



## Copyright 2004, Instituto Brasileiro de Petróleo e Gás - IBP

Este Trabalho Técnico Científico foi preparado para apresentação no 3º Congresso Brasileiro de P&D em Petróleo e Gás, a ser realizado no período de 2 a 5 de outubro de 2005, em Salvador. Este Trabalho Técnico Científico foi selecionado e/ou revisado pela Comissão Científica, para apresentação no Evento. O conteúdo do Trabalho, como apresentado, não foi revisado pelo IBP. Os organizadores não irão traduzir ou corrigir os textos recebidos. O material conforme, apresentado, não necessariamente reflete as opiniões do Instituto Brasileiro de Petróleo e Gás, Sócios e Representantes. É de conhecimento e aprovação do(s) autor(es) que este Trabalho será publicado nos Anais do 3º Congresso Brasileiro de P&D em Petróleo e Gás

---

# AVALIAÇÃO DA SENSITIZAÇÃO DO AÇO INOXIDÁVEL AISI 304L ATRAVÉS DE IMAGENS MICROGRÁFICAS

Rodrigo Carvalho Souza Costa<sup>1</sup>, Geraldo Luis Bezerra Ramalho<sup>1</sup>, Darby F. A. Lopes<sup>1</sup>, Fátima N. Sombra de Medeiros<sup>1</sup>, Luiz C. Lima de Medeiros<sup>2</sup>, Antonia D. S. Bruno<sup>3</sup>

<sup>1</sup> Universidade Federal do Ceará - UFC/DETI, Campus do PICI, Bloco 705, Fortaleza, CE,  
{rodcosta, fsombra, darby }@deti.ufc.br; gramalho@yahoo.com.br

<sup>2</sup> Petrobrás/UN-BC/ATP-C/ISUP, Macaé -RJ,  
luizmedeiros@petrobras.com.br

<sup>3</sup> Universidade Federal do Ceará - UFC/DEM, Campus do PICI, Bloco 714, Fortaleza, CE,  
antonio\_daniele@yahoo.com.br

**Resumo** – Neste artigo propomos uma metodologia para inspeção automática em dutos e tubulações confeccionados em aço inoxidável AISI 304L, do tipo utilizado em plantas petrolíferas. Imagens micrográficas de amostras das tubulações são processadas e delas são extraídas um conjunto de características as quais são utilizadas para classificar as amostras em três níveis de sensitização segundo a norma ASTM A262-02a. Dessa forma é possível determinar o grau de corrosão intergranular de determinadas regiões de dutos e tubulações e prover uma ferramenta automática de auxílio na tomada de decisão necessária para a manutenção da integridade e confiabilidade operacional dos mesmos.

**Palavras-Chave:** Corrosão Intergranular, Inspeção Automática, Reconhecimento de Padrões, Redes Neurais, Variáveis Canônicas

**Abstract** – In this paper we propose a methodology for automatic inspection of AISI 304L stainless steel pipes used in oil plants. Micrographics images of pipes are processed to extract a set of features used to classify samples into three levels of sensitization according to the ASTM A262-02a. Thus, it is possible to establish the pipes intergranular corrosion degree of certain regions and provide an automatic tool to support necessary decision-making to keep them operating in reliable and undamaged conditions.

**Keywords:** Intergranular Corrosion, Automatic Inspection, Pattern Recognition, Neural Networks, Canonical Variate

## 1. Introdução

Na indústria petrolífera, todos os dutos estão sujeitos à corrosão o que requer uma inspeção periódica para garantir a integridade humana e dos equipamentos. O monitoramento da corrosão é um aspecto importante de muitas tecnologias industriais relacionadas a vários mecanismos de operação segura e previsão de tempo de serviço (Choi, 2004). As possíveis falhas podem gerar grandes prejuízos financeiros, e até mesmo gerar desastres ambientais devido ao derrame do produto (óleo e gás) transportado (Dutra, 2002; Barbosa et al, 1999). O processo de manutenção envolvido na solução deste tipo de problema consiste em localizar regiões afetadas por este tipo de dano nos dutos e tubulações para fins de conserto de tais avarias, evitando assim potenciais vazamentos. Há vários métodos de inspeção incluindo, a inspeção visual, que é muito utilizada e útil (Tsushima, 1997). Porém, há alguns tipos de defeitos existentes sob a película de tinta ou revestimento, que não podem ser detectados facilmente (Rebbapragada, 2000).

O campo de aplicação dos aços inoxidáveis austeníticos é bastante vasto e pode abranger desde produtos de uso doméstico até produtos empregados em indústrias químicas, petroquímica, alimentícia, farmacêutica, médico-hospitalar e outras. Devido às excelentes propriedades mecânicas a elevadas temperaturas apresentadas por estes aços, é comum sua aplicação em serviços envolvendo altas temperaturas por longos períodos de tempo, como válvulas de pressão, aquecedores, trocadores e condensadores de calor (Lima, 2002). Contudo, ao serem expostos a altas temperaturas, na faixa de 450° a 850°C, ou a processos de soldagem, este tipo de aço se torna susceptível a corrosão intergranular devido o fenômeno da sensitização, que é um processo relacionado com a precipitação de carbonetos ricos em cromo na região de contorno de grão, deixando a região adjacente empobrecida de cromo (Sedriks, 1996).

A corrosão pode ocorrer sob diferentes formas, e o conhecimento das mesmas é muito importante no estudo de um processo corrosivo. A caracterização da forma de corrosão auxilia bastante no esclarecimento do mecanismo e na aplicação de medidas adequadas de proteção (Gentil, 1999). É muito importante detectar as regiões corroídas a tempo para que medidas adequadas possam ser tomadas para evitar possíveis acidentes (Rebbapragada, 2000). Devido ao fenômeno de sensitização num metal, formam-se trincas microscópicas ao longo dos contornos de grãos da estrutura metalúrgica do material, não havendo praticamente alteração nas dimensões da peça. Quando as trincas atingem uma certa profundidade, a peça pode se romper, ou podem se destacar pedaços do material, pela ação de esforços mecânicos, mesmo muito baixos (Lima, 2002). Para avaliar a sensitização dos aços inoxidáveis austeníticos, a norma ASTM A262-02a estabelece três diferentes estruturas, a saber:

- **Step:** existem apenas desníveis entre os grãos.
- **Dual:** há o início da precipitação de carbonetos ricos em cromo na região de contorno de grão, mas não é suficiente para circundar completamente os grãos.
- **Ditch:** um ou mais grãos estão completamente circundados, mostrando a existência da sensitização.

Este trabalho propõe uma metodologia para análise e avaliação automática da sensitização no aço inoxidável AISI 304L utilizando técnicas de processamento de imagens digitais aplicadas a imagens micrográficas obtidas de dutos e tubulações com diferentes graus de sensitização. Admitindo que as imagens são previamente geradas e disponibilizadas em amostras, o primeiro passo da metodologia proposta consiste em segmentar as micrografias. Com base na imagem segmentada, são extraídas medidas da forma e tamanho dos contornos de grãos (atributos ou características) que serão utilizados posteriormente na etapa de classificação dos padrões estudados.

Algumas vezes, ao invés de utilizar muitas características para realizar a classificação, é bem mais eficiente selecionar as características que melhor discriminam as classes do problema estudado. As características mais significativas podem ser experimentalmente identificadas com base no desempenho do classificador, ajustando-se o conjunto de características usado na entrada do mesmo. Outro método consiste na transformação do espaço original em um espaço de menor dimensão utilizando análise por componentes principais (Gonzalez, 2000) ou variáveis canônicas (Monteiro, 2000). A eliminação de informação redundante no conjunto de características favorece a redução do esforço computacional do processo de classificação (Tang, 2005). O método mais geral de redução da dimensionalidade do problema ou redução do conjunto de características consiste em gerar um novo espaço de características a partir da combinação linear das existentes em que seja realizada a maximização da dispersão entre classes e minimização da dispersão intra-classe.

O algoritmo proposto identifica o grau de sensitização no aço inoxidável 304L em três tipos diferentes, utilizando técnicas de processamento de imagens e classificação de padrões aplicada às imagens micrográficas. A seção 2 apresenta a metodologia utilizada para avaliar a sensitização utilizando a norma ASTM A-262-02a. Na seção 3 é descrita a metodologia proposta que avalia a sensitização a partir de informações extraídas das imagens micrográficas e, na seção 4 é feita uma breve introdução da análise por variáveis canônicas como método eficiente de redução da dimensionalidade de problemas. A seção 5 exhibe os resultados experimentais e as discussões sobre os mesmos. Por fim a seção 6 apresenta as conclusões e perspectiva de trabalhos futuros.

## 2. Metodologia

A segmentação automática, em geral, é uma das tarefas mais difíceis em processamento de imagens, pois esta determina o eventual sucesso ou fracasso na análise posterior. Por esta razão, um cuidado considerável deve ser tomado para gerar uma segmentação robusta.

O método de segmentação proposto consiste de uma modificação do algoritmo de crescimento de regiões. Este algoritmo é um procedimento que agrupa pixels ou sub-regiões da imagem em regiões maiores. A mais simples dessas abordagens é a agregação de pixels, que começa com um conjunto de pontos "sementes" e, a partir deles, ocorre o crescimento das regiões anexando a cada ponto semente aqueles pixels que possuem propriedades similares como nível de cinza, textura ou cor.

O algoritmo de crescimento de regiões requer, para cada classe de objeto presente na cena, a escolha prévia de um conjunto de pixels pertencentes a estes objetos, chamados pixels sementes. Na abordagem proposta são escolhidos os picos do histograma como os representantes das classes de objetos. Os pixels sementes são selecionados automaticamente através da análise multiescala proposta por Marques et. al (2004).

Este algoritmo executa uma correlação entre o histograma original suavizado e o primeiro nível de decomposição wavelet do mesmo para a detecção de picos. Com base nesta análise, os pixels candidatos serão agrupados aos pixels sementes se estes obedecerem aos seguintes critérios de agregação:

- Qualquer pixel acrescentado à região deve apresentar conectividade 4 com pelo menos um pixel previamente incluído naquela região.
- O nível de cinza do pixel candidato deve estar entre os dois vales adjacentes ao pixel semente.

A região pára de crescer quando não existirem mais pixels candidatos que obedeçam aos critérios de agregação. Uma vez detectados os contornos de grão é feita uma descrição dos mesmos em termos da sua geometria, calculando-se área, perímetro, complexidade, etc. A complexidade assume valores numéricos pequenos para uma região com geometria simples (ex. círculo) e valores grandes para regiões complexas (ex.: hexágono).

De cada imagem micrográfica são extraídas 20 características as quais são descritas no Apêndice A.

## 3. Análise por Variáveis Canônicas

A análise por variáveis canônicas (AVC) é um método matemático desenvolvido inicialmente por Hotelling (1936) e citado por Monteiro (2000). Esta análise fornece uma descrição das diferenças entre classes de padrões especificados *a priori* em um conjunto de dados multivariados (Monteiro, 2000). A especificação das classes depende essencialmente do delineamento do problema estudado. O objetivo deste estudo é encontrar um novo espaço de  $c$  variáveis que maximize a variação entre as diferentes classes do problema estudado e simultaneamente minimize as variações dos padrões dentro da classe. Para isso, é necessário construir uma matriz que quantifique a variação dentro das classes e a variação entre as classes que são denominadas respectivamente, de *matrizes de soma dos quadrados dentro* ( $W$ ) e *entre classes* ( $B$ ) e definidas por:

$$W = \sum_{k=1}^m \sum_{i=1}^n (x_{ij} - \bar{x}_i)(x_{ij} - \bar{x}_i)^T \quad (1)$$

$$B = \sum_{i=1}^n (\bar{x}_i - \bar{x})(\bar{x}_i - \bar{x})^T \quad (2)$$

em que,  $n$  é o número total de grupos,  $m$  é número total de elementos de cada grupo e  $x_{ij}$  é a observação de uma variável no  $j$ -ésimo elemento do  $i$ -ésimo grupo e  $T$  sobrescrito é o transposto.  $\bar{x}_i$  é a média de uma dada variável para o  $i$ -ésimo grupo e  $\bar{x}$  é a média geral para uma dada variável para todos os grupos.

Sabendo que os autovalores  $\lambda$  de uma matriz de variâncias e covariâncias descrevem os eixos de variação máxima, escolhem-se os autovetores ( $E$ ) que maximizem a razão entre as matrizes de soma dos quadrados dentro e entre classes:

$$\frac{E^T B E}{E^T W E} \quad (3)$$

Dessa forma, basta extrair os autovetores da matriz:

$$W^{-1} B \quad (4)$$

A projeção de cada indivíduo  $y$  sobre as  $c$  variáveis canônicas é obtida pela combinação linear dos valores das variáveis originais com os coeficientes dos autovetores associados aos  $c$  maiores autovalores ( $\lambda$ ).

#### 4. Resultados

Os resultados experimentais foram obtidos pela aplicação dos algoritmos às micrografias do aço 304L submetidas a diferentes tratamentos térmicos e que foram adquiridas do banco de dados SENSISTEEL (Lima, 2002). Foram utilizadas as micrografias das amostras submetidas ao tratamento térmico de 380° (durante 96h) e 450° (durante 24h) e que foram classificadas em Lima (2002) como estrutura STEP, 480° (durante 96h) como estrutura DUAL e 500°, 550° e 600° (durante 96h) como estrutura DITCH. A Fig. 1 mostra três imagens resultantes de diferentes tratamentos térmicos que exibem as três estruturas definidas na norma ASTM A262-02a.




Fig. 1. Amostra do aço 304L submetida ao tratamento térmico de a) 450 ° durante 24h b) 480° durante 96h e c) 500° durante 96h.

Tabela 1. Quantidade de imagens utilizadas para teste considerando cada tipo de estrutura definida na norma ASTM262-02a.

|            | <b>Step</b> | <b>Dual</b> | <b>Ditch</b> |
|------------|-------------|-------------|--------------|
| Quantidade | 10          | 6           | 18           |

Para aumentar o número de amostras de teste dos algoritmos, as imagens foram divididas de modo a formarem o banco de imagens totalizado na Tabela 1. A Fig. 2 exibe o resultado da etapa de segmentação, para diferentes imagens de teste, estruturas STEP (Fig. 2(a) e 2(b)), DUAL (Fig. 2(c)) e DITCH (Fig. 2(d) e 2(e)).




Fig. 2. Micrografia do 304L submetido ao tratamento térmico de a) 350° durante 96h, b) 480° durante 24h, c) 480° durante 96h d) 500° durante 96h e e) 600° durante 96h e (f-j) resultados do algoritmo proposto.

As amostras foram classificadas no espaço característico original de atributos utilizando-se duas técnicas diferentes de classificadores não-paramétricos supervisionados (Michie et. al, 1994) (Haykin, 1999): kNN (k-Nearest Neighbour) e MLP (Multi-Layer Perceptron).

Em todos os testes de classificação foram escolhidas aleatoriamente 70% das amostras para a fase de treinamento e os 30% restantes para a fase de testes. A tabela abaixo mostra o percentual de classificação correta calculada para cada classificador.

Tabela 2. Percentual de classificação correta calculada para cada classificador.

| Classificador | Taxa média de classificação correta | Número de Testes (repetições) | Características do Classificador                                                                                                                |
|---------------|-------------------------------------|-------------------------------|-------------------------------------------------------------------------------------------------------------------------------------------------|
| kNN           | 87,0%                               | 500                           | 3, 5 e 7 vizinhos                                                                                                                               |
| MLP           | 96,0%                               | 100                           | Rede de 3 camadas, com 5 neurônios na camada escondida; 500 épocas de treinamento usando algoritmo backpropagation com taxa de aprendizagem 0.5 |

Classificadores paramétricos como Bayes e Fisher (Michie et. al, 1994) também foram testados, porém devido ao limitado número de amostras disponíveis, não foi possível obter uma boa estimação da matriz de covariância, e isto afetou negativamente o desempenho dos dois métodos de classificação utilizados. Quando a quantidade de amostras não é significativamente grande com relação à quantidade de atributos estamos diante do problema COD (Course of Dimensionality) (Jain et. al, 2000) (Zhang, 2000). Neste caso a matriz de covariância fica mal-condicionada e fica difícil achar uma solução para sua inversa, a qual é requerida em vários métodos classificadores paramétricos. Uma solução possível para este problema é reduzir o número de atributos usando técnicas de transformação do espaço de dados, quando possível. A transformação dos atributos das amostras usando as variáveis canônicas, além de descorrelacioná-las, ajuda a maximizar a separação entre grupos e diminuir a dimensão do espaço de atributos. Como pode ser observado na Fig. 3, que ilustra o espaço transformado das características utilizando as variáveis canônicas, é possível obter uma classificação 100% correta das amostras utilizadas neste trabalho utilizando limiares numa árvore de decisão (Decision-Tree) (Michie et. al, 1994).




Fig. 3. Resultado da transformação das amostras para o espaço das variáveis canônicas. As linhas tracejadas mostram onde poderiam ser posicionados os limiares para separação das três classes.

## 5. Conclusões

As taxas de acerto obtidas com os classificadores paramétricos deixam claro que os atributos escolhidos são bastante discriminativos e permitem a separação, com boa precisão, das três classes de corrosão entre si no espaço original. A transformação dos atributos para um espaço de dimensionalidade reduzida, entretanto, possibilita uma redução significativa do esforço computacional e uma simplificação na tarefa de classificação. Além disso, com os dados transformados para o espaço das variáveis canônicas, foi possível obter uma taxa de acerto de 100%, já as amostras foram agrupadas com pequena variância dentro de suas classes e com uma separabilidade ótima entre elas.

Este trabalho mostra que é possível classificar automaticamente amostras com diferentes graus de sensibilidade através da análise de imagens micrográficas de amostras de dutos de aço. Essa informação pode ser utilizada a fim de tomar medidas preventivas e evitar que a corrosão se alastre pelos dutos, evitando danos mais graves.

## 6. Agradecimentos

Os autores agradecem a ANP-PRH (Processos # 2001.7192-9 e # 2001.7061-0) e ao CNPq pelo suporte financeiro deste projeto.

## 7. Referências

- BARBOSA, C. H., BRUNO, A. C., VELLASCO, M., PACHECO, M., Automation of Squid Nondestructive Evaluation of Steel Plates by Neural Networks, *IEEE Transactions on Applied Superconductivity*, v. 9, n. 2, p. 3475-3478, 1999.
- CHOI, K. Y., KIM, S. S., Morphological analysis and classification of types of surface corrosion damage by digital image processing. *Corrosion Science*, v. 47, n. 1, p. 1-15, 2005.
- DUTRA, F. S., Gálvez-Durand, F., Alves, V. C., System on a Chip for Petroleum Pipeline Inspection. In: *Proceedings of the 15 th Symposium on Integrated Circuits and Systems Design*, p. 331--336, Washington, EUA: IEEE Computer Society, set, 2002.
- GENTIL, V., *Corrosão*, 2ª edição, Editora Guanabara, Rio de Janeiro, Brasil, 1999.
- GONZALEZ, R.C. & Woods, R.E., *Processamento de Imagens Digital*. Edgard Blücher Ltda, São Paulo, Brasil, 2000.
- HAYKIN, S., *Redes Neurais: Princípios e Prática*, 2a Edição, Bookman, Porto-Alegre, Brasil, 1999.
- HOTELLING, H., Relations between two sets of variates, *Biometrika*, v. 28, p. 321-377, 1936.
- JAIN, A. K., DUIN, R. P.W., MAO, J., Statistical Pattern Recognition: A Review. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 22, n. 1, p. 4-37 2000.
- LIMA, A. S. *Análise da suscetibilidade à corrosão intergranular nos aços inoxidáveis austeníticos usados em refinarias: AISI 304L, AISI 316L, AISI 321 e AISI 347*, Dissertação (Mestrado), Universidade Federal do Ceará, Centro de Tecnologia, Departamento de Engenharia Mecânica e Produção, 2002.
- MARQUES, R. C. P., *Filtragem de ruído speckle em imagens de radar de abertura sintética e avaliação dos efeitos sobre a segmentação*, Dissertação (Mestrado), Universidade Federal do Ceará, Centro de Tecnologia, Departamento de Engenharia Elétrica, 2004.
- MICHIE, D., SPIEGELHALTER, D.J., TAYLOR, C. C., *Machine Learning, Neural and Statistical - Electronic Version*. fev, 1994. url: <http://www.amsta.leeds.ac.uk/~charles/statlog/whole.pdf>.
- MONTEIRO, R. M., DOS REIS, S. F. *Princípios de Morfometria Geométrica*, Holos, Ribeirão Preto, 1999.
- REBBAPRAGADA, S., *Intelligent Computational Methods for Corrosion Damage*, Dissertação (Mestrado), Universidade de Purdue, 2000.
- SEDRIS, A. J., *Corrosion of Stainless Steel*, John Wiley & Sons Inc, New York, EUA, 1996.
- TANG, E. K., SUGANTHAN, P. N., YAO, X., QIN, A.K., Linear dimensionality reduction using relevance weighted LDA, *International Journal of Pattern Recognition*, v. 38, n. 1, p. 485-493, 2005.
- TSUSHIMA, T., ISHII, A., OCHI, Y., MASAOKA, N., MATSUSUE, H., Corrosion Inspection of Steel Tube Inner Wall. In: *Proc. of IEEE/ASME International Conference on Advanced Intelligent Mechatronics '97*, p.34, Tokyo, Japan: IEEE Computer Society, jun, 1997.
- ZHANG, G. P., Neural Networks for Classification: A Survey. *IEEE Transactions on Systems, Man, and Cybernetics - Part C: Applications and Reviews*, v. 30, n. 4, p. 451-462, 2000.

## Apêndice: A

### Características:

- Área (A)
- Perímetro (P)
- As coordenadas ( $Q_{CM}$  e  $P_{CM}$ ) do centro de massa (C.M.).
- Distâncias máxima ( $D_{max}$ ) e mínima ( $D_{min}$ ) do centróide ao pontos da borda.
- Espalhamento (S)

$$S = 100 \cdot \frac{\lambda_2}{\lambda_1 + \lambda_2} \quad (5)$$

O espalhamento (S) é derivado da análise de componentes principais dos vetores, cujos componentes são as coordenadas dos pixels que pertencem aos contornos de grãos. O processo consiste em extrair a matriz de covariância dos contornos e em seguida seus autovalores e autovetores. Os maiores autovalores e os respectivos autovetores são preservados e organizados em ordem crescente. Extraem-se os dois maiores autovalores ( $\lambda_1$  e  $\lambda_2$ ) e, a partir destes, calcula-se o espalhamento.

- Complexidade (Comp)

$$Comp = \frac{P}{2\sqrt{\pi \cdot A}} \quad (6)$$

- $A/P$  = Relação área perímetro.

$$\text{Comp} = \frac{P}{2\sqrt{\pi \cdot A}} \quad (7)$$

- O desvio padrão da intensidade dos níveis de cinza dos pixels pertencentes aos contornos de grãos ( $\sigma_{obj}$ )
- O desvio padrão da intensidade dos níveis de cinza dos pixels pertencentes aos grãos ( $\sigma_{fundo}$ )
- Valores máximo ( $G_{max}$ ) e médio ( $G_{med}$ ) do gradiente da borda
- Contraste máximo ( $C_{max}$ ), a diferença em dB entre o valor médio da intensidade dos pixels dos grãos e o menor valor da intensidade dos pixels pertencentes aos contornos de grãos.
- Contraste médio ( $C_{med}$ ), a diferença em dB entre o valor médio da intensidade dos pixels do grão e o valor médio da intensidade dos pixels dos contornos.