

INFLUÊNCIA DA PREPARAÇÃO METALOGRÁFICA E DAS CONDIÇÕES DE AQUISIÇÃO DAS IMAGENS NA QUANTIFICAÇÃO AUTOMÁTICA DE FASES SECUNDÁRIAS¹

Cleiton Carvalho Silva²
Thiago Ivo de S. Menezes³
Hélio Cordeiro de Miranda⁴
Jesualdo Pereira Farias⁴
Victor Hugo C. de Albuquerque⁵
João Manuel Ribeiro da Silva Tavares⁶

Resumo

O objetivo deste trabalho foi investigar a influência da preparação metalográfica e das condições do processo de aquisição de imagens sobre a quantificação de fases secundárias através de uma rede neural do tipo *perceptron* multicamadas. As imagens foram obtidas por microscopia eletrônica de varredura (MEV) a partir de revestimentos de superligas à base de Ni soldadas pelo processo TIG com alimentação de arame frio utilizando como substrato um aço C-Mn. Os resultados mostraram que o ataque excessivo (preparação metalográfica inadequada) da microestrutura e/ou o ajuste inadequado de brilho e contraste no momento da aquisição das imagens interferem na qualidade da segmentação e consequentemente nas quantificações obtidas para as fases secundárias.

Palavras-chave: Soldagem; Análise de imagem; Redes neurais; Superligas de níquel.

INFLUENCE OF THE METALLOGRAPHIC PREPARATION AND IMAGE ACQUISITION CONDITIONS ON THE SECONDARY PHASE QUANTIFICATION

Abstract

In this work, the influence of the metallographic preparation and the image acquisition conditions on the quantification of secondary phases by a multilayer perceptron neural network was investigated. The images were obtained by scanning electron microscopy (SEM) from Ni-based superalloy coatings on C-Mn steel deposited by gas tungsten arc welding (GTAW) cold wire process. The results showed that excessive chemical etching of the microstructure (inadequate metallographic preparation) and/or inadequate brightness and contrast adjustment during the SEM image acquisitions interfere in the segmentation results and consequently on the secondary phase quantifications.

Keywords: Welding; Image analysis; Neural network; Ni-base superalloy.

¹ Contribuição técnica ao 66º Congresso Anual da ABM, 18 a 22 de julho de 2011, São Paulo, SP, Brasil.

² Dr., Universidade Federal do Ceará, Departamento de Engenharia Metalúrgica e de Materiais.

³ Grad., Universidade Federal do Ceará, Departamento de Engenharia Metalúrgica e de Materiais.

⁴ Dr., Universidade Federal do Ceará, Departamento de Engenharia Metalúrgica e de Materiais.

⁵ Dr., Universidade de Fortaleza, Centro de Ciências Tecnológicas.

⁶ Dr., Universidade do Porto, Faculdade de Engenharia, Departamento de Engenharia Mecânica.

1 INTRODUÇÃO

Frequentemente, inclusões não-metálicas e fases precipitadas participam do processo de nucleação e crescimento de trincas de muitos materiais de importância tecnológica, como as ligas de alumínio, níquel e cobalto.⁽¹⁻³⁾ Além disso, em ligas resistentes à corrosão, a presença de fases ricas em elementos que participam do processo de passivação da superfície pode acarretar em desestabilização localizada da camada, tornando a liga susceptível à corrosão.^(4,5) Avaliações detalhadas sobre microestrutura, inclusive considerando informações quantitativas, têm sido usadas com sucesso para explicar diferenças de propriedades dos materiais e seu comportamento em serviço.⁽⁶⁻⁸⁾

A utilização de ferramentas computacionais, buscando automatizar e tornar os resultados das quantificações mais precisos e menos subjetivos à interpretação do operador, e focando a análise microestrutural quantitativa, têm permitido obter resultados significativos em áreas de Engenharia e Ciência de Materiais.⁽⁹⁻¹¹⁾

Segundo Tiwari e Tewari⁽¹²⁾ as etapas básicas na análise microestrutural quantitativa são: (i) formação da imagem (através de diferentes modalidades e dispositivos de microscopia), (ii) aquisição da imagem (através de dispositivos eletrônicos como câmeras digitais, scanners etc.), (iii) melhoramento da imagem por pré-processamento da mesma, (iv) segmentação das regiões de interesse, (v) análise e interpretação das regiões segmentadas. A aquisição de imagem, técnicas de pré-processamento e segmentação de imagens constituem campos ativos de pesquisa, especialmente por grupos dedicados ao desenvolvimento e otimização de abordagens computacionais baseadas em processamento e análise de sinais digitais.⁽¹³⁻¹⁸⁾

Recentemente, Albuquerque et al.⁽¹⁹⁾ aplicaram com sucesso uma rede neural para segmentar e quantificar automaticamente microestruturas a partir de imagens de microscopia eletrônica de varredura (MEV). Contudo, durante a execução do trabalho, observaram uma forte influência nos resultados obtidos da qualidade da preparação metalográfica realizada, bem como dos ajustes de contraste e brilho considerados durante o processo de aquisição das imagens a analisar, que, por vezes, é negligenciada durante a análise microestrutural.

Neste sentido, o objetivo deste trabalho foi investigar a influência da preparação metalográfica e dos ajustes de contraste e brilho usados na aquisição das imagens sobre a qualidade da segmentação e quantificação obtida por uma ferramenta de análise de imagens baseada numa rede neural.

2 MATERIAIS E MÉTODOS

O material avaliado no presente estudo foram soldas de revestimento depositadas com o metal de adição AWS ER-NiCrMo-4 com 1,2 mm de diâmetro, correspondendo a uma liga do tipo Hastelloy C276. A deposição foi realizada sobre chapas de aço ASTM A516 Gr.60, que é empregado na construção de equipamentos para indústrias químicas, petroquímicas e de petróleo e gás. A composição química de ambos os materiais encontra-se indicada na Tabela 1. A deposição por soldagem foi realizada através do processo TIG com alimentação de arame frio. Utilizou-se um eletrodo de tungstênio dopado com tório, com 4 mm de diâmetro. O gás de proteção utilizado foi uma mistura de Argônio com 30% de Hélio.

Tabela 1. Composição química do metal de adição (AWS ERNiCrMo-4) e metal de base (ASTM A516 Gr. 60)

Item	Composição química (% peso)							
	Ni	C	Cr	Mo	W	Fe	Mn	Si
AWS ERNiCrMo-4 (Hastelloy C276 [®])	56,80	0,002	16,13	16,28	3,38	6,07	0,52	0,03
ASTM A516 Gr. 60	Ni	C	Cr	Mo	Fe	Al	Mn	Si
	0,01	0,15	0,02	0,01	Bal.	0,02	0,95	0,2

A deposição foi realizada numa bancada robotizada (Figura 1), sendo utilizada uma fonte eletrônica de soldagem multiprocesso com sistema de aquisição de dados para monitorar os valores de tensão e corrente durante a soldagem.



Figura 1. Bancada de experimentos com robô industrial e sistema de soldagem TIG com alimentação de arame acoplado.

Os parâmetros de soldagem empregados na deposição da camada foram definidos visando otimizar a soldagem com baixa diluição com base em outros estudos.⁽²⁰⁾ Os parâmetros usados são apresentados na Tabela 2.

Tabela 2. Principais parâmetros de soldagem usados na deposição dos revestimentos da liga Hastelloy C276

Ensaio	I _{ef} (A)	U _{ef} (V)	V _s (cm/min)	E (kJ/cm)	Valim (m/min)	Tecimento
T2	334	21	25	11,5	6,0	Triangular
T8	284	21	17	15,2	11,0	Triangular
T14	340	23	21	13,1	9,5	Espiral

Após o processo de soldagem, foram extraídas amostras para preparação metalográfica convencional através de lixamento e polimento mecânico. A revelação das microestruturas foi conseguida através de ataque eletrolítico utilizando-se uma solução de ácido crômico 10%, tensão de 2,0 V e tempo de ataque variando de 15 segundos a 30 segundos. A caracterização foi realizada através da técnica de MEV.

As imagens obtidas foram classificadas em quatro grupos principais, baseada na combinação entre aspectos de preparação metalográfica da amostra (ataque para revelação da microestrutura) e aquisição da imagem (contraste e brilho):

- Teste A : Preparação metalográfica adequada – Aquisição adequada;
- Teste B : Preparação metalográfica adequada – Aquisição inadequada;
- Teste C : Preparação metalográfica inadequada – Aquisição adequada;

- Teste D : Preparação metalográfica inadequada – Aquisição inadequada.

Para avaliar os resultados de quantificação das fases secundárias em cada grupo, foi estabelecido um padrão de comparação para cada condição de soldagem aplicada, baseado em resultados de segmentação e quantificação obtidos para um conjunto de imagens de alta qualidade, tanto relativamente à preparação metalográfica quanto à aquisição de imagem, para cada uma das condições avaliadas: T2, T8 e T14. A quantificação foi realizada com base em análise estatística considerando uma população suficiente para garantir um nível de confiabilidade de 95%.

Para segmentar as imagens em estudo, foi utilizada uma ferramenta computacional de processamento e análise de imagem baseada numa rede neural artificial. A topologia da rede usada para segmentar as imagens em análise consiste em: (i) uma entrada composta de três neurônios, em que cada um destes corresponde ao espaço de cores primárias (vermelho/ verde / azul) representando os valores de cada pixel da imagem a ser avaliada, (ii) uma camada escondida formada por 7 neurônios, este número foi definido baseado na regra eurística proposta por Kolmogorov,⁽²¹⁾ na qual o número de neuronios na camada escondida é duas vezes o números de neuronios da camada de entrada mais um e, finalmente, (iii) uma camada de saída composta por três neurônios. Como função de ativação dos neurônios das camadas escondida e de saída foi considerada a função logística,⁽²²⁾ apresentando três valores de saída: 1 (um), 0 (zero) e -1 (menos um).

Portanto, enquanto a rede neural é usada neste trabalho para segmentar imagens em níveis de cinza (níveis de 0 até 255) e quantificar as regiões de interesse (fases secundárias e matriz), também tem a capacidade de classificar imagem coloridas até 27 classes.

Na experimentação realizada, a rede neural foi inicialmente treinada com 20% do conjunto total de imagens para realizar a segmentação e posterior quantificação das fases secundárias e matriz, sendo as imagens restantes utilizadas na fase de teste. Na fase de treinamento, foram utilizados uma média de 15 pixels selecionados manualmente para cada região a segmentar por um especialista em análise microestrutural. É importante salientar que esta operação precisa somente ser realizada uma única vez para quantificar um conjunto de imagens do mesmo tipo.

O algoritmo usado no treinamento da rede neural de multiplas camadas foi o *backpropagation*,⁽²³⁾ um dos algoritmos mais usados para a fase de treinamento deste tipo de rede. O critério de parada adotado para o treinamento da rede foi baseado no erro absoluto igual ou menor que 0,01, ou um número de iterações igual a 2500 épocas. Maiores detalhes sobre a rede neural usada neste trabalho podem ser encontrados em Albuquerque et al.⁽¹⁹⁾

3 RESULTADOS E DISCUSSÃO

3.1 Segmentação

Inicialmente foram avaliados os resultados para as imagens cuja preparação e aquisição foram consideradas adequadas, visto que as diversas regiões constituintes do material são claramente identificadas. É importante salientar que o foco principal deste trabalho é distinguir corretamente os precipitados (fases claras ou brilhantes) em relação à matriz (regiões cinza claro e cinza escuro ou preto), embora sejam visualizadas três regiões, conforme mostrado na Figura 2. Nesta figura, é observada na imagem da esquerda (Figura 2a) uma região cinza escura ou

preta, cuja segmentação obtida está representada a verde na imagem da direita (Figura 2b) e que corresponde ao centro da dendrita. A região cinza claro, que foi segmentada e representada na Figura 2b na cor amarela, corresponde à região interdendrítica. Tanto o centro da dendrita quanto a região interdendrítica compõem a microestrutura matriz formada pela fase γ , que não é objeto de interesse deste trabalho. Os pontos menores e de brilho intenso, (segmentados e representados na cor azul na imagem da direita (Figura 2b), correspondem aos precipitados que, no caso de revestimentos depositados com a liga Hastelloy C276, são formados pelas fases secundárias P , μ e σ , que não são possíveis de serem diferenciadas adequadamente por MEV. Por este motivo, no presente trabalho, buscou-se apenas a análise da distinção e quantificação entre matriz e precipitados/fases secundárias, visto que, independente do tipo de fase secundária formada, os reflexos sobre as diversas características como propriedades mecânicas e resistência à corrosão, são sempre deletérios.

Na Figura 2 observa-se uma boa proximidade entre a imagem de MEV (Figura 2a) e a segmentação obtida (Figura 2b), indicando que o nível de preparação metalográfica e de aquisição de imagem (contraste e brilho), de acordo com avaliação de um especialista em análise microestrutural, estão dentro da qualidade esperada para a quantificação de fases.

O segundo caso, considerando preparação (ataque químico) adequada e aquisição, é apresentado na Figura 3. A segmentação obtida neste caso (Figura 3b) não apresentou diferença significativa em relação à imagem original (Figura 3a), mostrando que mesmo com um nível de contraste e brilho de menor qualidade foi ainda possível obter uma segmentação satisfatória.

Para a condição de ataque preparação metalográfica inadequada e condições de aquisição adequadas, verificou-se que as bordas das regiões interdendríticas apresentam um maior nível de brilho, semelhante ao observado para os precipitados de fases secundárias (Figura 4a), o que gera uma segmentação errônea (Figura 4b), devido a rede neural considerar as fases secundárias e as bordas das regiões interdendríticas como uma única microestrutura. O detalhe ampliado apresentado na Figura 4c mostra as bordas das dendritas ou células com brilho intenso, sendo esta região segmentada e representada a azul, cor que corresponde aos precipitados, na Figura 4d.




Figura 2. Exemplo de microestrutura obtida por MEV com preparação metalográfica adequada e boas condições de aquisição imagem (a); imagem segmentada correspondente.




Figura 3. Exemplo de microestrutura obtida por MEV com preparação metalográfica adequada e condições de aquisição inadequadas (a); imagem segmentada correspondente obtida.

Para a condição de ataque excessivo (preparação metalográfica inadequada) e condições de aquisição de imagem inadequadas (Figura 5a), verificou-se que a rede neural não conseguiu segmentar de forma adequada a imagem, tal como no caso anterior, conforme se pode verificar pela Figura 5b. Neste caso, houve uma identificação exagerada das bordas das dendritas em conjunto com os precipitados, o que irá influenciar a quantificação. Para verificar o efeito das bordas sobre a qualidade da segmentação, foram realizadas intervenções nas imagens, escurecendo manualmente as regiões identificadas erroneamente pela rede neural como precipitados (Figura 5c), no caso concreto, as bordas das dendritas. Para isso, um novo treinamento da rede neural foi realizado. Verificou-se nitidamente uma significativa redução da quantidade de regiões erradamente identificadas como precipitados, tornando o resultado da análise mais compatível com o observado na imagem (Figura 5d).




Figura 4. Exemplo de imagem obtida via MEV com preparação metalográfica inadequada e condições de aquisição de imagem adequadas (a); imagem correspondente segmentada (b); detalhe ampliado de (b), (c); imagem segmentada resultante de (c), (d)da.




Figura 5. Exemplo de imagem obtida via MEV com preparação metalográfica inadequada e condições de aquisição de imagem inadequadas (Teste D), (a); imagem correspondente segmentada (b); imagem (b) editada em programa de edição de imagens; imagem segmentada a partir de (c), (d).

3.2 Quantificação

Com base nos resultados de segmentação e quantificação dos precipitados obtidos para cada uma das quatro categorias indicadas previamente, foram construídos gráficos comparativos entre as referidas condições de análise, Figura 6. Nestes gráficos, cada uma das categorias quantificadas foram comparadas com padrões adotados, por exemplo, as imagens coletadas com preparação metalográfica adequada e aquisição de imagem inadequada (Teste B), foram oriundas da caracterização inicial de uma amostra soldada denominada T14, logo, sua quantificação foi comparada com o Padrão da amostra T14, produzido com novas imagens de qualidade adequada e com nível de confiabilidade dos resultados de 95%. No caso do Teste A (Figura 6a), é possível verificar uma excelente correspondência entre o resultado do Teste e o respectivo Padrão. Este comportamento era esperado, tendo em vista que as imagens em questão são de alta qualidade, ou seja, preparação e aquisição adequadas (Figura 2). A diferença entre o valor médio padrão com o do teste foi de 0,2.

Para a condição de preparação metalográfica adequada e aquisição inadequada (Teste B) (Figura 3), observa-se uma maior diferença entre os valores médios do Teste e do Padrão (0,8% de diferença entre as médias), bem como um maior desvio padrão na ordem de $\pm 0,65$. Quando o fator ataque químico (preparação metalográfica) passa a influenciar a análise, os resultados mostram haver uma diferença mais significativa. No caso de ataque excessivo (preparação inadequada) com aquisição adequada, houve a presença nas imagens de bordas com brilho intenso na interseção entre o centro da dendrita e a região interdendríticas. Isso resultou num aumento mais significativo da fração volumétrica dos precipitados. Se

comparado ao padrão (fração volumétrica média de 3,4%), o valor médio das medidas do Teste C (Figura 4), aumentou 67%, fornecendo um valor de 5,7% correspondente à fração volumétrica dos precipitados.

A condição mais crítica, Teste D (preparação metalográfica e aquisição inadequadas) apresentou uma maior discrepância entre os valores medidos no teste e o padrão. Conforme mostrado na Figura 6d, observa-se que o valor médio passa de 3,4% (Padrão) para 8,5%, equivalente a uma variação de 150%. Como indicado anteriormente, as bordas de dendrita se confundem com os precipitados (Figura 5c), por isso, o aumento significativo da quantidade para 8,5%.

Como já referido, para verificar o efeito das bordas sobre a qualidade da segmentação obtida pela rede neural, foram realizadas intervenções nas imagens originais, escurecendo manualmente as regiões identificadas erroneamente como precipitados (Figura 5c). O resultado do novo treinamento da rede foi considerado satisfatório, uma vez que resultou numa imagem segmentada muito próxima da micrografia original. A qualidade da segmentação, após esta intervenção, revelou visualmente uma quantidade de precipitados bastante inferior a apresentada na Figura 5c, o que pode ser comprovado através da imagem segmentada obtida (Figura 5d). Analisando quantitativamente os resultados da intervenção nas imagens do Teste D, verificou-se que após a eliminação manual das bordas de dendritas, esta quantidade foi reduzida para 3,7%, compatível com o correspondente padrão (3,4%).




Figura 6. Gráficos comparativos entre os resultados quantificados dos testes e os seus respectivos padrões; Teste A (a); Teste B (b); Teste C (c); Teste D (d).

Tabela 3. Valores médios e desvio padrão das análises quantitativas para cada teste e padrões

Condições analisadas		Valor médio do Teste	Valor médio do Padrão	Diferença crítica entre Padrão e Teste	Variação entre o Teste e o Padrão (%)
Ataque adequado	Aquisição adequada (Teste A)	2,5 ± 0,30	2,3 ± 0,15	0,2	8,7%
	Aquisição inadequada (Teste B)	2,8 ± 1,00	2,0 ± 0,30	0,8	40,0%
Ataque inadequado	Aquisição adequada (Teste C)	5,7 ± 1,60	3,4 ± 0,95	2,3	67,6%
	Aquisição inadequada (Teste D)	8,5 ± 2,2	3,4 ± 0,95	5,1	150,0%

4 CONCLUSÕES

Com base nos resultados obtidos e apresentados no presente trabalho sobre a influência da qualidade da preparação metalográfica e das condições de aquisição de imagem sobre a quantificação de fases secundárias através de uma rede neural *perceptron* multicamadas, foi possível concluir que:

- Tanto a preparação metalográfica quanto as condições de aquisição de imagem tem reflexos diretos sobre os resultados de segmentação e quantificação obtidos.
- Nos casos em que a preparação metalográfica foi adequada mas os ajustes de brilho e contraste no momento da aquisição de imagem foram inadequados, houve uma pequena diferença em termos de valores médios com maiores reflexos sobre o desvio padrão.
- Para as condições em que a preparação metalográfica foi inadequada, independente da qualidade da aquisição de imagem, foi observada uma maior diferença entre os valores médios, bem como uma maior dispersão em termos de desvio padrão.

Agradecimentos

Os autores gostariam de agradecer ao Laboratório de Engenharia de Soldagem – Engesolda da UFC. Ao Laboratório de Caracterização da UFC. A Petrobras pela colaboração no desenvolvimento deste projeto. E aos órgãos de fomento CNPq, FINEP e CAPES pelo suporte financeiro e concessão de bolsa. O sexto autor gostaria de agradecer ao suporte financeiro do CNPq e FUNCAP através da concessão de sua bolsa de Desenvolvimento Científico Regional (DCR - projeto de número 35.0053/2011.1) para Universidade de Fortaleza (Unifor).

REFERÊNCIAS

- 1 Agarwal H, Gokhale AM, Graham S, Horstemeyer MF. Quantitative characterization of three-dimensional damage evolution in a wrought Al-alloy under tension and compression. *Metallurgical and Materials Transactions A*. v. 33A, p. 2599-2606, 2002.
- 2 Balasundaram AK, Gokhale AM, Graham S, Horstemeyer MF. Three dimensional particle cracking damage development in an Al-Mg base alloy. *Materials Science & Engineering A*. v. 355, p. 368-383, 2003.
- 3 Agarwal H, Gokhale AM, Graham S, Horstemeyer MF. Anisotropy of intermetallic particle cracking damage evolution in an Al-Si-Mg base wrought aluminum alloy under uniaxial compression. *Metallurgical and Materials Transactions A*, v. 33A, p. 3443-8, 2002.
- 4 Summers T.S.E., Rebak R.B., Palmer T.A., and Crook P. Scientific Basis for Nuclear Waste Management XXV, Materials Research Society, Warrendale, PA, 2002, vol. 713, pp. 45-52.
- 5 El-Dasher, B.S., Edgecumbe, T.S., Torres, S.G. The effect of solution annealing on the microstructural behavior of alloy 22 welds. *Metallurgical and Materials Transactions A*. v. 37A, n. 3, pp. 1027-1038, 2006.
- 6 Tewari A, Spowart JE, Gokhale AM, Mishra RS, Miracle DB. Characterization of the effects of friction stir processing on microstructural changes in DRA composites. *Mat Sc and Eng A* 2006;428(1-2):80-90.
- 7 Silva, C.C. ; Menezes, T.I.S. ; Albuquerque, V.H.C.; Miranda, H. C.; Farias, J.P.. Efeito da diluição sobre a formação de fases topologicamente compactas em revestimentos de superligas à base de níquel. In: 65º Congresso Anual da ABM - Internacional, 2010, Rio de Janeiro. Anais do 65º Congresso Anual da ABM - Internacional, 2010.
- 8 Albuquerque, V.H.C., Tavares, J.M.R.S., Cortez, P.C. Quantification of the microstructures of hypoeutectic white cast iron using mathematical morphology and an artificial neural network. *International Journal of Microstructure and Materials Properties*, v. 5, n. 1, pp. 52-64, 2010.
- 9 Nazar A.M., Silva E.A., Ammann J.J. Image Processing for Particle Characterization. *Materials Characterization*. v. 36, p. 165-173, 1996.
- 10 Patel A., Nettleship I., Palmiere E.J. The Use of Image Analysis in the Characterization of Partially Oriented Ceramic Matrix Composites. *Materials Characterization*. v. 39, p. 15-23, 1997.
- 11 Lee S.G., Mao Y., Gokhale A.M., Harris J., Horstemeyer M.F. Application of digital image processing for automatic detection and characterization of cracked constituent particles/inclusions in wrought aluminum alloys. *Materials Characterization*, v. 60, p. 964-970, 2009.
- 12 Tiwari S., Tewari A. Inherent limitations of bitmap discretization in quantitative microstructural analysis. *Materials Characterization*. v. 61, p. 493-501, 2010.
- 13 Kass M, Witkin A, Terzopoulos D. Snakes — active contour models. *Int J Comput Vis* 1987;1(4):321–31.
- 14 Komenda J. Automatic recognition of complex microstructures using the Image Classifier. *Materials Characterization*. v. 46, p. 87-92, 2001.
- 15 Albuquerque, V.H.C. Alexandria, A.R., Cortez, P.C., Tavares, J.M.R.S. Evaluation of Multilayer Perceptron and Self-Organizing Map Neural Network Topologies applied on Microstructure Segmentation from Metallographic Images. *NDT & E International*, v. 42, n. 7, pp. 644-651, 2009.

- 16 Albuquerque, V.H.C. Cortez, P.C., Alexandria, A.R., Tavares, J.M.R.S. A New Solution for Automatic Microstructures Analysis from Images Based on a Backpropagation Artificial Neural Network. *Nondestructive Testing and Evaluation*. v. 23, n. 4, pp. 273-283, 2008.
- 17 Papa, J.P., Albuquerque, V.H.C., Falcão, A.X., Tavares, J.M.R.S. Fast Automatic Microstructural Segmentation of Ferrous Alloy Samples using Optimum-Path Forest Computational Modeling of Objects Represented in Images, *Lecture Notes in Computer Science*, v. 6026, pp. 210-220, 2010.
- 18 Papa, J.P., Pereira, C.R. Albuquerque, V.H.C., Silva, C.C., Falcão A.X., Tavares, J.M.R.S. Precipitates Segmentation from Scanning Electron Microscope Images Through Machine Learning Techniques. In: *IWCIA 2011 – International Workshop on Combinatorial Image Analysis*, Madrid, Spain, 23-25 April 2011
- 19 Albuquerque, VHC, Silva, CC, Menezes, TIS, Farias, JP, Tavares, JMRS. Automatic Evaluation of Nickel Alloy Secondary Phases from SEM Images. *Microscopy Research and Technique*. v. 74, n. 1, pp. 36-46, Jan. 2011
- 20 Silva C.C. Revestimentos de Ligas Níquel Depositadas pelo Processo TIG com Alimentação de Arame Frio – Aspectos Operacionais e Metalúrgicos. 320p. Tese de Doutorado, Universidade Federal do Ceará, Fortaleza (2010).
- 21 Bodyanskiy Y, Kolodyazhniy V, Otto P., Neuro-fuzzy Kolmogorov's network for time series prediction and pattern classification. *Springer LNCS* 3698:91-202 (2005).
- 22 Elliott DL, Better A., Activation Function for Artificial Neuronal Networks, *ISR Technical Report TR 93-8*, Institute for Systems Research, University of Maryland (1993).
- 23 Singh V., Rao S.M., Application of Image Processing and Radial Basis Neuronal Network Techniques for Ore Sorting and Ore Classification. *Minerals Engineering*, 18, 1412-1420 (2005).