente a uma imagem.

Os mapas auto-organizáveis de Kohonen fazem parte de um grupo de Redes Neurais chamado de redes baseadas em modelos de competição, ou simplesmente redes competitivas segundo FAUSETT (1994). A saída da Rede Neural não é uma série de neurônios, como ocorre na maioria dos modelos. Sua saída corresponde apenas ao neurônio vencedor, que será detalhado posteriormente.

De todas as diferenças e características detalhadas, a mais significativa para sua escolha na realização desse trabalho é que o *Mapa de Kohonen* possui o aprendizado não supervisionado. Possuir um aprendizado não supervisionado significa que quando é realizado o treinamento da Rede Neural Artificial são inseridas as entradas e a saída é calculada pela própria Rede, sem qualquer orientação do que ela deveria responder.

O principal objetivo de se utilizar Mapas Auto-Organizáveis é agrupar os dados de entrada que são semelhantes e formar classes ou agrupamentos denominados *clusters*, e que representam um padrão encontrado nos dados.

Quando se utiliza essa Rede como classificadora, há uma unidade de entrada para cada componente do vetor de entradas. Cada unidade de saída representa um *cluster*, o que limita a quantidade de *clusters* ao número de saídas. Durante o treinamento a rede determina a unidade de saída que melhor responde ao vetor de entrada.

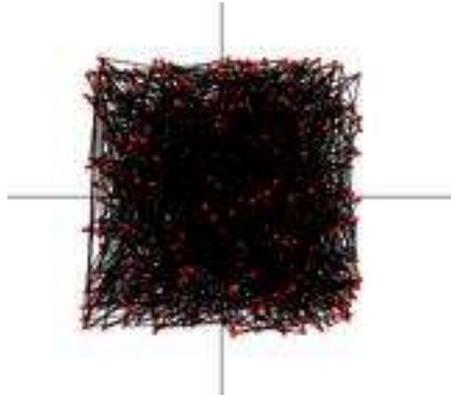


Figura 1: Configuração inicial de um Mapa Auto-Organizável

Durante o processo de auto-organização do mapa (Figura 1), a unidade que possuir vetor com pesos que mais se aproximem dos pesos do vetor dos padrões de entrada, a unidade é escolhida como sendo a “vencedora”. A unidade vencedora e suas unidades vizinhas têm seus pesos atualizados.

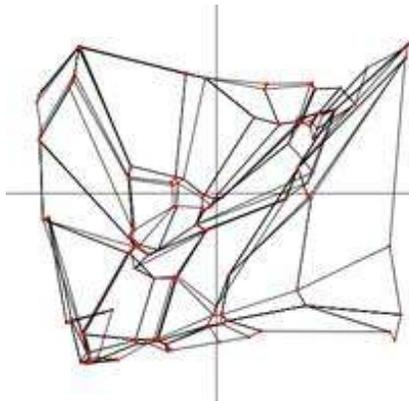


Figura 2: Como a rede se organiza

No treinamento a rede calcula o grau de similaridade para cada unidade na camada que compete. Esse valor quantifica quanto os pesos das unidades se assemelham ao do valor de entrada, e é a *distância Euclidiana* entre os vetores de entrada e cada neurônio da camada competitiva. Ao fim do processo de treinamento a configuração do mapa é alterada e se obtém os padrões inseridos (Figura 2).

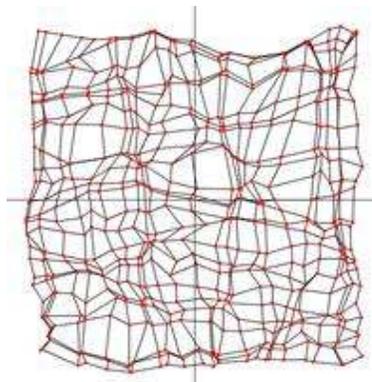


Figura 3: Após inserção de mais padrões

Para a realização do processo de organização (Figura 3) alguns parâmetros devem ser ajustados, como a taxa de aprendizagem, que assume valor inicial inferior a 1 e decai com o tempo até um valor próximo de zero. Também há a função de Vizinhança, que deve assumir um valor pré-fixado. Ele precisa ser instanciado previamente e maximizar a qualidade da organização do mapa.

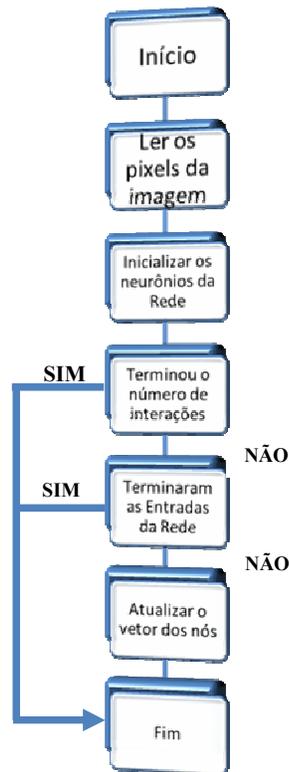


Figura 4: Fluxograma do algoritmo de treinamento da Rede Neural

Para ilustrar melhor o funcionamento do treinamento da Rede Neural, o algoritmo (Figura 4) mostra os passos a serem seguidos pelo programa para que a Rede Neural seja treinada.

4. RESULTADOS OBTIDOS

Para que se faça a correta análise das imagens e extração de suas características, foram realizados testes com imagens com seu histograma equalizado, imagens convertidas em escala de cinza, canais RGB (Red Green Blue – Vermelho Verde Azul) e canais HSI (Hue Saturation Intensity - Cor, Saturação, Intensidade).

Dos tipos de processamentos de imagens testados nas imagens, o pior resultado obtido foi na utilização das imagens em escala de cinza, pois não foram obtidas boas características para inserção no classificador. Somente a informação do valor das cores, convertidos em uma faixa monocromática de cores, não destaca os defeitos e causa confusões nas identificações.

Já os melhores resultados obtidos, dentre os processos descritos, foi a divisão das imagens em canais HSI, onde a intensidade isolada num canal fornecia melhores parâmetros para inserir

na Rede para um treinamento mais preciso e eficiente. E ainda o quanto a cor e a saturação influem na visão humana e na maneira como a imagem é vista tornam nessa forma de processamento a melhor dentre as consideradas.

Assim, os resultados implicam na escolha do método de subdivisão das imagens, no levantamento de metadados das imagens, como o tamanho da imagem e se já foi utilizada previamente, além dos metadados da barra a qual a imagem pertence. Ainda, a extração e armazenamento de parâmetros para configuração da rede, que se encontra em implementação. Um simulador auxilia no desenvolvimento de rede neural para que os parâmetros possam trazer os melhores resultados.

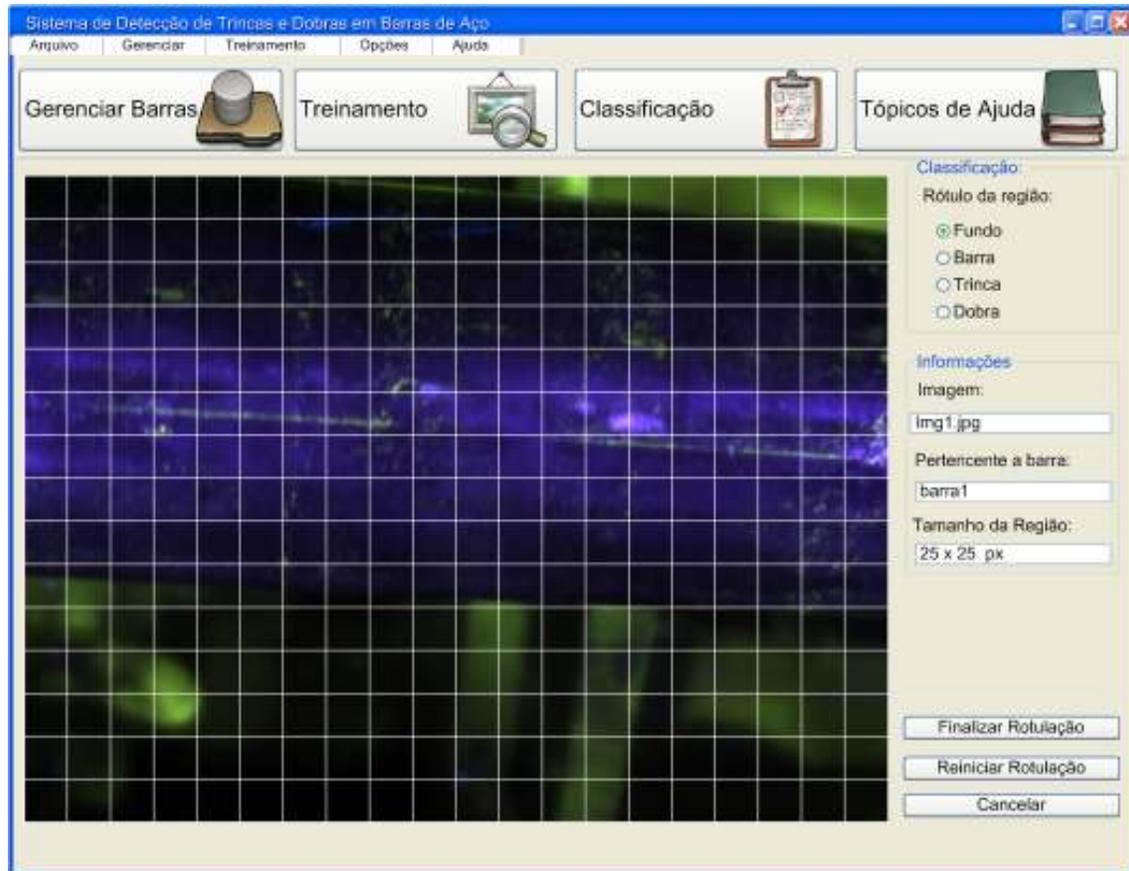


Figura 5: Imagem que mostra o processo de rotulação

Na Figura 5 pode-se observar uma imagem nos canais RGB sendo rotulada. Cada região tem que receber um dos rótulos Fundo, Trinca, Dobra ou Barra, localizados no canto superior direito, juntamente com algumas informações pertinentes a imagem escolhida.

5. CONCLUSÕES

O desenvolvimento e implementação desse Sistema de detecção de Anomalias em barras de aço se mostraram uma solução para minimizar o erro gerado quando um humano realiza o processo de classificação, devido à complexidade e repetitividade das atividades a serem realizadas.

A opção desse tipo de Rede Neural Artificial foi realizada baseada em implementações que vem sendo documentadas e dos resultados que estão sendo obtidos com imagens de testes. E ainda existe a característica de treinamento não supervisionado, que reduz o tempo de desenvolvimento do classificador, pois o tempo de treinamento da Rede Neural é menor.

REFERÊNCIAS

HAYKIN, S. *Redes neurais: princípios e práticas*. 2ª Ed. Porto Alegre: Bookman, 2001.

PINO, M.A.P. DEL. *A Theoretical & Practical Introduction to Self Organization using JNNS*, Disponível em: < http://ots.fh-brandenburg.de/downloads/studienarbeiten/sa_miguel_angel_del_perez_jnns.pdf >. Acesso em: 15 jun. 2009.

GONZALES, R.; WOODS, R. E. *Processamento De Imagens Digitais*. São Paulo. Edgard Blücher LTDA. 2000.

RICH, E.; KNIGHT, K. *Inteligência artificial*. 2ª Ed. São Paulo: Makron Books, 1993.

SILVA, A. L. V. S.; MEI, P. R. *Aços e ligas especiais*. São Paulo: Edgard Blücher, 2006.

CONSTRUÇÃO EM AÇO, CARACTERÍSTICAS. Disponível em: <<http://www.cbca-ibs.org.br/nsite/site/caracteristicas.asp>>. Acesso em: 02 abr. 2009.