



21-25
AGOSTO DE 2016
FORTALEZA - CEARÁ

CLASSIFICAÇÃO AUTOMÁTICA DO TIPO DE FERRO FUNDIDO UTILIZANDO RECONHECIMENTO DE PADRÕES EM IMAGENS DE MICROSCOPIA

Douglas de Araújo Rodrigues, douglas@lapisco.ifce.edu.br¹
Gesilane Pereira dos Santos, gesilane@lapisco.ifce.edu.br¹
Marcelo Correia Fernandes, marcelofernandes@lapisco.ifce.edu.br¹
José Ciro dos Santos, ciro@ifce.edu.br¹
Francisco Nélcio Costa Freitas, fneliocf@ifce.edu.br¹
Pedro Pedrosa Rebouças Filho, pedrosarf@ifce.edu.br¹

¹Instituto Federal de Educação, Ciência e Tecnologia do Ceará, Av. Parque Central, CEP 61939-140, Maracanaú - CE

Resumo: O presente trabalho propõe a utilização de técnicas de Inteligência Computacional Aplicada em conjunto com extratores de informações em imagens de metalografia. A finalidade deste projeto consiste em substituir a classificação manual de ferros fundidos pela automática. Os extratores de atributos analisados são a textura obtida pela matriz de co-ocorrência em tom de cinza, Local Binary Pattern, além dos momentos estatísticos, centrais e invariantes. Os classificadores avaliados são Bayes, Support Vector Machine (SVM), Multilayer Perceptron (MLP), K-nearest neighbors e k-means. As grafitas presentes em cada imagem foram extraídas através do método Contornos Conectados. Essas grafitas foram catalogadas como ferros fundidos nodular, maleável ou cinzento, totalizando 1700 amostras. Foram realizadas duas etapas para a análise. Na primeira foram consideradas as grafitas separadamente. Em uma segunda etapa, a imagem completa foi analisada considerando todas as grafitas extraídas da mesma, em que o tipo de objeto com maior incidência na análise seria o reconhecimento adotado para toda a amostra. Em ambas as etapas o método SVM obteve os melhores resultados no reconhecimento do tipo de ferro fundido. A partir dos resultados apresentados, conclui-se que a abordagem é promissora e pelos resultados, pode incorporar softwares comerciais para auxílio à especialistas na área.

Palavras-chave: Ferro fundido, Processamento Digital de Imagens, Reconhecimento de Padrões, Inteligência Computacional Aplicada.

1. INTRODUÇÃO

O desenvolvimento da indústria metalúrgica permitiu o surgimento de novas ligas e materiais de bastante relevância, permitindo o desenvolvimento tecnológico nos dias atuais. A aplicação final dos metais e suas ligas está diretamente relacionada às suas propriedades físicas, químicas e mecânicas. Dentre os diversos metais existentes, o ferro, combinado com outros materiais da liga, apresentam características que o tornam o metal mais importante da atualidade. Com uma diversidade de aplicações, tais como em peças automotivas (Pevéc *et al.*, 2014), em equipamentos de aquecimento de água (Jotshi *et al.*, 1996) e em carcaças de rolamentos de esferas de discos de moagem (Crisan *et al.*, 2008).

O ferro fundido é uma liga metálica amplamente utilizada no setor industrial por possibilitar uma extensa diversidade de aplicações. Isso se deve, principalmente, ao fato das propriedades mecânicas do material variarem de acordo com a composição do mesmo e ao tratamento térmico a qual é submetido.

Chiaverini (1982) define o ferro fundido como uma liga ferro-carbono-silício, de teores de carbono geralmente acima de 2,0%, em quantidade superior à que ser retida em solução sólida na austenita, de modo a resultar em carbono parcialmente livre.

O carbono presente na liga geralmente se apresenta na forma de grafita, que, por sua vez, possui formas variadas. Com base nessa diferenciação, William (2010) classifica o ferro fundido em diferentes tipos, entre eles se destacam os ferros fundidos cinzento, nodular e maleável.

O ferro fundido cinzento, no qual, o carbono presente encontra-se no formato de partículas laminares ou em veios, pode ser utilizado em fundições de motores a diesel, revestimentos e caixas de transmissão (William, 2010). O ferro




Figura 1: Amostras de Ferros Fundidos: a) cinzento; b) nodular ; c) maleável.

fundido nodular ou também conhecido como dúctil confere ao material características com alto módulo de elasticidade e resistência mecânica, e apresenta carbono livre na forma de grafita esferoidal (Feiste *et al.*, 2002). As aplicações típicas deste tipo de ferro são em corpos de válvula de bombas, engrenagens e cilindros. Já as aplicações do ferro fundido maleável estão envolvidas nos serviços gerais de engenharia sob temperaturas normais e elevadas. As suas grafitas são apresentadas na forma de flocos ou vermicular (William, 2010).

As características inerentes à cada tipo desse material exigem uma classificação minuciosa e coerente com a realidade, para que não haja nenhum equívoco em seu uso, seja ele industrial ou laboratorial. Os processos manuais de análise de propriedades micrográficas de estruturas metálicas são, por vezes, bastante complexos. O trabalho realizado por especialistas na caracterização de uma amostra, requer do profissional uma rígida e demorada análise visual. Deste modo, é evidente que tais processos estão sujeitos a diversas limitações inerentes às condições humanas.

A automatização do processo convencional de análise das grafitas que compõem os ferros fundidos visa uma considerável diminuição de erros provenientes da manipulação do homem na amostra, além de otimizar o tempo gasto na realização de sua classificação.

Neste contexto, surgiram trabalhos que permitem auxiliar os profissionais e estudantes da área de Ciências dos Materiais a classificar de forma automática os ferros fundidos. Dentre estes, vale destacar os trabalhos de Gomes and Paciornik (2005) e Pattan *et al.* (2010). O trabalho de Gomes and Paciornik (2005), apresenta um método automático para classificar a forma de partículas de grafita nos ferros fundidos. Este método identifica o material a partir da análise da média do ângulo interno das grafitas. Já o trabalho de Pattan *et al.* (2010), propõe uma abordagem com rede neural para realizar a classificação do ferro fundido com base na morfologia dos grãos de grafita processando as imagens da microestrutura.

O presente trabalho propõe a utilização de técnicas de Inteligência Computacional Aplicada e Reconhecimento de Padrões na análise digital de imagens micrográficas, destinadas a classificação e caracterização de ferros fundidos. O objetivo é automatizar o processo de análise, reduzindo de forma apreciável, o tempo necessário e a possibilidade de falhas no resultado da interpretação.

2. PROCESSAMENTO DIGITAL DE IMAGENS

Nesta seção, iremos explicar as etapas de segmentação dos objetos em cada imagem e os atributos extraídos destes objetos para posterior classificação.

2.1 Segmentação

Um sistema de Visão Computacional (VC) é geralmente constituído pelas etapas de aquisição das imagens, pré-processamento, segmentação, extração de atributos e reconhecimento de objetos. A segmentação é a etapa responsável por dividir a imagem em regiões de interesse, tendo fundamental importância em um sistema de VC, em que o desempenho deste sistema depende essencialmente da qualidade desta etapa (Aguado Alberto and Nixon Mark, 2002).

De modo geral, existem duas categorias de métodos de segmentação que se diferenciam, sobretudo, pela propriedade em que se baseiam. São estes os métodos de segmentação por descontinuidade e por similaridade. A primeira categoria realiza a divisão da imagem com base na detecção de mudanças bruscas entre pixels vizinhos na imagem, e são responsáveis pela detecção de pontos, linhas e bordas. A segmentação por similaridade baseia-se na separação de objetos por possuírem valores próximos de uma dada característica preestabelecida (Gonzalez and Woods, 2008).

Para se obter um desempenho desejável na segmentação, alguns métodos, ou combinações entre eles, são bastante aplicados. Neste trabalho, foi utilizado o método de Contornos Conectados, que utiliza conceitos de segmentação por descontinuidade.

Na segmentação por meio do método de Contornos Conectados, inicialmente é necessária a aplicação do gradiente detector de bordas Canny na imagem trabalhada em níveis de cinza. Este detector apresenta as posições das descontinuidades de intensidade controlada que representam as bordas detectadas (Canny, 1986). Essas posições são alocadas em um vetor bidimensional (Gomes *et al.*, 2015). A partir daí, é realizada uma análise de busca desses vetores. Esta verificação tem por objetivo encontrar, no sentido horário, o próximo pixel vizinho conectado. Este processo se repete até que não existam mais pixels vizinhos a este ou até o último pixel analisado esteja conectado ao pixel inicial, como notado na Fig. 2. Após este processo é efetuado uma aproximação poligonal, que consiste na alocação em um novo vetor de elementos presentes na invariação do contorno.

A atuação desta técnica para a segmentação da grafita é realizada de acordo com a apresentação da Fig. 3.




Figura 2: Ilustração da aplicação do método Contornos Conectados: a) imagem de entrada; b) imagem com primeiro ponto encontrado em preto; c) imagem com o segundo ponto encontrado em vermelho; d) processo intermediário; e) resultado final.




Figura 3: Aplicação do método Contornos Conectados na grafita.

2.2 Métodos de extração de características

Essa etapa visa extrair as características da região de interesse das imagens resultantes do processo de segmentação. Estas imagens são representadas numericamente de modo a facilitar a aplicação do processo seguinte, que corresponde a classificação por meio da aprendizagem de máquinas. Os métodos de extração usados neste trabalho são descritos abaixo.

Os Momentos Centrais são provenientes da redução dos Momentos Espaciais com o centro de gravidade do objeto. Desde modo, os Momentos Centrais referem-se ao centro de gravidade do objeto. Este método apresenta a vantagem de invariância à translação, o que torna possível a descrição da forma do objeto (Czachorski *et al.*, 2011).

Nos Momentos Estatísticos a extração de atributos é realizada a partir da distribuição na imagem em níveis de cinza que, são usualmente calculadas com base no histograma. Desde modo, essas características possibilitam a descrição estatística da relação entre os níveis de cinza (Gonzalez and Woods, 2008; Hu, 1962).

O reconhecimento independentemente da posição, tamanho e orientação é o princípio dos Momentos de Hu, também denominados de Momentos Invariantes. Hu (1962) apresentou em sua teoria, uma possibilidade capaz de realizar a descrição de figuras geométricas planas com base nos momentos invariantes bidimensionais (Flusser *et al.*, 2015; Licciardi *et al.*, 2012; Yang *et al.*, 2011).

Haralick (1979) apresentou um método para descrever as texturas baseando-se em estatísticas de segunda ordem. Os recursos decorrentes de cálculos de matrizes de co-ocorrência são definidos no lugar de uma imagem em determinado sentido. Estas matrizes consistem em uma contagem da quantificação de combinações diferentes de níveis de cinza e são fundamentais, pois elas são a base para a preparação de várias medidas estatísticas conhecidas como descritores Haralick (Haralick *et al.*, 1973; Ramalho *et al.*, 2014; Neto *et al.*, 2015).

Outro método que objetiva realizar a descrição de texturas é o operador LBP (Library Binary Pattern). Este tem como fundamentação atribuir um rótulo para cada pixel da imagem a partir de uma limiarização adaptativa local, obtendo como resultado um número binário para cada pixel. Sendo assim, o histograma está pronto para a descrição da textura. A princípio, utilizava-se o kernel 3x3 para a realização da limiarização. Com a necessidade da descrição de texturas de escalas diversas fez necessário que o operador LBP trabalhasse com diferentes kernels (Ojala *et al.*, 2002).

3. RECONHECIMENTO DE PADRÕES

Nesta seção, há a definição das cinco técnicas de reconhecimento de padrões usadas neste trabalho.

3.1 Reconhecimento de Padrões usando os K-Nearest Neighbors

O algoritmo do método de aprendizado K-Nearest Neighbors (KNN) analisa os padrões que estão vizinhos um dos outros no espaço das características e conclui que estes pertencem ao mesmo conjunto padrão. Deste modo, os objetos que possuem características semelhantes pertencem ao mesmo grupo. Essa análise pode considerar uma faixa de um até k vizinhos. Sendo que cada vizinho indica uma classe. Quando a observação com um número de vizinhos é superior a 1, há para cada ponto de teste a previsão de diferentes valores. Estas previsões são efetuadas de forma diferente em problemas de classificação e de regressão (Faceli *et al.*, 2011). Desde modo, tem por finalidade a classificação do ponto de teste.

Em problemas de classificação, em que a classe assume valores em conjuntos discretos, a maioria das classes que foram votadas por cada vizinho é adotado para classificar o ponto de teste. Quando se apresenta problemas de regressão, na qual os conjuntos se apresentam de forma contínua, as previsões do KNN são baseadas em uma média ou na mediana dos resultados nos k vizinhos mais próximos.

3.2 Reconhecimento de Padrões usando o K-Means

Frequentemente, o K-Means é utilizado para a descoberta de agrupamentos de dados, porém, pode ser adaptado para aplicações em classificação de padrões. O algoritmo K-Means particiona um conjunto de dados em k agrupamentos, de maneira que cada um possua um centróide (Bishop, 2006). Este conjunto de centróides são os vetores que representam o conjunto de dados. Assim um conjunto de dados pode ser compactado para este conjunto de k vetores.

Inicialmente é realizado um treinamento não-supervisionado, da qual, posteriormente, os padrões são associados aos centróides mais próximos, de tal maneira que ao final deste processo estão associados k padrões a um determinado centróide. Em seguida, cada centróide recebe o rótulo da classe com mais ocorrências dentre os seus k padrões associados. Quando um exemplo não visto é apresentado, o K-Means verifica qual o centróide mais próximo e então atribui a esta amostra o rótulo deste centróide.

3.3 Reconhecimento de Padrões usando o Classificador Bayes

O classificador Bayes utiliza uma abordagem em fundamentos estatísticos e categoriza um objeto com base na probabilidade deste pertencer a uma dada classe. O classificador calcula as probabilidades de um objeto pertencer a uma das classes possíveis, determinando para este, a classe que obteve a maior dessas probabilidades, isto é, a classe mais provável.

O teorema de decisão Bayesiano faz uso da probabilidade de vários objetos que pertencerem a mesma classe $P(C_i, X)$ por meio da probabilidade condicional, da probabilidade a priori da classe $P(C_i)$ que é obtida a partir do número de objetos i de cada classe em relação ao número total de objeto, e a probabilidade de ocorrência desses objetos $P(X)$ (Mitchell, 1997). Esta teoria é descrita na Fórmula de Bayes em Eq. (1). A partir desta fórmula, modifica-se a probabilidade a priori tendo em vistas novas evidências de forma a obter probabilidades a posteriori.

$$P(C_i|X) = \frac{P(X|C_i)P(C_i)}{P(X)} \quad (1)$$

3.4 Reconhecimento de Padrões usando Support Vector Machine

Com base na Teoria de Aprendizado Estatístico (Vapnik, 1999) que também é conhecida como a Teoria de Vapnik-Chervonenkis (VC), as Máquinas de Vetores de Suporte (SVMs) são utilizadas para a classificação e análise de regressão. Embasadas no princípio da minimização do risco estrutural, o processo de otimização do SVM visa determinar uma função que separa durante a realização do trade-off o que existe entre generalização e sobreajuste.

Um aspecto comum do SVM consiste em uma formulação que destina a resolução de problemas binários. Apesar de o SVM ter sido formulado para problemas com duas classes, o mesmo possui abordagens para resolver problemas de multiclass (Crammer and Singer, 2001). As abordagens de um-contrá-um e um-contrá-todos Duan and Keerthi (2005) são aqueles amplamente utilizadas. Em problemas que apresentam exemplos não linearmente separáveis, o artifício do kernel é usado para gerar versões não-lineares do classificador SVM linear padrão. O kernel representa um produto de ponto no espaço de recurso em que o vetores originais são mapeados.

3.5 Reconhecimento de Padrões usando o Multi-layer perceptron (MLP)

O Multi-layer Perceptron (MLP) consiste em camadas de Rede Neural de Multicamadas que visam resolver problemas cujos padrões não são linearmente separáveis. As estruturas que compõem essa Rede são normalmente subdivididas em camada de entrada de rede, uma ou mais camadas ocultas e uma camada de saída (Ruck *et al.*, 1990; Nissen, 2003; Haykin, 2008).

Esse método busca resolver problemas cujos padrões não são linearmente separáveis (Minsky and Papert, 1969). Estas redes estão divididas em duas etapas: treinamento e teste. A primeira etapa consiste no treinamento, na qual os pesos sinápticos são ajustados através de um algoritmo de treinamento da rede. Este algoritmo tem por finalidade treinar a rede de forma que se possa separar as classes apresentadas e, consequentemente, obter saídas desejadas (Haykin, 2008;

de Sá Medeiros, 2008). A etapa de teste consiste no reconhecimento de padrões apresentados à rede que não estavam no conjunto de treinamento.

4. METODOLOGIA

Nesta secção é descrita a abordagem proposta neste trabalho para identificação e reconhecimento de grafitas de forma automática em imagens metalográficas. O processo adotado desde a aquisição até o reconhecimento de ferro fundido em uma amostra é apresentado no fluxograma da Figura 4. O primeiro passo é realizar a aquisição da imagem em microscópio óptico após análise metalográfica. A imagem de entrada será separada em subregiões contendo apenas um objeto de ferro fundido isolado resultado do processo de segmentação da grafita. Estes ferros fundidos individuais passarão pela etapa de extração de atributos que será usados para reconhecer os o tipo de ferro fundido na etapa seguinte. A análise destes objetos individuais permite que nós possamos reconhecer cada amostra individualmente. Para reconhecer uma amostra com vários objetos, reconhecemos todos os objetos individualmente nesta imagem, sendo esta etapa chamada de "teste de campo" neste trabalho. O tipo de grafita que aparecer mais em uma amostra define a classificação adotada para toda amostra. Esta análise faz com que imperfeições na amostra não causem danos na classificação, onde objetos podem estar presente devido a inclusões no material e até mesmo por falhas na preparação na amostra.




Figura 4: Fluxograma da metodologia adotada para as duas etapas de resultados.

4.1 Aquisição das imagens

As imagens usadas neste trabalho foram adquiridas por meio de um microscópio óptico metalográfico, este procedimento foi realizado por especialistas no Laboratório de Materiais para Construção Mecânica do Instituto Federal do Ceará.

Inicialmente, foram obtidas amostras dos ferros fundidos cinzento, maleável e nodular. Estas amostras foram cortadas em porções aproximadas para análise, em seguida, houve o embutimento para facilitar o melhor manuseio nas etapas posteriores da metalografia. Foram realizados procedimentos com o objetivo de se retirar imperfeições mais profundas na superfície do material e a deixá-la com uma superfície polida isenta de marcas.

Durante esse processo foi necessário certificar-se, principalmente, das condições de iluminação e da preparação das amostras, pois, pode facilitar os procedimentos efetuados posteriormente.

4.2 Reconhecimento das grafitas individualmente

O processo de segmentação das grafitas foi realizado utilizando o método de segmentação por descontinuidade pela detecção de bordas do objeto, para isso se fez uso do operador gradiente Canny. Em seguida, o método Contornos Conectados foi aplicado nas imagens com a utilização de uma matriz de busca de ordem 3. Para os contornos dos objetos ficarem melhores delimitados, foi empregado uma aproximação poligonal.

Cada grafita segmentada foi previamente submetida a uma filtragem de acordo com a sua área, com a finalidade de reduzir contornos inapropriados. As grafitas restantes, após essa verificação, foram catalogadas como amostras dos ferros fundidos cinzento, maleável e nodular. Os objetos detectados com imperfeição no preparo da amostra foram descartados. Desse modo, eliminando aquelas imagens que não atendiam pré-requisitos de uma grafita.

Posteriormente ao processo de segmentação, foram utilizados cinco extratores de atributos em cada grafita segmentada. Foram usados 14, 48, 7, 10 e 7 números de atributos gerados pelo método GLCM, LBP, Momentos Centrais, Estatísticos e de Hu, respectivamente.

As bases de dados aplicadas neste trabalho, foram obtidas usando 1700 grafitas de ferros fundidos dos três tipos trabalhados: cinzento, maleável e nodular. Em seguida, esses bancos gerados foram classificados usando os métodos de reconhecimento de padrões: KNN, SVM, MLP, Bayes e K-Means.

4.3 Reconhecimento da grafita por imagem

A etapa de aplicação do projeto foi realizada, primeiramente, a partir da obtenção das amostras de ferro fundido. Em seguida, é feita uma análise no microscópio ótico para averiguar se as imagens estão preparadas para serem submetidas ao sistema de classificação. Desde modo, verifica a iluminação e os resquícios da etapa de preparação do material na metalografia. Por fim, capturam-se as imagens das amostras utilizando uma câmera digital para que sejam submetidas ao sistema de classificação automatizada do tipo de ferro fundido.

A imagem que foi adquirida foi segmentada, sendo analisada considerando todos os objetos extraídos da mesma. Cada grafita é classificada entre ferro fundido nodular, maleável ou cinzento. O tipo de objeto com maior incidência na análise da imagem por completo é o reconhecimento adotado para toda a amostra.

5. RESULTADOS E DISCUSSÕES

Os resultados deste trabalho são apresentados particionados em duas etapas. Primeiramente, são mostrados os resultados obtidos pelos métodos da etapa de Reconhecimento de Padrões em que foram considerados cada objeto selecionado. Em seguida, são avaliados os resultados na qual a imagem completa foi analisada considerando todos os objetos extraídos da mesma, em que o tipo de objeto com maior incidência na análise seria o reconhecimento adotado para toda a amostra.

5.1 Resultados do reconhecimento da grafita individualmente

A validação cruzada visa obter um conjunto de dados e subdividi-los aleatoriamente em dois subconjuntos diferentes: um utilizado para o treinamento e outro para o teste deste treinamento. Este processo irá realizar a validação do conjunto de teste a partir da análise do conjunto separado para o treinamento. Para atenuar a variabilidade, várias iterações de validação cruzada são realizadas.

Com relação a partição dos dados gerais trabalhados obtidos durante a etapa de extração, foi usado o processo de validação cruzada Hold Out. Nessa validação, as amostras que foram destinadas para o conjunto de teste foram definidas aleatoriamente e os restantes das amostras que não foram escolhidas são determinadas para o treino. Neste presente trabalho foram usadas 5 iterações para o Hold Out, considerando 20,0% da amostra total de dados foram destinados ao conjunto de treino e 80,0% para o conjunto de teste.

Para a etapa do Reconhecimento de Padrões, o classificador Bayes utiliza a distribuição normal. No método KNN a análise foi de 1, 3 e 5 vizinhos mais próximos. No método SVM foram considerados os kernels linear, RBF, polinomial e sigmóide. O K-Means foi usado a configuração com três grupos.

Para a rede MLP foram usadas topologias diferentes para cada banco. Estas formatações foram determinadas avaliando com a configuração variando de 5 a 300 neurônios na camada oculta. Foram usados 25, 250, 90, 80, 35 neurônios nesta camada para os bancos Momentos de Hu, Momentos Estatísticos e Momentos Centrais, GLCM e LBP, respectivamente.

Com o intuito de validar os métodos de aprendizagem de máquinas, considerando as configurações utilizadas, é feito uma análise quantitativa dos resultados obtidos das métricas sensibilidade, sensibilidade, f-score e acurácia. A Tab. 1 resume os resultados das métricas, obtidos para cada um dos métodos de Reconhecimento de Padrão utilizando as configurações especificadas.

A partir da análise da Tab. 1, observamos que os extratores GLCM e LBP obtiveram os melhores resultados. Isto se deve ao fato destes serem obtidos a partir de extratores baseados na textura. Em contrapartida, o mesmo não ocorre com os extratores que se baseiam nas formas dos objetos, tais como Momentos de Hu, Centrais e Estatísticos.

Com base nos resultados apresentados na Tab. 1, constata-se que o classificador SVM obteve os melhores resultados com o extrator GLCM. Para este banco, o classificador apresentou os melhores valores de acurácia, utilizando o kernel linear. Ainda com base nestas observações, é possível verificar que o método KNN com uma análise dos cinco vizinhos mais próximos, também apresenta valores altos de acurácia.

A Tab. 2 apresenta a matriz confusão das combinações extrator classificador que obtiveram valores das métricas superiores a 90,0%. Essa matriz oferece uma medida eficaz do padrão de classificação, ao apresentar o número de grafitas classificadas corretamente e as classificações preditas para cada classe. Os resultados mais relevantes são aqueles presentes na diagonal principal da matriz confusão, no qual, representam o valor percentual das grafitas que foram classificadas corretamente. Os demais elementos, apresentam os valores percentuais de grafitas que foram incorretamente classificadas como pertencentes a uma determinada classe.

Analisando os resultados da Tab. 2, nota-se a precisão geral dos classificadores. De forma geral, os métodos avaliados possuem um número de classificações corretas relevante em relação ao número total de amostras trabalhadas. Realizando uma análise integral das matrizes confusões, nota-se que os métodos citados anteriormente, cujos resultados das métricas foram superiores a 90% para a acurácia, obtiveram excelentes percentuais de acertos quanto ao reconhecimento individual de cada classe. O método de maior destaque é o SVM com o kernel RBF, que pode ser analisado através da matriz confusão, na qual, os valores da diagonal principal apresentam os melhores resultados.

Tabela 1: Resultado das métricas obtidas por extração e classificação

Extrator	Classificador	Configuração	PPV (%)	Sens (%)	F-Score (%)	Acc (%)
GLCM	Bayes	Normal	64.4±0.29	64.4±0.29	64.4±0.30	68.9±0.30
	SVM	Linear	95.7±0.00	96.6±0.05	96.1±0.01	99.4±0.10
		RBF	96.0±0.12	96.7±0.12	96.7±0.12	97.8±0.44
		Polinomial	96.3±0.50	96.3±0.50	96.3±0.50	97.5±0.34
		Sigmoide	44.2±0.23	44.2±0.23	44.2±0.23	54.3±0.00
	MLP	Conf. 1	96.3±0.02	96.0±0.01	96.1±0.04	97.5±0.27
		Conf. 2	96.3±0.03	96.6±0.10	96.6±0.08	97.5±0.36
	KNN	N = 1	95.2±0.03	94.0±0.01	94.0±0.05	95.2±0.01
		N = 3	95.7±0.01	95.3±0.01	95.5±0.01	97.2±0.00
		N = 5	89.4±0.02	97.9±0.01	97.1±0.02	99.6±0.03
	K-means		66.9±0.00	63.2±0.00	65.0±0.00	75.2±0.00
LBP	Bayes	Normal	84.4±0.91	85.6±0.87	85.0±0.92	89.6±0.67
	SVM	Linear	88.0±0.11	87.1±0.09	87.5±0.12	91.7±0.79
		RBF	93.2±0.61	94.8±0.55	94.0±0.10	95.4±0.42
		Polinomial	92.0±0.33	95.3±0.18	93.6±0.40	94.5±0.23
		Sigmoide	44.2±0.00	40.2±0.01	42.1±0.00	54.3±0.00
	MLP	Conf. 1	86.7±0.70	83.4±0.85	85.0±0.60	90.8±0.52
		Conf. 2	87.0±0.71	86.9±0.72	86.9±0.58	91.0±0.52
	KNN	N = 1	90.0±0.05	92.0±0.00	90.7±0.01	91.9±0.02
		N = 3	90.4±0.14	91.3±0.10	90.8±0.09	93.3±0.10
		N = 5	90.7±0.02	91.0±0.10	90.8±0.04	93.6±0.31
	K-means		44.3±0.00	44.3±0.00	44.3±0.00	54.4±0.00
M. Centrais	Bayes	Normal	31.7±0.40	35.4±0.32	33.4±0.20	41.0±0.35
	SVM	Linear	67.2±0.09	67.2±0.09	67.2±0.09	70.0±0.10
		RBF	57.5±0.29	58.8±0.30	57.7±0.20	67.0±0.27
		Polinomial	57.8±0.16	57.8±0.19	57.8±0.16	67.3±0.15
		Sigmoide	56.9±0.00	58.0±0.00	57.4±0.00	66.4±0.00
	MLP	Conf. 1	59.8±0.36	59.0±0.40	59.4±0.32	69.4±0.32
		Conf. 2	60.6±0.24	61.3±0.32	60.9±0.24	69.0±0.21
	KNN	N = 1	45.9±0.09	46.0±0.02	45.0±0.05	50.1±0.02
		N = 3	45.2±0.77	48.0±0.50	46.6±0.55	55.3±0.77
		N = 5	51.9±1.05	50.8±0.89	51.3±0.90	60.8±1.00
	K-means		56.9±1.05	56.9±0.00	56.9±0.00	66.4±0.00
M. HU	Bayes	Normal	25.0±0.00	25.0±0.00	25.0±0.00	33.3±2.22
	SVM	Linear	56.9±0.00	56.8±0.00	56.8±0.00	66.4±0.00
		RBF	55.0±0.01	55.0±0.01	55.0±0.02	66.4±0.00
		Polinomial	56.8±0.10	56.8±0.02	56.8±0.12	66.4±0.11
		Sigmoide	56.9±0.00	59.0±0.00	57.9±0.01	66.4±0.00
	MLP	Conf. 1	57.6±0.50	57.3±0.60	57.4±0.45	67.1±0.54
		Conf. 2	57.3±1.23	57.0±1.16	57.1±1.20	66.8±1.12
	KNN	N = 1	37.0±0.01	40.0±0.02	34.0±0.04	49.0±0.07
		N = 3	37.3±0.50	37.3±0.54	37.3±0.04	47.8±0.57
		N = 5	41.0±0.72	40.7±0.70	40.8±0.67	50.7±0.74
	K-means		35.4±0.00	35.4±0.00	35.4±0.00	45.1±0.00
M. Estatísticos	Bayes	Normal	44.5±0.78	44.5±0.80	44.5±0.72	54.6±0.78
	SVM	Linear	61.0±3.19	62.0±2.20	61.5±3.00	70.1±2.77
		RBF	64.0±3.25	64.0±3.25	64.0±3.25	72.7±2.81
		Polinomial	62.9±5.04	62.5±5.00	62.7±5.01	71.7±4.45
		Sigmoide	57.7±0.61	57.9±0.60	57.8±0.59	66.7±0.55
	MLP	Conf. 1	73.7±1.35	73.8±1.40	73.7±1.67	86.7±1.63
		Conf. 2	74.5±0.58	74.9±0.57	74.7±0.55	81.4±0.46
	KNN	N = 1	55.4±0.02	56.7±0.03	53.9±0.03	58.8±0.02
		N = 3	55.5±0.47	55.5±0.47	55.5±0.47	65.1±0.43
		N = 5	50.6±0.38	51.0±0.40	50.8±0.40	60.6±0.36
	K-means		29.2±0.01	29.5±0.01	29.3±0.02	37.0±0.02

5.2 Resultados do reconhecimento de grafita por amostra

Os resultados são obtidos a partir das amostras de ferro fundido cinzento, maleável e nodular, em que todas são submetidas a um Teste em Campo, possibilitando uma verificação do reconhecimento automático do tipo de ferro fundido. Para todas as amostras foram utilizados os métodos de reconhecimento de padrões que alcançaram valores superiores a 90,0% nas métricas avaliadas durante o Teste Virtual.

São mostrados na Fig. 5 os resultados obtidos com a aplicação do Teste em Campo para as amostras dos ferros fundidos. Sendo que a classe 0, classe 1 e classe 2 correspondem a ferro fundido cinzento, maleável e nodular, respectivamente.

Tabela 2: Matrizes confusões do GLCM e LBP

GLCM												
	SVM Linear			SVM RBF			KNN Poly			MLP 1		
classe	0	1	2	0	1	2	0	1	2	0	1	2
0	17,74	0,25	0,06	17,75	0,31	0,00	1,00	35,22	0,88	18,34	7,20	1,20
1	1,23	35,31	0,50	1,15	35,17	0,57	1,00	35,22	0,88	0,73	35,18	1,07
2	0,43	0,81	43,67	0,50	0,90	43,66	0,38	0,73	43,23	0,32	0,66	43,07
	MLP 2			KNN 1			KNN 3			KNN 5		
classe	0	1	2	0	1	2	0	1	2	0	1	2
0	17,99	0,29	0,12	18,02	0,30	0,30	17,49	0,37	0,00	17,41	0,29	0,00
1	0,90	35,39	0,85	0,89	35,4	1,04	0,96	34,90	1,03	1,54	34,75	0,37
2	0,51	0,69	43,26	0,23	1,20	42,62	0,96	1,10	43,20	0,44	1,32	43,86

LBP												
	SVM Poly			SVM RBF			KNN 3			KNN 5		
classe	0	1	2	0	1	2	0	1	2	0	1	2
0	17,80	1,43	0,04	17,12	1,37	0,03	16,72	1,19	0,12	16,30	1,16	0,00
1	1,47	32,76	1,48	2,19	33,08	1,63	2,32	32,20	1,72	2,82	31,45	1,54
2	0,13	2,19	42,70	0,09	1,93	42,57	0,35	3,03	42,46	0,32	3,76	42,69

Nota-se que os resultados gerais dos gráficos da Fig. 5 apresentam valores superiores a 90,0%. Consta-se também que os resultados obtidos para as amostras de ferro fundido cinzento e nodular apresentam uma pequena superioridade com relação ao reconhecimento do ferro fundido maleável. Isto porque as grafias das amostras são visualmente mais bem definidos.

Analisando os resultados descritos na Fig. 5, percebe-se a eficácia do método SVM com o kernel para RBF. Este se destacou com o reconhecimento de cerca de 100,0% dos ferros fundidos do tipo cinzento, maleável e nodular no extrator GLCM. Já para o LBP, o mesmo teve um acerto de 100,0% para o cinzento e nodular, possuindo apenas uma falha na amostra do ferro fundido maleável.




Figura 5: resultado gerais do Teste em Campo utilizando os métodos de reconhecimento de padrão para o: a) GLCM; b) LBP.

6. CONCLUSÃO

Este trabalho propõe a utilização de técnicas de Inteligência Computacional Aplicada em conjunto com extratores de informações em imagens de metalografia para classificação automática dos tipos de ferros fundidos.

Em relação as tecnologias utilizadas para classificação dos objetos individualmente, o classificador SVM com kernel linear obteve os melhores resultados com $99,4 \pm 0,10$. Já para análise da amostra como um todo, o método SVM com kernel RBF obteve os melhores resultados no reconhecimento do tipo de ferro fundido, reconhecendo com um percentual de quase 100,0% os ferros fundidos maleável, cinzento e nodular.

A partir da análise dos resultados apresentados, podemos concluir que a abordagem é promissora, podendo incorporar softwares comerciais para auxílio à engenheiros, especialistas, estudantes e outros da área da Ciências dos Materiais. Para trabalhos futuros, pretende-se expandir este reconhecimento para outros tipos de ferros fundidos, como o ferro fundido branco. Além do uso de outros extratores e classificadores.

7. AGRADECIMENTOS

Os autores agradecem ao apoio financeiro do IFCE via editais de fomento PROAPP-IFCE de 2014, PAPEX/IFCE de 2015 e PROFEP/IFCE-Maracanaú de 2016.

8. REFERÊNCIAS

- Aguado Alberto, S. and Nixon Mark, S., 2002. *Feature extraction and image processing*. Newnes, Oxford.
- Bishop, C.M., 2006. "Pattern recognition".
- Canny, J., 1986. "A computational approach to edge detection". *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 8, No. 6, pp. 679–698. ISSN 0162-8828. doi: <http://doi.ieeecomputersociety.org/10.1109/TPAMI.1986.4767851>.
- Chiaverini, V., 1982. *Aços e Ferros Fundidos*, Vol. 5. Associação Brasileira de Metais – ABM.
- Crammer, K. and Singer, Y., 2001. "On the algorithmic implementation of multiclass kernel-based vector machines". *Journal of Machine Learning Research*, Vol. 2, pp. 265–292.
- Crisan, A., Munteanu, S.I., Ciobanu, L. and Riposan, I., 2008. "Optimization of the chemical composition of cast iron used for casting ball bearing grinding disks". *Tsinghua Science and Technology*, Vol. 13, No. 2, pp. 164–169. doi: 10.1016/S1007-0214(08)70029-4.
- Czachorski, T., Kozielski, S. and Stanczyk, U., 2011. *Man-Machine Interactions 2*. Advances in Intelligent and Soft Computing. Springer Berlin Heidelberg. ISBN 9783642231698.
- de Sá Medeiros, C.M., 2008. *Uma Contribuição ao problema de seleção de modelos neurais usando o princípio de máxima correlação dos erros*. Ph.D. thesis, Universidade Federal do Ceará.
- Duan, K.B. and Keerthi, S.S., 2005. "Which is the best multiclass svm method? an empirical study". In *Multiple classifier systems*, Springer, pp. 278–285.
- Faceli, K., Lorena, A.C., Gama, J. and Carvalho, A., 2011. "Inteligência artificial: Uma abordagem de aprendizado de máquina". *Livros Técnicos e Científicos*.
- Feiste, K., Reimche, W., BACH, F.W., Marques, P. and Rebello, J., 2002. "Caracterização das propriedades mecânicas de ferro fundido nodular por análise harmônica dos sinais das correntes parasitas". In *6ª Conferência sobre Tecnologia de Equipamentos*.
- Flusser, J., Suk, T., Boldys, J. and Zitova, B., 2015. "Projection operators and moment invariants to image blurring". *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, Vol. 37, No. 4, pp. 786–802. ISSN 0162-8828. doi:10.1109/TPAMI.2014.2353644.
- Gomes, O. and Paciornik, S., 2005. "Automatic classification of graphite in cast iron". *Microscopy and Microanalysis*, Vol. 11, No. 04, pp. 363–371.
- Gomes, S.L., Rebouc, P.P. et al., 2015. "Computer vision system to aid drivers of vehicles through vertical signaling traffic". *International Journal of Computer Applications*, Vol. 115, No. 5.
- Gonzalez, R.C. and Woods, R.E., 2008. *Digital image processing*. Prentice Hall, Upper Saddle River, N.J., 3rd edition. ISBN 9780131687288.
- Haralick, R., 1979. "Statistical and structural approaches to texture". *Proceedings of the IEEE*, Vol. 67, No. 5, pp. 786–804. ISSN 0018-9219. doi:10.1109/PROC.1979.11328.
- Haralick, R., Shanmugam, K. and Dinstein, I., 1973. "Textural features for image classification". *Systems, Man and Cybernetics, IEEE Transactions on*, Vol. SMC-3, No. 6, pp. 610–621. ISSN 0018-9472. doi: 10.1109/TSMC.1973.4309314.
- Haykin, S.O., 2008. *Neural Networks and Learning Machines*. Pearson Prentice Hall.
- Hu, M.K., 1962. "Visual pattern recognition by moment invariants". *Information Theory, IRE Transactions on*, Vol. 8, No. 2, pp. 179–187. ISSN 0096-1000. doi:10.1109/TIT.1962.1057692.
- Jotshi, C.K., Goswami, D.Y., Klausner, J.F., Hsieh, C.K., Leung, M., Li, H., Malakar, S. and Colacino, F., 1996. "Heat transfer characteristics of a high temperature sensible heat storage water heater using cast iron as a storage material". In *Energy Conversion Engineering Conference, 1996. IECEC 96., Proceedings of the 31st Intersociety*. Vol. 3, pp. 2099–2103 vol.3. ISSN 1089-3547. doi:10.1109/IECEC.1996.553454.
- Licciardi, G., Villa, A., Dalla Mura, M., Bruzzone, L., Chanussot, J. and Benediktsson, J., 2012. "Retrieval of the height of buildings from worldview-2 multi-angular imagery using attribute filters and geometric invariant moments". *Selected Topics in Applied Earth Observations and Remote Sensing, IEEE Journal of*, Vol. 5, No. 1, pp. 71–79. ISSN 1939-1404. doi:10.1109/JSTARS.2012.2184269.
- Minsky, M. and Papert, S., 1969. *Perceptrons*. M.I.T Press.
- Mitchell, T.M., 1997. *Machine Learning*. McGraw-Hill, Inc., New York, NY, USA, 1st edition. ISBN 0070428077, 9780070428072.
- Neto, E.C., Cortez, P., Cavalcante, T., da Silva Filho, V., Rebouças Filho, P. and Holanda, M., 2015. "Supervised enhancement filter applied to fissure detection". In *VI Latin American Congress on Biomedical Engineering CLAIB 2014, Paraná, Argentina 29, 30 & 31 October 2014*. Springer, pp. 337–340.
- Nissen, S., 2003. *Implementation of a Fast Artificial Neural Network Library (FANN)*. Department of Computer Science University of Copenhagen (DIKU). Software available at <http://leenissen.dk/fann/>.

- Ojala, T., Pietikainen, M. and Maenpaa, T., 2002. "Multiresolution gray-scale and rotation invariant texture classification with local binary patterns". *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, Vol. 24, No. 7, pp. 971–987. ISSN 0162-8828. doi:10.1109/TPAMI.2002.1017623.
- Pattan, P.C., Mytri, V. and Hiremath, P., 2010. "Classification of cast iron based on graphite grain morphology using neural network approach". In *Second International Conference on Digital Image Processing*. International Society for Optics and Photonics, pp. 75462S–75462S.
- Pevec, M., Oder, G., Potrč, I. and Šraml, M., 2014. "Elevated temperature low cycle fatigue of grey cast iron used for automotive brake discs". *Engineering Failure Analysis*, Vol. 42, pp. 221 – 230. ISSN 1350-6307. doi:http://dx.doi.org/10.1016/j.engfailanal.2014.03.021. URL <http://www.sciencedirect.com/science/article/pii/S135063071400106X>.
- Ramalho, G.L.B., Rebouças Filho, P.P., Medeiros, F.N.S.d. and Cortez, P.C., 2014. "Lung disease detection using feature extraction and extreme learning machine". *Revista Brasileira de Engenharia Biomédica*, Vol. 30, No. 3, pp. 207–214.
- Ruck, D.W., Rogers, S.K., Kabrisky, M., Oxley, M.E. and Suter, B.W., 1990. "The multilayer perceptron as an approximation to a bayes optimal discriminant function". *IEEE Transactions on Neural Networks*, Vol. 1.
- Vapnik, V.N., 1999. "An Overview of Statistical Learning Theory". *IEEE Transactions on Neural Networks*, Vol. 10, No. 5, pp. 988–999.
- William, D.; Callister, J.R.D., 2010. *Materials Science and Engineering: An Introduction*. John Wiley and Sons Ltd., NJ, USA, 8th edition.
- Yang, J., Xiong, N., Vasilakos, A., Fang, Z., Park, D., Xu, X., Yoon, S., Xie, S. and Yang, Y., 2011. "A fingerprint recognition scheme based on assembling invariant moments for cloud computing communications". *Systems Journal, IEEE*, Vol. 5, No. 4, pp. 574–583. ISSN 1932-8184. doi:10.1109/JSYST.2011.2165600.

9. RESPONSABILIDADE AUTORAIS

Os autores são os únicos responsáveis pelo conteúdo deste trabalho.

AUTOMATIC CLASSIFICATION OF TYPE OF CAST IRON USING PATTERN RECOGNITION IN MICROSCOPY IMAGES

Douglas de Araújo Rodrigues, douglas@lapisco.ifce.edu.br¹

Gesilane Pereira dos Santos, gesilane@lapisco.ifce.edu.br¹

Marcelo Correia Fernandes, marcelofernandes@lapisco.ifce.edu.br¹

José Ciro dos Santos, ciro@ifce.edu.br¹

Francisco Nélito Costa Freitas, fneliof@ifce.edu.br¹

Pedro Pedrosa Rebouças Filho, pedrosarf@ifce.edu.br¹

¹Instituto Federal de Educação, Ciência e Tecnologia do Ceará, Av. Parque Central, CEP 61939-140, Maracanaú - CE

Abstract: The current work proposes the use of Applied Computational Intelligence along with information extractors in metallography images. The purpose of this project consists in substitute the manual classification of molten iron for an automated one. The attribute extractors analyzed are the texture obtained by the grayscale co-occurrence matrix, Local Binary Pattern, aside from statistical, central and invariant moments. The rated classifiers are Bayes, Support Vector Machine (SVM), Multilayer Perceptron (MLP), k-nearest neighbors and k-means. The present graphites in each image were extracted through the Connected Contours method. These graphites were cataloged as nodular, maleable or grey molten iron, totalizing 1700 samples. Two stages were done for the analysis. In the first one, the graphites were considered separately. In a second stage, the complete image was analyzed considering all the graphites that were extracted from it, in a way that the type of the object with the highest incidence in the analysis would be the acknowledgement adopted for the whole sample. In both stages the SVM method obtained the best results in the acknowledgement of molten iron type. From the presented results, it is concluded that the approach is promising and by its results, it might embed commercial softwares in order to support specialists in the field.

Palavras-chave: Cast Iron, Digital Image Processing, Pattern Recognition, Applied Computational Intelligence.