

UNIVERSIDADE FEDERAL DO CEARÁ
CENTRO DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA DE TELEINFORMÁTICA
PROGRAMA DE GRADUAÇÃO EM ENGENHARIA DE TELEINFORMÁTICA

**ESTUDO E ANÁLISE DE UMA METODOLOGIA PARA LOCALIZAÇÃO DE
CORROSÃO ATMOSFÉRICA EM SUPERFÍCIES METÁLICAS POR
IMAGENS DIGITAIS**

KARINNE SARAIVA DA SILVA

FORTALEZA – CE

2007

KARINNE SARAIVA DA SILVA

**ESTUDO E ANÁLISE DE UMA METODOLOGIA PARA LOCALIZAÇÃO DE
CORROSÃO ATMOSFÉRICA EM SUPERFÍCIES METÁLICAS POR
IMAGENS DIGITAIS**

Projeto de Final de Curso submetido à
Coordenação do Programa de Graduação em
Engenharia de Teleinformática da Universidade
Federal do Ceará.

Orientadora: Profa. Dra. Fátima N. S. de Medeiros

FORTALEZA

AGRADECIMENTOS

A Deus, acima de tudo, por ter me dado a oportunidade de estar aqui, terminando meu curso de graduação e proporcionado a todos na minha família uma grande alegria, tão necessária para uma boa vida nos dias atuais.

A toda a minha família, pais, irmã, avós, tios e primos, pelo apoio sempre dado a educação.

À minha mãe que sempre foi um exemplo de força e perseverança também nos estudos.

À minha irmã querida e amada, Karla, que sempre que pode me ajuda em tudo.

A todos do grupo de processamento de imagens pelo companheirismo e momentos de descontração nas horas de trabalho durante a iniciação científica.

À professora Fátima Sombra, um exemplo de dedicação e perseverança, que me acolheu no grupo de pesquisa desde o final do primeiro ano de curso, me apresentando ao mundo da pesquisa.

A todos os professores, colegas e funcionários da Engenharia de Teleinformática que de forma direta e indireta muito ajudaram durante todo o curso de graduação. Especialmente aos colegas que conseguiram chegar junto comigo ao final do curso em quatro anos e aos funcionários Anagildo e Marleide que sempre que solicitei resolveram vários problemas para mim.

Ao CNPq pelo suporte financeiro dado durante dois anos.

Ao Atlântico, especialmente a Jaudenia, pelo tempo de estágio e ajuda em tudo que precisei.

“Onde não havia caminhos,
nós voamos.”

RESUMO

A corrosão é um processo de deterioração de materiais, em geral dos metais, e pode estar ou não associado a esforços mecânicos. A corrosão tem se tornado um problema de importância mundial, pois está associada a perdas econômicas que atingem de forma direta ou indireta as mais variadas atividades nas indústrias química, petrolífera, petroquímica, dentre outras, podendo causar perda de recursos humanos e materiais, redução na eficiência de processos, elevação nos custos de manutenção, etc.

A identificação dos processos corrosivos requer conhecimento, habilidade e experiência de especialistas. Este projeto apresenta uma metodologia disponível na literatura utilizada na localização de processos corrosivos utilizando técnicas de processamento de imagens digitais. O algoritmo exposto se baseia na informação de textura das imagens que exibem processos corrosivos segundo a análise de coeficientes de detalhes obtidos da decomposição por Transformada Wavelet.

SUMÁRIO

LISTA DE FIGURAS

<i>Figura 1 – Convenção dos eixos para representação de imagens digitais.....</i>	<i>11</i>
<i>Figura 2 – Passos fundamentais em processamento de imagens.....</i>	<i>12</i>
<i>Figura 3 – Diagrama de blocos da metodologia utilizada e apresentada em [20].....</i>	<i>14</i>
<i>Figura 4 – Processo de análise composto pela repetição de filtros</i>	<i>26</i>
<i>Figura 5 - Processo de análise composto pela repetição de filtros</i>	<i>27</i>
<i>Figura 6 – Um estágio da decomposição de uma imagem digital em multiresolução.</i>	<i>28</i>
<i>Figura 7 – Estruturas de decomposição em subbandas para vários estágios R [14]..</i>	<i>28</i>
<i>Figura 8 – (a) Imagem Lena original, (b) DWT-2D – 1 nível, (c) DWT-2D – 2 níveis, (d) DWT-2D – 3 níveis.....</i>	<i>29</i>
<i>Figura 9 - Um estágio da reconstrução de uma imagem digital em multiresolução [14].....</i>	<i>29</i>
<i>Figura 10 – As wavelets Haar para o espaço</i>	<i>31</i>
<i>Figura 11 – Exemplos de imagens de superfícies acometidas pela corrosão.....</i>	<i>33</i>
<i>Figura 12 - Dados artificiais bidimensionais.....</i>	<i>38</i>
<i>Figura 13 - Dados de teste com os autovetores da matriz de covariância e seus respectivos autovalores.....</i>	<i>38</i>
<i>Figura 14 - Dados no espaço.....</i>	<i>38</i>
<i>Figura 15 - (a) Inicialmente os centros (pontos pretos) são definidos aleatoriamente; (b) Os pontos vermelhos foram associados aos centros, e estes foram movidos para os respectivos centróides; (c) A associação é mostrada com mais detalhes, e os centros são movidos mais uma vez; (d) Novamente os centros são movidos, resultando na segmentação da imagem.....</i>	<i>41</i>
<i>Figura 16 – Representação gráfica do algoritmo apresentado.....</i>	<i>43</i>
<i>Figura 17 – (a) Exemplo de imagem com diferentes padrões de textura; (b) Decomposição wavelet em 3 níveis.....</i>	<i>45</i>
<i>Figura 18 – (a) Imagem original; (b) Transformada Wavelet para 3 níveis de decomposição; (c) Imagem segmentada e (d) Imagem segmentada filtrada [20].....</i>	<i>48</i>
<i>Figura 19 – (a) Imagem original (5 padrões texturais); (b) Imagem segmentada [30].</i>	<i>48</i>
<i>Figura 20 - (a) Imagem original (2 padrões texturais); (b) Imagem segmentada [30].</i>	<i>49</i>
<i>Figura 21 - (a), (c), (e) Imagens originais; (b), (d), (f) Suas respectivas versões segmentadas [5].....</i>	<i>50</i>

CAPÍTULO 1

INTRODUÇÃO

A corrosão se tornou um problema de importância mundial que afeta direta ou indiretamente diversas atividades do setor petroquímico, aeronáutico, farmacêutico, etc., podendo causar falhas no fornecimento de energia, perda de valiosos recursos, perda ou contaminação de produtos, diminuição da eficiência, além de um maior gasto em manutenção e sobredimensionamento de material.

Para a avaliação de corrosão em superfícies metálicas existem diversas formas de inspeção. Uma delas é fazendo uso de algoritmos de processamento digital de imagens, como apresentado por Livens *et al.* [2].

Quando uma superfície é corroída sua textura é modificada, possibilitando a distinção entre as áreas corroídas e áreas que não foram atingidas pela corrosão. Uma ferramenta usada para análise de textura em imagens é a Transformada Wavelet [9].

Neste trabalho será apresentado um algoritmo com o objetivo de segmentar imagens de superfícies metálicas submetidas a corrosão atmosférica por meio da análise textural.

1.1 Motivação

A corrosão pode ocorrer sob diferentes formas, e o conhecimento das mesmas é muito importante no estudo de um processo corrosivo em aplicações da indústria aeronáutica, química, automobilística, petroquímica, etc. 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 [25].

Na indústria petrolífera, todos os dutos estão sujeitos a corrosão e requerem inspeção para garantir a segurança humana e dos equipamentos. Sua manutenção representa uma das tarefas mais importantes na indústria do petróleo. As possíveis

falhas podem gerar grandes prejuízos financeiros, além de poder gerar desastres ambientais devido ao derrame do produto transportado (óleo e gás) [26]. O processo de manutenção dos equipamentos é fundamental na prevenção de problemas graves, pois na maioria das vezes paradas para consertos equivalem a grandes perdas financeiras.

É muito importante detectar as regiões corroídas a tempo para que as medidas adequadas possam ser tomadas para evitar o acontecimento de possíveis acidentes [5]. Há vários métodos de inspeção dos equipamentos, incluindo a inspeção visual, que é muito utilizada e muito útil. Porém, há alguns tipos de defeitos que estão ocultos pela pintura e não podem ser detectados [5]. Além disso, a inspeção visual está sujeita às falhas humanas, principalmente se for realizada de forma repetitiva. O auxílio do processamento digital de imagens reduz o risco de erros decorrente do cansaço visual.

Técnicas não destrutivas, como o uso de Processamento Digital de Imagens, são amplamente utilizadas na inspeção de tanques de armazenamento e dutos na indústria petrolífera, sem alterar as suas propriedades e o desempenho dos sistemas [27].

1.2 Objetivos

Os efeitos das falhas de corrosão no desempenho e na manutenção do material podem ser minimizados com o monitoramento adequado e freqüente do material ou equipamentos, de seu tempo de vida, bem como o controle dos fatores ambientais e humanos, além do dimensionamento efetivo.

Este trabalho apresenta uma metodologia para análise do processo corrosivo utilizando técnicas de processamento de imagens digitais. Este algoritmo será capaz de identificar processos de corrosão atmosférica que atingem superfícies metálicas.

1.3 Representação de Imagens Digitais

O interesse em métodos de processamento de imagens digitais decorre de duas áreas principais de aplicação: melhoria de informação visual para a interpretação humana e o processamento de dados de cenas para percepção automática através de máquinas.

O termo imagem monocromática, ou simplesmente imagem, refere-se à função bidimensional de intensidade da luz $f(x,y)$, onde x e y denotam as coordenadas espaciais e o valor de f em qualquer ponto (x, y) é proporcional ao brilho (ou níveis de cinza) da imagem naquele ponto. A Figura 1 ilustra a convenção dos eixos normalmente utilizados.

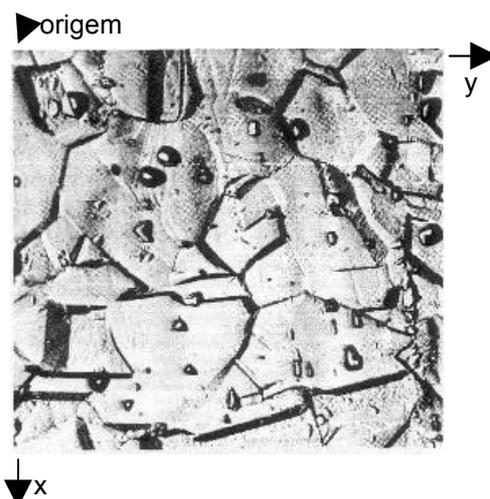


Figura 1 – Convenção dos eixos para representação de imagens digitais.

Uma imagem digital é uma função $f(x,y)$ discretizada tanto em coordenadas espaciais quanto em brilho. Uma imagem digital pode ser considerada como sendo uma matriz cujos índices de linhas e colunas identificam um ponto na imagem, e o correspondente valor do elemento da matriz identifica o nível de cinza naquele ponto. Os elementos dessa matriz digital são chamados de elementos de imagem, elementos da figura, *pixels* ou *pels*, estes dois últimos, abreviações de *picture elements*.

1.4 Passos Fundamentais do Processamento de Imagens

Apresentaremos a seguir os passos fundamentais para executar uma tarefa de processamento de imagem [23].

O primeiro passo no processo é a aquisição da imagem, isto é, adquirir uma imagem digital. Para tanto, necessitamos de um sensor para imageamento e a capacidade de digitalizar o sinal produzido pelo sensor. Esse sensor poderia ser uma câmera de TV monocromática ou colorida que produza uma imagem inteira do domínio

do problema a cada 1/30s (tempo necessário para que a câmera capte luz e forme a imagem). O sensor de imageamento poderia também ser uma câmera de varredura por linha que produza uma única linha de imagem por vez. Nesse caso, o movimento do objeto ao longo do varredor de linhas produz uma imagem bidimensional. Se a saída da câmera ou outro sensor de imageamento não se encontrar na forma digital, um conversor analógico-digital a digitaliza. A natureza do sensor e da imagem que ele produz é determinada pela aplicação.

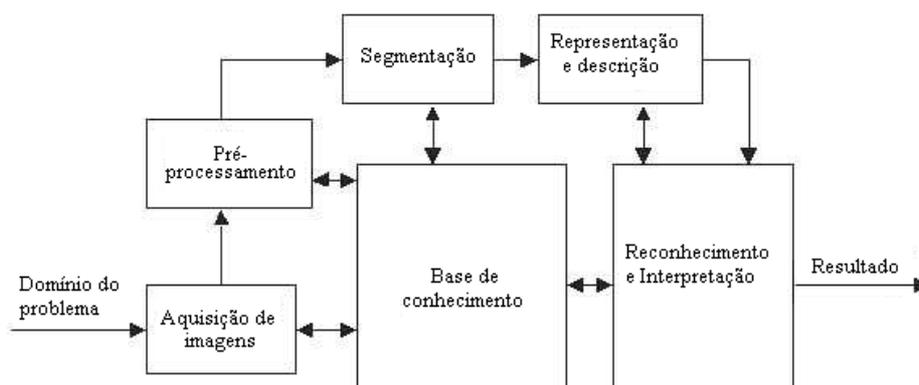


Figura 2 – Passos fundamentais em processamento de imagens.

O próximo estágio trata da segmentação. Definida em termos gerais, a segmentação divide a imagem de entrada em partes ou objetos constituintes. Em geral, a segmentação automática é uma das tarefas mais difíceis no processamento de imagens digitais. Por um lado, um procedimento de segmentação robusto favorece substancialmente a solução bem sucedida de um problema de imageamento. Por outro lado, algoritmos de segmentação fracos ou erráticos quase sempre geram falhas no processamento. No caso do reconhecimento de caracteres, por exemplo, o papel básico da segmentação é extrair caracteres individuais e palavras do fundo da imagem.

A saída do estágio de segmentação é constituída tipicamente por dados em forma de *pixels*, correspondendo tanto à fronteira de uma região como a todos os pontos dentro da mesma. Em ambos os casos é necessário converter os dados para uma forma adequada ao processamento computacional. A primeira decisão que precisa ser feita é se os dados devem ser representados como fronteiras ou como regiões completas. A representação por fronteira é adequada quando o interesse se concentra nas características da forma externa, tais como cantos ou pontos de inflexão. A representação por região é adequada, quando o interesse se concentra em propriedades

internas, tais como textura ou a forma do esqueleto. Em algumas aplicações, entretanto, essas representações coexistem. Essa situação acontece em aplicações de reconhecimento de caracteres, que freqüentemente requerem algoritmos baseados na forma da borda, bem como também esqueletos e outras propriedades internas.

A escolha de uma representação é apenas parte da solução para transformar os dados iniciais numa forma adequada para o subsequente processamento computacional. Um método para descrever os dados também deve ser especificado, de forma que as características de interesse sejam enfatizadas. O processo de descrição, também chamado seleção de características, procura extrair características que resultem em alguma informação quantitativa de interesse ou que sejam básicas para discriminação entre classes de objetos [23]. Em se tratando de reconhecimento de caracteres, descritores tais como buracos e concavidades são características importantes, pois auxiliam na diferenciação entre uma parte do alfabeto e outra.

O último estágio do módulo apresentado na Figura 2, envolve reconhecimento e interpretação dos dados. Reconhecimento é o processo que atribui um rótulo a um objeto, baseado na informação fornecida pelo seu descritor ou conjunto de descritores. A interpretação envolve a atribuição de significado a um conjunto de objetos reconhecidos. Por exemplo, a identificação de um caractere, (ex. c), requer a associação dos descritores para aquele caractere com o rótulo c . A interpretação procura atribuir significado a um conjunto de entidades rotuladas, como exemplo, uma cadeia de cinco números ou de cinco números seguidos por um hífen e por mais três números pode ser interpretada como um código de endereçamento postal.

1.5 Apresentação do Algoritmo Estudado

A metodologia apresentada trata imagens em tons de cinza de regiões acometidas por corrosão atmosférica. Adotaremos $v(x,y)$ como a representação da imagem, que será transformada para o domínio da freqüência por Transformada Wavelet Discreta (DWT), obtendo a imagem $W_{x,y}$, que compreende várias subimagens decorrentes dos vários níveis k de decomposição.

Dessas subimagens podemos extrair o vetor de características de texturas $t'(x)$ cuja dimensionalidade depende do nível de decomposição k da Transformada Wavelet.

Vale salientar que algumas dessas características contidas no vetor $t'(x)$ podem conter pouca informação sobre textura e devem ser removidas para diminuir o esforço computacional. Para a redução da dimensionalidade usaremos Análise por Componentes Principais (PCA), que selecionará os dados mais significativos e que serão utilizados no processo de segmentação. Sendo assim, $t(x)$ representa os vetores com as informações mais significativas sobre a textura da imagem $v(x, y)$.

A segmentação será realizada pela clusterização, ou seja, formação de *clusters*, usando o algoritmo k-médias, em seguida, os *clusters* receberão um rótulo $L(t)$. A imagem segmentada $s(x, y)$ é obtida aplicando o rótulo de acordo com a imagem original e sua correspondência com o vetor de informações texturais $t(x)$.

O resultado da segmentação é o mapa de textura $u(x, y)$, que é a saída do filtro da média executado sobre $s(x, y)$. O diagrama de blocos do algoritmo pode ser visto na Figura 3:

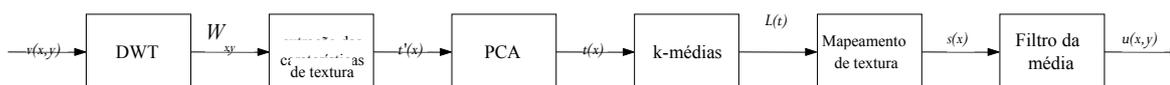


Figura 3 – Diagrama de blocos da metodologia utilizada e apresentada em [20].

1.6 Organização do Trabalho

Esta monografia está dividida em 6 capítulos. O Capítulo 2 apresenta fundamentos teóricos sobre corrosão atmosférica e textura. O Capítulo 3 faz uma abordagem sobre a Transformada Wavelet, fazendo menção ao seu uso para análise textural. No Capítulo 4 são apresentados os métodos de redução de características e segmentação utilizados nesse trabalho. A abordagem utilizada é melhor exposta no Capítulo 5. Resultados de ilustração, conclusões e perspectivas futuras são mostrados no Capítulo 6.

CAPÍTULO 2

CORROSÃO ATMOSFÉRICA E TEXTURA

2.1 Corrosão Atmosférica

Num aspecto muito difundido e aceito universalmente podemos definir corrosão como a deterioração de um material, geralmente metálico, por ação química ou eletroquímica do meio ambiente aliada ou não a esforços mecânicos. A deterioração causada pela interação físico-química entre o material e o seu meio operacional representa alterações prejudiciais indesejáveis, sofridas pelo material, tais como desgaste, variações químicas ou modificações estruturais, tornando-o inadequado para o uso.

Sendo a corrosão, em geral, um processo espontâneo, está constantemente transformando os materiais metálicos de modo que a durabilidade e desempenho dos mesmos deixam de satisfazer os fins a que se destinam. No seu todo esse fenômeno assume uma importância fundamental na vida moderna, dado que não conseguimos imaginar as tecnologias atuais sem os metais e suas ligas [24].

Os problemas de corrosão são freqüentes e ocorrem nas mais variadas atividades, como por exemplo, nas indústrias química, petrolífera, petroquímica, naval, de construção civil, automobilística, nos meios de transporte, aéreo, ferroviário, metroviário, marítimo, rodoviário e nos meios de comunicação, como sistemas de telecomunicações, na odontologia (restaurações metálicas, aparelhos de prótese), na medicina (ortopedia) e em obras de arte como monumentos e esculturas.

As perdas econômicas que atingem essas atividades são muitas, como custos de substituição das peças e equipamentos que sofreram corrosão, custos e manutenção dos

processos de proteção, paralisações acidentais para limpeza ou substituições, perda de eficiência, contaminação de produtos, superdimensionamento nos projetos.

Em alguns setores, embora a corrosão não seja muito representativa em termos de custo direto, deve-se levar em consideração o que ela pode representar em questões de segurança, interrupções de comunicações e preservação de monumentos históricos.

Existem diversas formas de corrosão e o conhecimento das mesmas é muito importante nos estudos dos processos corrosivos. Os tipos de corrosão podem ser apresentados considerando-se a aparência ou a forma de ataque e as diferentes causas da corrosão e seus mecanismos. Abaixo são apresentadas algumas dessas formas [24]:

1. Uniforme: A corrosão se processa em toda extensão da superfície, ocorrendo perda uniforme de espessura.
2. Por placas: A corrosão se localiza em regiões da superfície metálica e não em toda sua extensão, formando placas com escavações.
3. Alveolar: A corrosão se processa na superfície metálica produzindo sulcos ou escavações semelhantes a alvéolos.
4. Puntiforme: A corrosão se processa em pontos ou em pequenas áreas localizadas na superfície metálica produzindo pites, que são cavidades que apresentam o fundo em forma angulosa e profundidade geralmente maior que seu diâmetro.
5. Intergranular: A corrosão se processa entre os grãos da rede cristalina do material metálico, que pode sofrer fraturas.
6. Intragranular: A corrosão se processa nos grãos da rede cristalina do material metálico, que pode sofrer fraturas.
7. Filiforme: A corrosão se processa sob forma de finos filamentos, mas não profundos, que se propagam em diferentes direções e que não se cruzam.
8. Esfoliação: A corrosão se processa de forma paralela à superfície metálica.
9. Corrosão grafítica: A corrosão se processa no ferro fundido cinzento em temperatura ambiente e o ferro metálico é convertido em produtos de corrosão, restando a grafite intacta.
10. Dezincificação: É a corrosão que ocorre em ligas de cobre-zinco, causando perda de zinco.
11. Empolamento pelo hidrogênio: O hidrogênio atômico penetra no material metálico e, difunde-se rapidamente e em regiões com descontinuidades, ele se transforma em H_2 exercendo pressão e originando formação de bolhas.

12. Em torno do cordão de solda: Ocorre em aços inoxidáveis não estabilizados.

Existem também diversos meios corrosivos [24]. Alguns são encontrados mais freqüentemente, como: águas naturais, solo, produtos químicos, alimentos, substâncias fundidas, solventes orgânicos madeira, plásticos e a atmosfera. Este trabalho se aplica aos metais sujeitos ao meio corrosivo da atmosfera.

A importância da atmosfera, como meio corrosivo, pode ser confirmada pelo grande número de publicações científicas relacionadas com ensaios de corrosão utilizando diferentes materiais metálicos e prolongados períodos de exposição, nos mais diferentes países [1, 5].

Na atmosfera, há diversos componentes causadores da corrosão atmosférica: poluentes, como óxidos de enxofre, óxidos de nitrogênio, ozônio e particulados. A ação corrosiva da atmosfera depende fundamentalmente dos fatores [24]:

- Umidade relativa: A influência da umidade na ação corrosiva da atmosfera é acentuada, pois se sabe que o ferro em atmosfera de baixa umidade relativa praticamente não sofre corrosão. Se além da umidade houver também a presença de substâncias poluentes, evidentemente que a velocidade da corrosão será acelerada;
- Substâncias poluentes – particulados e gases: As partículas sólidas, sob a forma de poeira, existem na atmosfera e a torna mais corrosiva. O gás carbônico e umidade causam carbonatação do concreto. O dióxido de enxofre forma com a umidade presente no ar o ácido sulfuroso;
- Temperatura: Se for elevada, irá diminuir a possibilidade de condensação de vapor d'água na superfície metálica e a adsorção de gases, minimizando a possibilidade de corrosão;
- Tempo de permanência do filme eletrólito na superfície metálica: Quanto menor esse tempo, menor a ação corrosiva da atmosfera.

Materiais metálicos como ferro, zinco, alumínio e cobre são os materiais metálicos mais utilizados em estruturas, equipamentos e instalações externas. Dependendo do material metálico, do meio corrosivo e dos poluentes presentes, os processos corrosivos serão mais rápidos e os produtos de corrosão apresentarão características inerentes a cada tipo de atmosfera e de material metálico.

2.2 Análise de Textura

A textura contém informações importantes, geralmente utilizadas pelo ser humano para a interpretação e análise de vários tipos de imagens, podendo ser interpretada como relações espaciais e arranjos de elementos básicos de uma imagem.

A análise textural é uma tarefa difícil em processamento de imagens. Sua descrição e análise regional são os estágios iniciais de muitas aplicações em processamento de imagens.

Dentro da comunidade científica de processamento de imagens, textura é um termo utilizado para indicar propriedades intrínsecas de superfícies ou regiões, especialmente para aquelas que não possuem uma variação suave de intensidade [1], sendo tão pequenas que não conseguem separar objetos na resolução observada. Essa característica fornece informações importantes para a identificação de superfícies e objetos em muitos tipos de imagens.

Desde imagens multi-espectrais obtidas de aviões ou plataformas de satélites usadas pela comunidade de sensoriamento remoto, até imagens de cultura de células, obtidas em microscópio para serem estudadas na área biomédica, são utilizadas em análises de visão artificial.

Apesar da sua importância, não há uma abordagem formal ou uma precisa definição de textura, que inclua propriedades intuitivas como, rugosidade, granularidade, regularidade, semi-periodicidade e invariância à translação [1].

Formalmente, a textura pode ser definida como um conjunto local de propriedades de vizinhanças dos níveis de cinza dentro de uma região da imagem. Os métodos para extrair textura são diversos, refletindo em diferentes conceitos originados nas diversas áreas de aplicação. Existem vários métodos de análise textural e podem ser classificados [1] como:

- Estatísticos: Adquirem-se informações texturais a partir da distribuição e relacionamentos dos *pixels* da imagem. Estes métodos normalmente conseguem maiores taxas de discriminação do que os métodos estruturais e das transformações. Exemplos desse tipo de método são a análise do Histograma, Matriz de Co-ocorrência e o espectro de textura;

- Estruturais: A textura é definida como uma composição de texturas primitivas dispostas de acordo com algumas regras sintáticas. Em outras palavras, um objeto retangular é representado em termos de linhas retas ou primitivas que compõem a borda. Sua vantagem é produzir uma boa descrição simbólica da imagem, porém é mais útil para formar a imagem (síntese) do que realizar análise. Um exemplo de ferramenta para análise estrutural é a morfologia matemática [3];
- Modelada: Realiza a análise utilizando modelos matemáticos sofisticados (fractais e estocásticos). Alguns parâmetros da imagem são extraídos do modelo e atuam como características para analisar a imagem [1]. Sua desvantagem é a complexidade computacional na estimação dos parâmetros;
- Transformações: Representa a imagem em um novo espaço, como, por exemplo, os espaços de frequência e escala, onde as características texturais se tornam mais acessíveis. Exemplos disso são os métodos espectrais, onde informação da distribuição espacial de frequência se torna clara nas transformadas de imagens através de Fourier, Gabor e Wavelet.

Neste trabalho será investigado e implementado o método proposto em [1] para extração das características texturais utilizadas na classificação baseado na Transformada Wavelet.

2.3 Características Texturais e o Processamento Multi-escala

Segundo Livens *et al.* [2], um significativo aspecto da textura é a escala. Estudos psicovisuais indicam que o sistema de visão humano processa uma imagem em múltiplas escalas. O córtex visual tem células especializadas que respondem a diferentes frequências e orientações. O processamento multi-escala humano é aplicado corretamente para a percepção de textura, sendo esta uma grande motivação para os métodos de análise textural baseados neste conceito.

2.3.1 Características Texturais

A decomposição Wavelet separa as informações diferentemente em cada escala. Em seu trabalho, Livens [1] propôs um conjunto de características, invariantes à rotação, extraídas dos coeficientes wavelets, $W_{\psi}^i(j, m, n)$, obtidos através da Transformada Wavelet, que será exposta no Capítulo 3.

Em cada imagem de detalhes é extraída a informação de energia convencional:

$$E_{tot}(j, m, n) = E_{\psi}^H(j, m, n) + E_{\psi}^V(j, m, n) + E_{\psi}^D(j, m, n) \quad (2.1)$$

em que:
$$E_{\psi}^i(j, m, n) = \frac{1}{MN} \sum_{m=1}^M \sum_{n=1}^N (W_{\psi}^i(j, m, n))^2 \quad (2.2)$$

obtidas nas várias direções $i=H, V, D$.

Nas Equações 2.1 a 2.6, m e n são índices dos *pixels* da decomposição da imagem na escala j , $E_{tot}(j, m, n)$ representa a energia total por *pixel* e $E_{\psi}^i(j, m, n)$ a energia por *pixel* em cada uma das direções: horizontal (H), vertical (V) e diagonal (D).

A partir das energias locais ($i = H, V, D$) é possível extrair a medida de anisotropia da energia, ou seja, o quanto a energia em uma direção difere de outra:

$$Orian(j, m, n) = \frac{1}{E_{tot}(j, m, n)} \sqrt{\Delta E_{tot}} \quad (2.6)$$

em que:
$$\Delta E_{tot} = (E_{\psi}^H(j, m, n) - E_{\psi}^V(j, m, n))^2 + (E_{\psi}^H(j, m, n) - E_{\psi}^D(j, m, n))^2 + (E_{\psi}^V(j, m, n) - E_{\psi}^D(j, m, n))^2. \quad (2.5)$$

Somando as informações de cada *pixel*, são obtidas a energia e a anisotropia da energia globais por escala:

$$E_{tot}(j) = \frac{1}{MN} \sum_{m=1}^M \sum_{n=1}^N E_{tot}(j, m, n). \quad (2.3)$$

$$Orian_{tot}(j) = \frac{1}{MN} \sum_{m=1}^M \sum_{n=1}^N Orian(j, m, n). \quad (2.4)$$

Dessa forma podemos obter as características de textura que serão utilizadas no processo de clusterização e segmentação das imagens.

CAPÍTULO 3

A TRANSFORMADA WAVELET

A Transformada Wavelet é uma ferramenta de análise espaço/freqüência que tem sido intensamente estudada durante as últimas décadas. Muitos dos avanços obtidos nesta área foram obtidas da cooperação de Ingrid Daubechies e Stephane Mallat. Daubechies construiu uma família de wavelets com base compacta (*compact support*) [29] e Mallat pôs a Transformada Wavelet no conceito de decomposição multiresolução de sinais, além da implementação da transformada rápida baseada em conceitos de filtragem [4].

As wavelets têm sido aplicadas a vários problemas na computação gráfica. No processamento de imagens, essas aplicações incluem: edição, compressão e análise de textura, entre outras. As wavelets são uma classe de funções bem comportadas para análise multiresolução de uma imagem. Esta transformada expande um sinal dentro de um conjunto completo de funções de base (geralmente é utilizado um conjunto de base ortogonal) [2]. Diferentemente das funções de Fourier, as wavelets 2D representam uma imagem em um domínio espaço/freqüência que contém não apenas a informação de freqüência, bem como a informação espacial, sendo capaz de revelar aspectos importantes como limites, pontos de inflexão, descontinuidades em grandes derivadas e similaridade [5].

Neste capítulo serão introduzidos os conceitos básicos da análise Wavelet, fornecendo uma base teórica necessária para a aplicação da teoria Wavelet nos próximos capítulos desta monografia.

As wavelets são funções geradas a partir de dilatações (ou compressões) e translações de uma única função Ψ definida como [6]:

$$\Psi_{a,b}(x) = |a|^{-1/2} \Psi\left(\frac{x-b}{a}\right), \quad a, b \in \mathbb{R}, a \neq 0. \quad (3.1)$$

A função ψ é denominada wavelet-mãe, neste trabalho, a função wavelet escolhida é a Haar, melhor apresentada na seção 3.3, a é o parâmetro de escala e b é parâmetro de posição ou translação.

A idéia fundamental no uso de wavelets é analisar um sinal em diferentes escalas, por isso desempenha um papel essencial na análise em multiresolução. Se o sinal é analisado através de uma versão dilatada da wavelet-mãe, o que corresponde a $a < 1$, é possível observar características grosseiras, enquanto que, com uma versão contraída, o que corresponde a $a > 1$ é possível observar detalhes finos do sinal [6]. A análise temporal é feita com a versão contraída, de alta frequência, da wavelet-mãe, enquanto a análise em frequência é feita com a versão dilatada, de baixa frequência, da mesma wavelet.

Devido à possibilidade de representar o sinal em termos de uma expansão, ou seja, usando uma combinação linear de funções wavelet, as operações no sinal podem ser realizadas utilizando apenas os coeficientes wavelet correspondentes. Se a função de base escolhida para representar o sinal é a que representa melhor este sinal ou se os coeficientes abaixo de um determinado limiar são truncados, obtém-se uma representação esparsa deste sinal. Este código esparsa torna as wavelets ferramentas excelentes na área de compressão de dados.

As Transformadas Wavelets são computacionalmente eficientes devido, em grande parte, às funções de escalonamento e a wavelet-mãe serem de suporte compacto, ou seja, são definidas em um domínio limitado e finito. Existem dois tipos de Transformada Wavelet: a Transformada Wavelet Contínua (CWT) e a Transformada Wavelet Discreta (DWT). Na CWT desloca-se uma janela de análise ao longo do tempo para capturar informações do sinal [7, 8]. Na DWT, a análise do sinal é feita em passos discretos através de uma série de filtros, tornando o processo computacionalmente realizável, de modo que este é o tipo de transformada utilizada neste trabalho e descrita a seguir.

3.1 A Transformada Wavelet Discreta

Com base no conceito de multiresolução criado por Mallat [9] é possível construir famílias de wavelets discretas e desenvolver algoritmos rápidos para o cálculo da DWT, de ordem $O(N)$. Esta estrutura de cálculo é conhecida como decomposição

piramidal. Na análise em multiresolução considera-se a existência de duas funções básicas, a função de escalonamento-mãe ϕ e a função wavelet-mãe ψ . Estas funções são ortogonais entre si e definidas de tal forma que, ao longo dos vários níveis de resolução, as funções de escalonamento, $\phi_{j,k}(t)$ e wavelet, $\psi_{j,k}(t)$ estão relacionadas às respectivas funções mãe de acordo com as Equações 3.2 e 3.3 definidas em [10, 14]:

$$\phi_{j,k}(t) = 2^{-j/2} \phi(2^j t - k), \quad j, k \in \mathbb{Z} \quad (3.2)$$

e

$$\psi_{j,k}(t) = 2^{j/2} \psi(2^j t - k), \quad j, k \in \mathbb{Z} \quad (3.3)$$

Pode-se descrever a relação existente entre os níveis de resolução por meio de um aninhamento dos espaços de função, em que cada espaço de maior resolução contém os de menor resolução, como expresso na Equação 3.4.

$$\dots \subset V_{-2} \subset V_{-1} \subset V_0 \subset V_1 \subset V_2 \subset \dots \quad (3.4)$$

Cada espaço V_j é coberto pela família de funções base $\phi_{j,k}(t)$ correspondente. As funções wavelets $\psi_{j,k}(t)$ estão contidas nos espaços W_j que constituem o complemento de V_j em relação ao espaço V_{j+1} . A relação entre dois níveis de resolução adjacentes pode ser definida por:

$$V_{j+1} = V_j \oplus W_j. \quad (3.5)$$

em que o símbolo \oplus representa a operação de soma direta. Como os espaços V_j e W_j estão contidos em V_{j+1} , ambos podem ser expressos como uma combinação linear das funções base do espaço V_{j+1} , ponderando cada uma destas funções através dos coeficientes $h_0[n]$ e $h_1[n]$.

Desta forma tem-se:

$$\phi_{j,k}(t) = \sum_n h_0[n-2k] \phi_{j+1,n}, \quad (3.6)$$

$$\psi_{j,k}(t) = \sum_n h_1[n-2k] \phi_{j+1,n}. \quad (3.7)$$

Uma vez que a função f está contida no espaço V_{j+1} ela pode ser expressa como uma combinação linear das funções base de $\phi_{j+1,k}(t)$. Projetando f em V_j e W_j , e expressando estas projeções em função das bases de V_j e W_j , é possível relacionar as projeções de f e os diversos níveis de refinamento da seguinte forma:

$$a_{j,k} = \langle f, \phi_{j,k} \rangle = \sum_k h_0[n-2k]; \quad \langle f, \phi_{j+1,n} \rangle = \sum_k h_0[n-2k] a_{j+1,n} \quad (3.8)$$

$$c_{j,k} = \langle f, \psi_{j,k} \rangle = \sum_k h_1[n-2k]; \quad \langle f, \psi_{j+1,n} \rangle = \sum_k h_1[n-2k] a_{j+1,n}. \quad (3.9)$$

Como V_{j+1} é a soma direta de V_j e W_j é possível expressar a base V_{j+1} como uma combinação linear das bases V_j e W_j , cada uma delas ponderadas pelos coeficientes $g_0[n]$ e $g_1[n]$.

$$\phi_{j+1,n}(t) = \sum_k g_0[n-2k] \phi_{j,k}(t) + \sum_k g_1[n-2k] \psi_{j,k}(t). \quad (3.10)$$

Utilizando a Equação 3.10 é possível expressar $\phi_{j+1,n}$ em função das projeções $a_{j,k}$ e $c_{j,k}$ da seguinte forma:

$$\phi_{j+1,n}(t) = \sum_k g_0[n-2k] a_{j,k} + \sum_k g_1[n-2k] c_{j,k}. \quad (3.11)$$

Os processos de análise e síntese descritos nas Equações 3.2 a 3.11 correspondem à aplicação de filtros passa-baixa seguidos de uma subamostragem e filtros passa-alta precedidos por uma superamostragem, respectivamente, assim como ocorre nos métodos de codificação de subbandas (*Subband Coding*) em que os coeficientes $\{h_0[n], h_1[n]\}$ e $\{g_0[n], g_1[n]\}$ constituem os bancos de filtro utilizado por estes métodos. Os coeficientes $\{h_0[n], h_1[n]\}$ correspondem ao banco de filtro de análise e são chamados de coeficientes de aproximação, porque contêm informação essencial para a reconstrução do sinal. Os coeficientes $\{g_0[n], g_1[n]\}$ correspondem ao banco de filtros de síntese e são chamados coeficientes de detalhes, porque contêm detalhes do sinal [11].

As expressões apresentadas para as funções base e para os coeficientes sugerem uma recursão, em que a projeção de f sobre V_j é decomposta em V_{j-1} e W_{j-1} , a projeção em V_{j-1} é decomposta sobre V_{j-2} e W_{j-2} , e assim sucessivamente. Na Figura 4 é mostrada esta relação recursiva entre os coeficientes da transformada contidos em cada subespaço, bem como o filtro de análise.

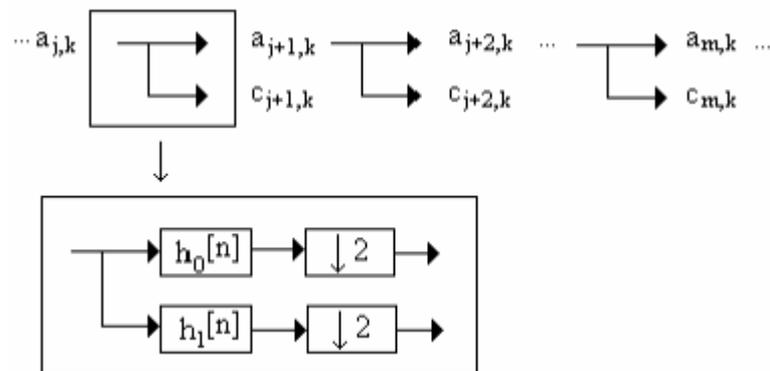


Figura 4 – Processo de análise composto pela repetição de filtros $\{h_0[n], h_1[n]\}$.

A saída do filtro, ilustrada na Figura 4, é decimada por dois, o que significa que, a cada duas saídas, uma é desprezada.

Uma vez que as projeções nos espaços V_j e W_j são ortogonais entre si e complementares em relação ao espaço V_{j+1} a reconstrução do sinal original é exata, desde que não ocorram perdas entre a decomposição e a reconstrução. Na Figura 5 é

mostrado o processo de reconstrução do sinal original e a estrutura do banco de filtros de síntese [14].

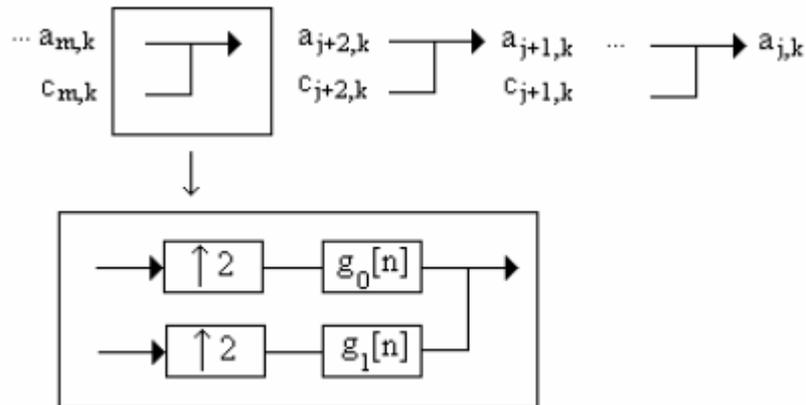


Figura 5 - Processo de análise composto pela repetição de filtros $\{g_0[n], g_1[n]\}$.

3.2 A Transformada Wavelet Discreta Bidimensional

A Transformada Wavelet é uma transformada separável. Por este motivo o processo de transformação pode ser estendido para o caso bidimensional pela aplicação do processo de análise descrito na Seção 3.1. Desta forma, a Transformada Wavelet para uma imagem digital $N \times M$ é executada aplicando-se a versão unidimensional a cada uma das dimensões. Inicialmente a DWT é aplicada às linhas na primeira dimensão e depois às colunas, que é a segunda dimensão do resultado [12]. A Figura 6 ilustra a decomposição por Transformada Wavelet Discreta bidimensional. Inicialmente, a imagem é filtrada ao longo do eixo x e decimada por 2, e em seguida a matriz obtida com esta transformação é filtrada ao longo do eixo y e também decimada por 2.

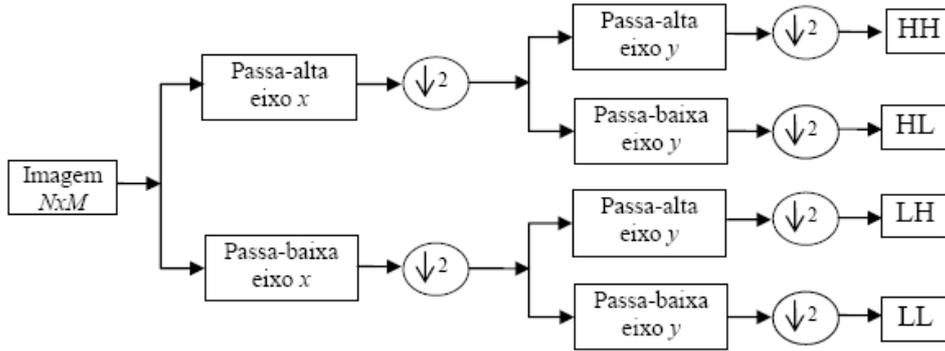


Figura 6 – Um estágio da decomposição de uma imagem digital em multiresolução.

O produto resultante de um estágio de transformação é a divisão da imagem em quatro subbandas ou quatro subimagens [12], denominadas LL, LH, HL, HH, após um nível de decomposição, como ilustra a Figura 7. A subimagem LL pode ser comparada a uma imagem correspondente à resolução $N/2 \times M/2$. As outras subimagens correspondem a imagens de detalhe que podem ser descartadas ou codificadas em aplicações de compressão de imagens.

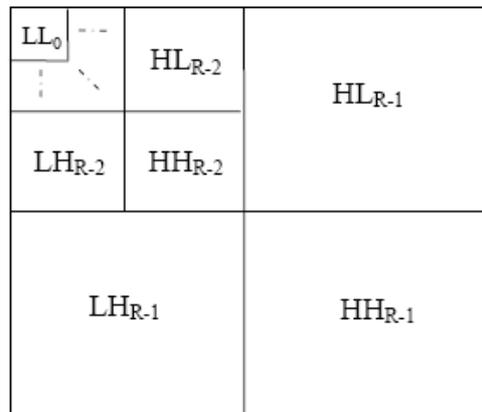


Figura 7 – Estruturas de decomposição em subbandas para vários estágios R [14].

Para se alcançar níveis mais altos de decomposição aplica-se a transformada à subbanda LL sucessivamente, o que resulta em uma divisão da imagem em múltiplas bandas. A Figura 8 mostra o resultado da decomposição até o terceiro nível da imagem Lena usando a Transformada Wavelet.

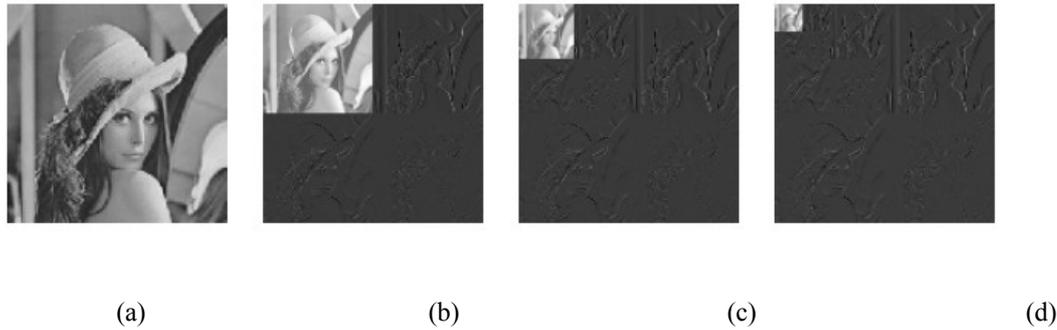


Figura 8 – (a) Imagem Lena original, (b) DWT-2D – 1 nível, (c) DWT-2D – 2 níveis, (d) DWT-2D – 3 níveis.

O processo de reconstrução da imagem consiste em vários estágios, como mostrado na Figura 9. Inicialmente as quatro subbandas do nível mais alto de decomposição são interpoladas pelo fator 2. Em seguida, cada uma delas é filtrada no eixo y pelo filtro de síntese correspondente. Após essa filtragem, somam-se as subbandas HH e HL e as subbandas LL e LH. Os resultados de cada uma destas somas são interpolados pelo fator 2 e filtrados no eixo x . Posteriormente, os resultados desta filtragem são somados para reconstruir a subbanda LL correspondente ao nível anterior de decomposição. Este processo é repetido até a imagem ser totalmente reconstruída.

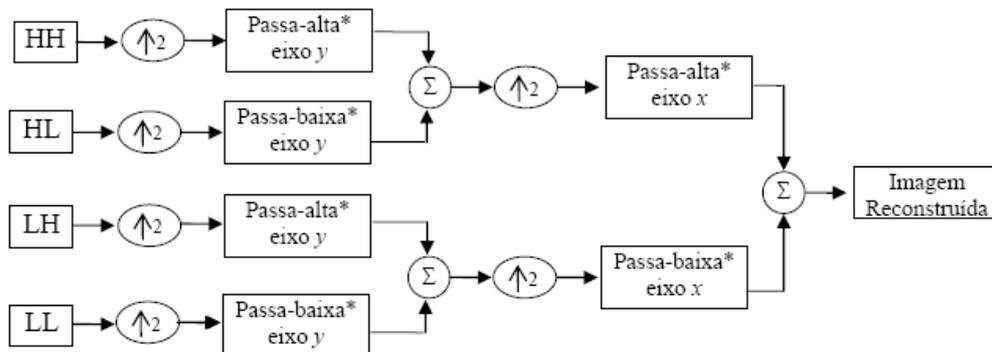


Figura 9 - Um estágio da reconstrução de uma imagem digital em multiresolução [14].

3.3 A Transformada Wavelet Haar

Uma imagem pode ser tratada como uma seqüência de coeficientes. De maneira alternativa, pode-se pensar em imagens como funções constantes por partes no intervalo

semi-aberto $[0,1)$. Para isto, utiliza-se o conceito de espaço vetorial da álgebra linear. Uma imagem de um *pixel* é uma função que é constante sobre todo o intervalo $[0,1)$. O espaço de todas estas funções é denotado por V_0 . Uma imagem de dois *pixels* tem duas partes constantes sobre os intervalos $[0,1/2)$ e $[1/2,1)$. O espaço contendo todas essas funções é denotado por V_1 . Seguindo este raciocínio, o espaço V_j inclui todas as funções constantes por partes definidas no intervalo $[0,1)$, com partes constantes sobre cada um dos subintervalos 2^{-j} [15].

As funções base para os espaços V_j são as funções de escalonamento f . Uma base simples para V_j é definida, através da função de escalonamento, em [7] como:

$$\phi_{j,k}(t) = \phi(2^j t - k), \quad k = 0, 1, \dots, 2^j - 1. \quad (3.12)$$

em que

$$\phi(t) = \begin{cases} 1, & \text{para } 0 \leq t \leq 1 \\ 0, & \text{caso contrário.} \end{cases}$$

As funções f são funções caixa (*box functions*) definidas no intervalo $[0,1]$ e são constantes por partes em subintervalos 2^j . Pode-se aproximar qualquer função nos espaços V_j pela combinação de funções base ϕ_j . As wavelets correspondentes a estas funções caixa são denominadas wavelets Haar e são definidas por:

$$\psi_{j,k}(t) = \psi(2^j t - k), \quad k = 0, 1, \dots, 2^j - 1. \quad (3.13)$$

em que

$$\psi(t) = \begin{cases} 1, & \text{para } 0 \leq t \leq \frac{1}{2} \\ -1, & \text{para } \frac{1}{2} \leq t \leq 1 \\ 0, & \text{caso contrário.} \end{cases}$$

As funções wavelet, $\psi_{j,k}(t)$ estão contidas nos espaços W_j . Na Figura 10 são mostradas as duas wavelets que geram o espaço W_1 [15].

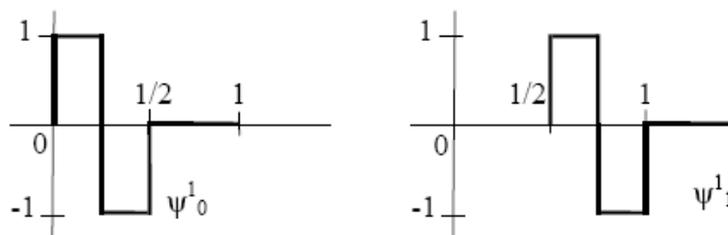


Figura 10 – As wavelets Haar para o espaço W_1 .

De acordo com a definição das funções de escalonamento e wavelet-mãe para a Transformada Wavelet Haar, os espaços V_j são formados efetuando-se a média de pares de valores adjacentes, e os espaços W_j são formados efetuando-se as diferenças entre pares de valores adjacentes. Portanto, a aplicação da função de escalonamento ou da wavelet-mãe corresponde a uma subamostragem do sinal.

Uma propriedade que é algumas vezes desejável é que as funções bases sejam normalizadas. Uma função $u(x)$ é normalizada se sua norma é igual a 1. A normalização para as bases Haar implica numa nova definição para as funções de escalonamento e wavelet-mãe, a saber:

$$\phi_{j,k}(t) = 2^{j/2} \phi(2^j t - k) \quad (3.14)$$

$$\psi_{j,k}(t) = 2^{j/2} \psi(2^j t - k) \quad (3.15)$$

em que o fator constante $2^{j/2}$ é escolhido de modo a satisfazer a condição $\langle u | u \rangle = 1$.

3.4 Análise de Textura por Transformada Wavelet

Neste trabalho adotamos a análise de textura para guiar o processo de segmentação das imagens. Para que a segmentação seja efetuada de maneira satisfatória é necessário que as propriedades de cada região da imagem sejam descritas de maneira efetiva. Estas propriedades, chamadas características, são elementos que fazem a distinção entre classes de objetos [13]. Entretanto, uma das tarefas mais complexas presentes na análise de imagens consiste em definir um conjunto de características capazes de efetuar essa descrição.

Dado que a textura encontra-se entre as características utilizadas pelos seres humanos para interpretar informações visuais sobre a distribuição espacial e a variação de luminosidade, além de descrever o arranjo estrutural das superfícies e relações entre regiões vizinhas, a utilização de informações texturais se apresenta como uma abordagem adequada para descrição de regiões da imagem. Exemplos de imagens de superfícies submetidas à corrosão são mostrados na Figura 11. Podemos observar que são apresentadas diferentes texturas.



Figura 11 – Exemplos de imagens de superfícies acometidas pela corrosão.

Embora o sistema visual humano apresente facilidade no reconhecimento e descrição de texturas, é extremamente difícil formalizar sua definição ou desenvolver um conjunto de descritores que possam ser utilizados para análise de imagens em diferentes domínios de aplicações. Tal dificuldade é refletida pela grande quantidade de definições e métodos de análise de texturas encontrados na literatura.

Normalmente, para a descrição de regiões texturizadas utiliza-se métodos de extração de características, os quais visam obter uma representação simplificada, porém significativa para cada região. Tais métodos são divididos entre as abordagens espectral, estatística e estrutural [16].

CAPÍTULO 4

ANÁLISE DE PADRÕES E CLUSTERIZAÇÃO

A análise e o reconhecimento de padrões é a ciência que trata da classificação e da descrição de uma estrutura de dados através de um conjunto de propriedades ou características.

Um padrão é uma descrição de um objeto que pode ser classificado como: concretos (espaciais: caracteres, imagens; e temporais: formas de onda, séries, etc.) e abstratos (raciocínio, soluções a problemas, etc.). Uma classe de padrões é uma família de objetos que compartilham uma mesma propriedade.

Em reconhecimento de padrões, é sempre desejável dispor de uma representação compacta e com um bom poder de discriminação de classes de padrões. Para isso, é desejável que não haja redundância entre as diferentes características dos padrões, ou seja, que não haja covariância entre as bases do espaço de características. Mas, obviamente, pode-se observar que o espaço de imagens é altamente redundante quando usado para descrever faces, por exemplo, pois cada *pixel* é altamente correlacionado com outros *pixels*.

Clusterização é a classificação não-supervisionada de dados, formando agrupamentos ou *clusters*. Ela representa uma das principais etapas de processos de análise de dados, denominada análise de *clusters* [21].

A análise de *clusters* envolve, portanto, a organização de um conjunto de padrões (usualmente representados na forma de vetores de atributos ou pontos em um espaço multidimensional – espaço de atributos) em *clusters*, de acordo com alguma medida de similaridade.

Intuitivamente, padrões pertencentes a um dado *cluster* devem ser mais similares entre si do que em relação a padrões pertencentes a outros *clusters*.

Problemas de clusterização podem ser encontrados em muitas áreas de atuação, nos mais variados contextos: recuperação de informação, segmentação de imagens, classificação de padrões, interferência filogenética, etc. [21, 28].

4.1 Análise por Componentes Principais – PCA

Segundo Jain *et al.* [17], o melhor extrator de características linear conhecido é o de análise por componentes principais (PCA). Essa transformada é amplamente utilizada pela comunidade de reconhecimento de padrões em aplicações de reconhecimento de faces. A Transformada PCA também conhecida por Transformada de Hotelling e por expansão de Karhunen-Loève, é amplamente utilizada para efetuar reconhecimento de faces [18]. A Transformada de Hotelling tem várias propriedades úteis que a tornam uma importante ferramenta para o processamento de imagens.

Considerando um conjunto de vetores do tipo \mathbf{x} , tem-se:

$$\mathbf{x} = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{bmatrix} \quad (4.1)$$

O vetor médio do conjunto é definido como:

$$m_x = E\{X\} . \quad (4.2)$$

em que $E\{\arg\}$ é o valor esperado do argumento e o subscrito denota que m está associado com o conjunto de vetores \mathbf{x} .

A matriz de covariância do conjunto de vetores é definida como:

$$C_x = E\{(\mathbf{x} - m_x)(\mathbf{x} - m_x)^T\} . \quad (4.3)$$

em que T indica a transposição. Como \mathbf{x} tem dimensão n , C_x e $\{(\mathbf{x} - m_x)(\mathbf{x} - m_x)^T\}$ são matrizes de ordem $n \times n$. O elemento c_{ii} de C_x é a variância de x_i , o i -ésimo componente dos vetores \mathbf{x} no conjunto, e o elemento c_{ij} de C_x é a covariância entre os elementos x_i e x_j desses vetores. A matriz C_x é real e simétrica. Se os elementos x_i e x_j são descorrelacionados, sua covariância é zero e, portanto, $c_{ij} = c_{ji} = 0$.

Para M amostras de vetores de um conjunto aleatório, o vetor médio e a matriz de covariância podem ser aproximados a partir de amostras por:

$$\mathbf{m}_x = \frac{1}{M} \sum_{k=1}^M \mathbf{x}_k \quad (4.4)$$

$$C_x = \frac{1}{M} \sum_{k=1}^M \mathbf{x}_k \mathbf{x}_k^T - \mathbf{m}_x \mathbf{m}_x^T . \quad (4.5)$$

Como C_x é real e simétrica, é sempre possível encontrar um conjunto de n autovetores ortonormais [19]. Sejam \mathbf{e}_i e λ_i , $i=1, 2, \dots, n$, os autovetores e autovalores correspondentes de C_x , arranjados (por conveniência) em ordem decrescente de modo que $\lambda_j \geq \lambda_{j+1}$ para $j=1, 2, \dots, n-1$. Seja A uma matriz cujas linhas são formadas a partir dos autovetores de C_x , ordenados de modo que a primeira linha de A é o autovetor correspondente ao maior autovalor, e a última linha é o autovetor correspondente ao menor autovalor.

Suponha que A é uma matriz de transformação que mapeia os \mathbf{x} em vetores denotados por \mathbf{y} , como segue:

$$\mathbf{y} = A(\mathbf{x} - \mathbf{m}_x) . \quad (4.6)$$

A Equação 4.6 é denominada Transformada de Hotelling. A média dos elementos do vetor \mathbf{y} resultante dessa transformação é zero, isto é:

$$\mathbf{m}_y = 0 \quad (4.7)$$

e a matriz de covariância dos dados transformados (\mathbf{y}) pode ser obtida em termos de A e C_x através de:

$$C_y = A C_x A^T . \quad (4.8)$$

Além disso, C_y é uma matriz diagonal cujos elementos ao longo da diagonal principal são os autovalores de C_x , isto é:

$$C_y = \begin{bmatrix} \lambda_1 & & 0 \\ & \lambda_2 & \\ & & \ddots \\ 0 & & & \lambda_n \end{bmatrix}. \quad (4.9)$$

Os elementos fora da diagonal da matriz de covariância são 0 e, portanto, os elementos do vetor \mathbf{y} são descorrelacionados. Considere que os λ_j 's são os autovalores de C_x e que os elementos ao longo da diagonal principal de uma matriz diagonal são seus autovalores. Assim, C_x e C_y possuem os mesmos autovalores. De fato, o mesmo vale para os autovetores.

Uma outra propriedade da Transformada de Hotelling diz respeito à reconstrução de \mathbf{x} a partir de \mathbf{y} . Como as linhas de A são vetores ortonormais, $A^{-1} = A^T$, e então qualquer vetor \mathbf{x} pode ser recuperado a partir do seu correspondente \mathbf{y} através da relação:

$$\mathbf{x} = A^T \mathbf{y} + \mathbf{m}_x \quad (4.10)$$

Suponhamos, entretanto, que, ao invés de usar todos os autovetores de C_x , a matriz A_K seja fornecida a partir dos K autovetores correspondentes aos K maiores autovalores, resultando a matriz de transformação de ordem $K \times n$. Os vetores \mathbf{y} possuiriam então dimensão K e a reconstrução dada na Equação 4.10 não mais seria exata. O vetor reconstruído através do uso de A_K é:

$$\hat{\mathbf{x}} = A_K^T \mathbf{y} + \mathbf{m}_x. \quad (4.11)$$

Pode-se mostrar que o erro médio quadrático entre \mathbf{x} e $\hat{\mathbf{x}}$ é dado pela expressão:

$$e_{ms} = \sum_{j=1}^n \lambda_j - \sum_{j=1}^K \lambda_j = \sum_{j=K+1}^n \lambda_j. \quad (4.12)$$

A primeira parte da Equação 4.12 indica que o erro é zero quando $K=n$, isto é, se todos os autovetores forem usados na transformação. Como os λ_j 's decaem monotonicamente, a Equação 4.12 também mostra que o erro pode ser minimizado através da seleção dos K autovetores. Assim, a

Transformada de Hotelling é ótima no sentido de que ela minimiza o erro quadrático médio entre os elementos dos vetores \mathbf{x} e suas aproximações $\hat{\mathbf{x}}$.

Concluimos, dessa forma, que se um autovetor possui autovalor associado com grande magnitude, significa que este fica em uma direção em que há uma grande variância dos padrões. Isso torna mais fácil a distinção dos padrões.

Através das Figura 12, 13 e 14 se pode visualizar o efeito da Transformada PCA ou de Hotelling para o caso bidimensional. Pode-se observar que é realizada uma rotação do espaço de forma que o primeiro vetor da nova base fique na direção em que há maior variância dos dados e o segundo fique perpendicular ao primeiro, na direção da segunda maior variação.

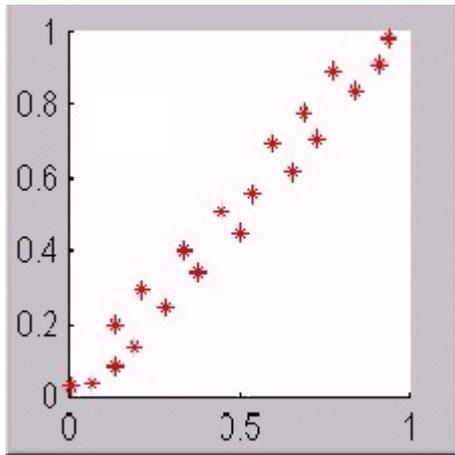


Figura 12 - Dados artificiais bidimensionais.

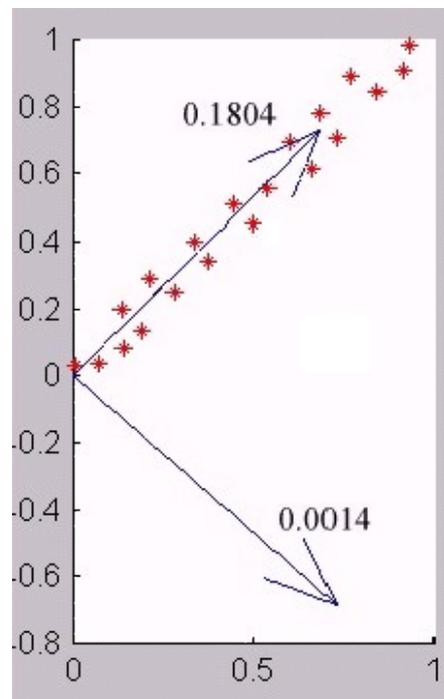


Figura 13 - Dados de teste com os autovetores da matriz de covariância e seus respectivos autovalores.

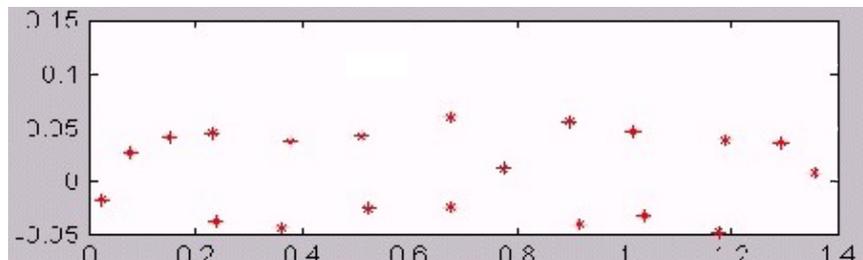


Figura 14 - Dados no espaço.

4.2 K-médias

Este é um dos algoritmos desenvolvidos para aplicações em segmentação de imagens ou agregação de *pixels*. A idéia deste algoritmo é fornecer um agrupamento de informações de acordo com os próprios dados, com base em análises e comparações entre os seus valores numéricos. Fornecendo uma classificação automática, ou seja, sem supervisão humana. Entretanto, geralmente o número de agrupamentos esperados é fornecido pelo usuário ou, este pode estabelecer o número máximo de iterações desejadas.

Primeiramente, o algoritmo gera centróides, que recebem valores iniciais aleatórios, cada um irá representar, ao final do algoritmo, um agrupamento de dados. Em seguida, são calculadas as distâncias entre cada dado, ou ocorrência, a cada um dos centróides. As classes são formadas unindo os dados ao centróide de maior proximidade, para este cálculo, geralmente é utilizada a distância euclidiana [23]. Na etapa seguinte são calculados novos valores para os centróides de cada classe, que será definido pela média de cada ocorrência pertencente a este centróide. Este processo é realizado até que não haja mais mudança nos elementos das classes ou quando é atingido o número máximo de iterações.

Para simplificar, a descrição do algoritmo pode ser apresentada em cinco passos, como encontrado em [22]:

1) Os centróides recebem valores iniciais arbitrários.

Neste passo os k centróides devem receber valores iniciais. Geralmente escolhem-se os k primeiros pontos de dados. É importante, também, colocar todos os pontos em um centróide qualquer para que o algoritmo possa iniciar seu processamento.

2) Gera-se uma matriz de distância entre cada ponto e os centróides.

Nesta etapa é calculada a distância entre cada ponto e os centróides. Esta é a parte que exige mais tempo de processamento, pois, se existem N pontos e k centróides devem ser calculadas $N \times k$ distâncias neste passo.

3) Classificar cada ponto de acordo com as suas distâncias dos centróides.

Neste passo os dados são classificados de acordo com sua distância aos centróides de cada classe. A clusterização se processa do seguinte modo: o centróide que está mais perto deste dado vai incorporá-lo, ou seja, ele irá pertencer à classe representada pelo centróide que está mais próximo.

4) Cálculo dos novos centróides para cada classe.

Nesta etapa os valores das coordenadas dos centróides são recalculados. Para cada classe que possui mais de um dado o novo valor do centróide é calculado fazendo-se a média de todos os dados que pertencem a esta classe.

5) Repetir até a convergência.

O algoritmo retorna ao passo 2 repetindo iterativamente o refinamento do cálculo das coordenadas dos centróides, até que mais nenhum dado mude de classe, ou o número máximo de iterações seja atingido.

Podemos também mostrar o funcionamento do algoritmo através da seqüência de figuras abaixo, onde cada ponto representa um dado a ser classificado.

Na Figura 15 (a) temos, em vermelho, os dados a serem agrupados e, em preto, os centróides escolhidos aleatoriamente. Na Figura 15(b) os dados foram associados aos centróides de acordo com as distâncias calculadas. A Figura 15(c) mostra mais uma iteração do algoritmo, e finalmente, na Figura 15(d) não há mais mudança da posição dos dados nos *clusters* e o algoritmo termina.

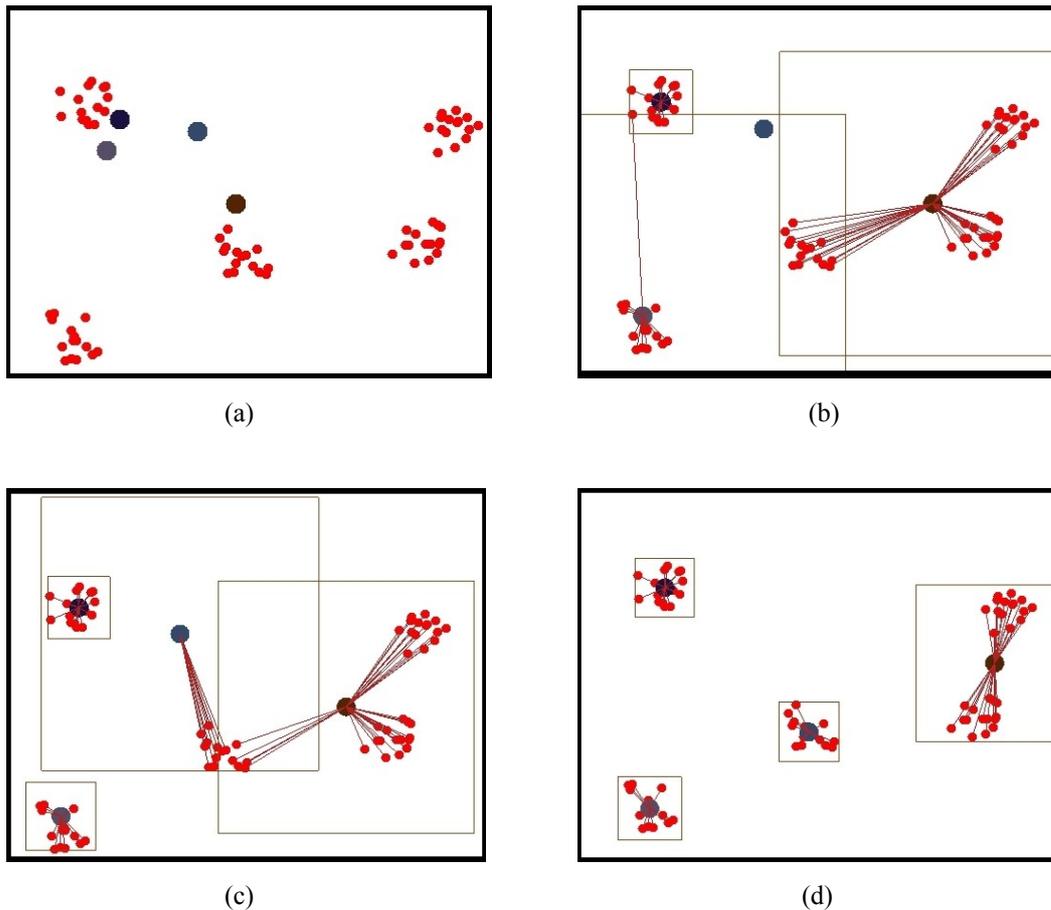


Figura 15 - (a) Inicialmente os centros (pontos pretos) são definidos aleatoriamente; (b) Os pontos vermelhos foram associados aos centros, e estes foram movidos para os respectivos centróides; (c) A associação é mostrada com mais detalhes, e os centros são movidos mais uma vez; (d) Novamente os centros são movidos, resultando na segmentação da imagem.

Observa-se que esta técnica de clusterização coloca cada ponto em apenas um *cluster*, portanto pode se dizer que este algoritmo faz uma clusterização dura (*hard clustering*). Outros algoritmos trabalham com o conceito de clusterização suave (*soft clustering*) onde existe uma métrica que diz o quão ‘dentro’ de cada classe o ponto está.

O objetivo do algoritmo k-médias é minimizar a variância dos atributos dos pontos que estão dentro de um determinado segmento. Matematicamente podemos dizer que o k-médias minimiza a função de erro quadrático definida por:

$$V = \sum_{i=1}^k \sum_{x_j \in S_i} |x_j - \mu_i|^2. \quad (4.13)$$

onde existem k segmentos S_i , com $i=1, 2, \dots, k$, e μ_i é o centróide, ou centro de um conjunto de pontos x_j , pertencentes a S_i .

Este algoritmo se tornou extremamente popular porque ele converge muito rapidamente, porém o resultado nem sempre converge para o mínimo global, podendo convergir para um mínimo local, dependendo assim da inicialização do mesmo.

Na prática, tem se observado que o número de iterações é tipicamente muito menor que o número de pontos a serem agrupados. A complexidade do algoritmo para cada iteração é de $O(Nk)$ para o cálculo da dissimilaridade entre cada ponto e os centróides, e de $O(N)$ para o cálculo dos novos valores dos centróides.

CAPÍTULO 5

METODOLOGIA ESTUDADA

A metodologia estudada apresenta cinco etapas e baseia-se no trabalho de Prince *et al.* [20]. As etapas incluem a obtenção da imagem, aplicação da Transformada Wavelet, extração e redução das características de textura, redução das características de textura por PCA, segmentação da imagem por clusterização.

Um esquema gráfico do

algoritmo pode ser visto na Figura 16:

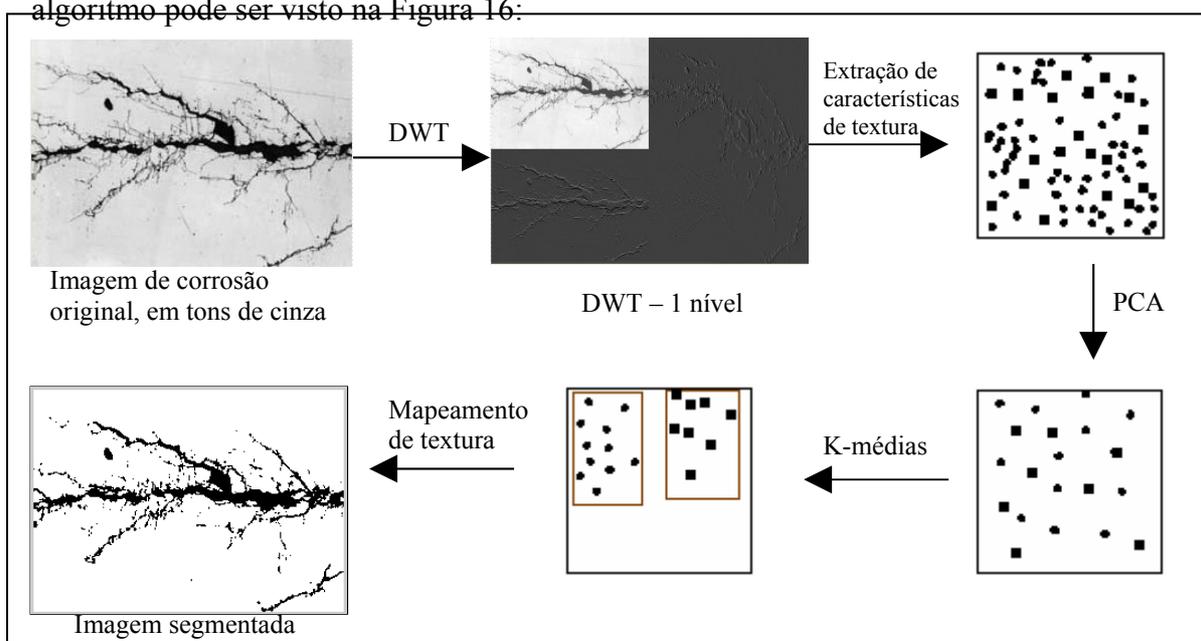


Figura 16 – Representação gráfica do algoritmo apresentado.

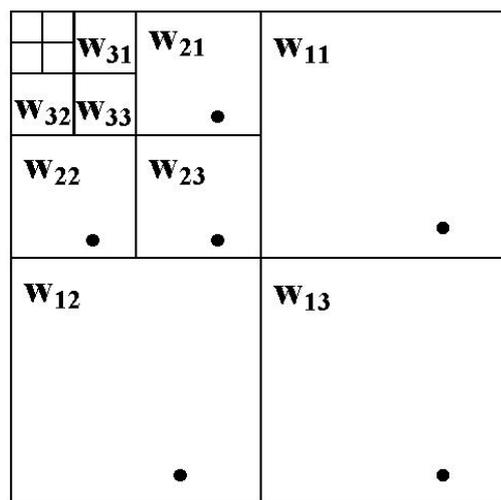
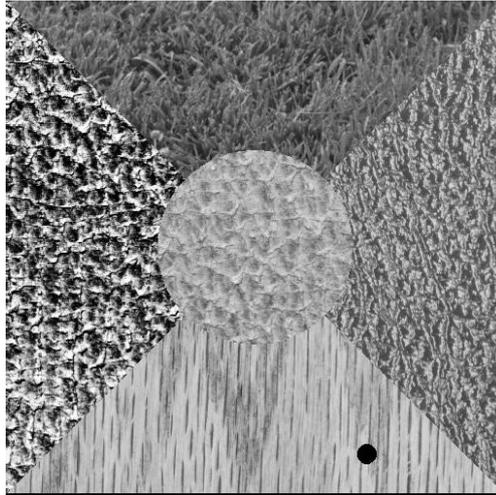
A etapa inicial está relacionada à obtenção da imagem do material afetado pela corrosão atmosférica. Fisicamente obtém-se a imagem da região que desejamos avaliar se está sendo acometida por corrosão atmosférica. A aquisição pode ser feita por câmeras digitais, ou analógicas, sendo posteriormente digitalizada. Para execução do algoritmo a imagem precisa ser transformada para escala de cinza.

Posteriormente é aplicada a Transformada Wavelet, para a avaliação da informação de textura da imagem, usamos a representação da imagem por Transformada Wavelet em k níveis de decomposição.

A extração das características de textura se dá pela utilização das subimagens obtidas no passo dos quais são extraídos vetores de características de texturas. Para cada elemento da imagem obtemos um vetor, segundo a aplicação da Equação 5.1, pelo cálculo da energia em cada escala.

$$t^{(i,j)}(x) = \left[w_{11}^{(i/2,j/2)}, w_{12}^{(i/2,j/2)}, w_{13}^{(i/2,j/2)}, w_{21}^{(i/4,j/4)}, w_{22}^{(i/4,j/4)}, w_{23}^{(i/4,j/4)}, \dots, w_{n1}^{(i/2^n,j/2^n)} \right] \quad (5.1)$$

em que $w_{nm}^{(i/2^n,j/2^n)}$ é a energia do *pixel* (i, j) na escala de decomposição n , e $m \in \{1, 2, 3\}$, sendo 1 a decomposição vertical, 2 a decomposição horizontal e 3 a decomposição diagonal, como mostrado na Figura 17. O cálculo da energia foi feito utilizando a Equação 2.2.



(a)

(b)

Figura 17 – (a) Exemplo de imagem com diferentes padrões de textura; (b) Decomposição wavelet em 3 níveis.

A redução das características de textura foi feita utilizando PCA. Algumas dessas características podem conter informação redundante ou irrelevante sobre textura e devem ser removidas para reduzir o esforço computacional. Para tanto, foi escolhido o método de Análise por Componentes Principais (PCA), diminuindo assim, a dimensionalidade do problema.

A conclusão do processo se dá pela segmentação da imagem por clusterização. Para tal fim, é usado o algoritmo k-médias para separar o vetor em

clusters, que serão rotulados. A imagem segmentada é obtida aplicando o rótulo dos *clusters* na imagem original, separando as informações de textura.

CAPÍTULO 6

RESULTADOS, CONCLUSÕES E PERSPECTIVAS

6.1. Resultados

A metodologia exposta no Capítulo 5 é aplicada a várias imagens que apresentam diversos tipos de textura, para avaliação do método. Algumas imagens utilizadas nos testes foram geradas artificialmente. Outras imagens são reais e foram obtidas via ultrassom [5].

Na Figura 18 são mostradas a imagem original, a decomposição Wavelet da mesma e a segmentação das duas diferentes texturas presentes na imagem.

Neste caso a segmentação foi mais bem sucedida, quando foi aplicado o filtro da média após a segmentação, corrigindo assim, pequenas áreas erroneamente agrupadas.

Esses enganos no agrupamento se devem principalmente à falta de conhecimento da natureza dos dados pelo algoritmo k-médias. Caso haja conhecimento a priori da natureza e da estrutura da imagem, poderia ser realizado um refinamento no algoritmo, que diminuiria o número de erros.

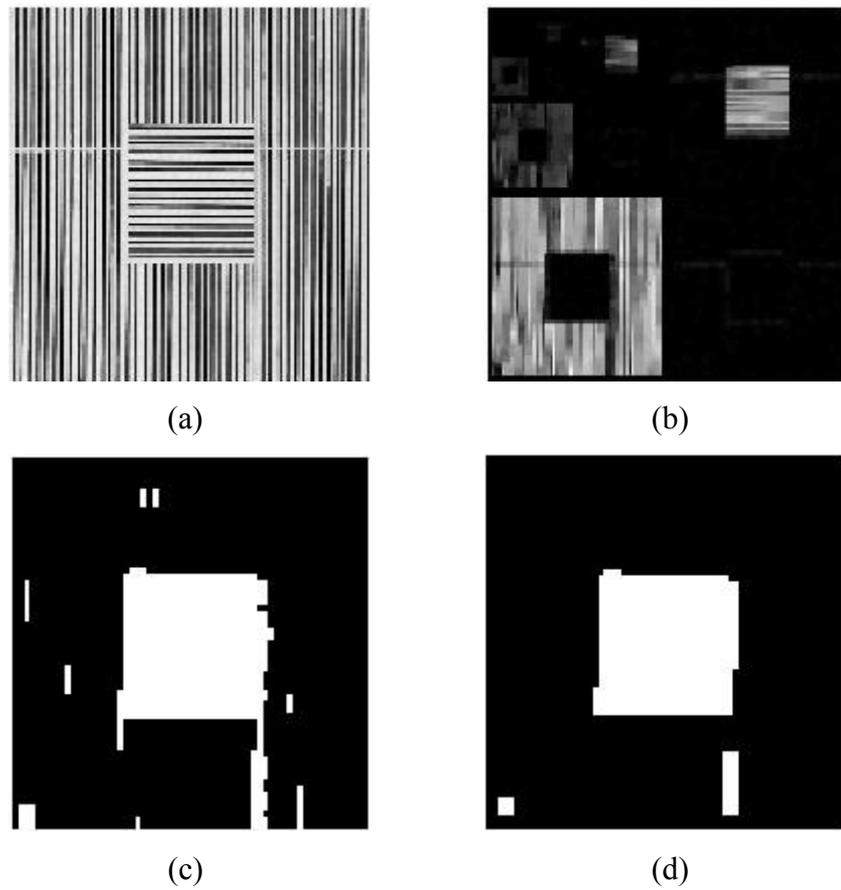


Figura 18 – (a) Imagem original; (b) Transformada Wavelet para 3 níveis de decomposição; (c) Imagem segmentada e (d) Imagem segmentada filtrada [20].

Observa-se na Figura 19 (a) que a imagem original contém cinco padrões de textura distintos e a Figura 19 (b) ilustra a segmentação da mesma, utilizando o método apresentado neste trabalho.

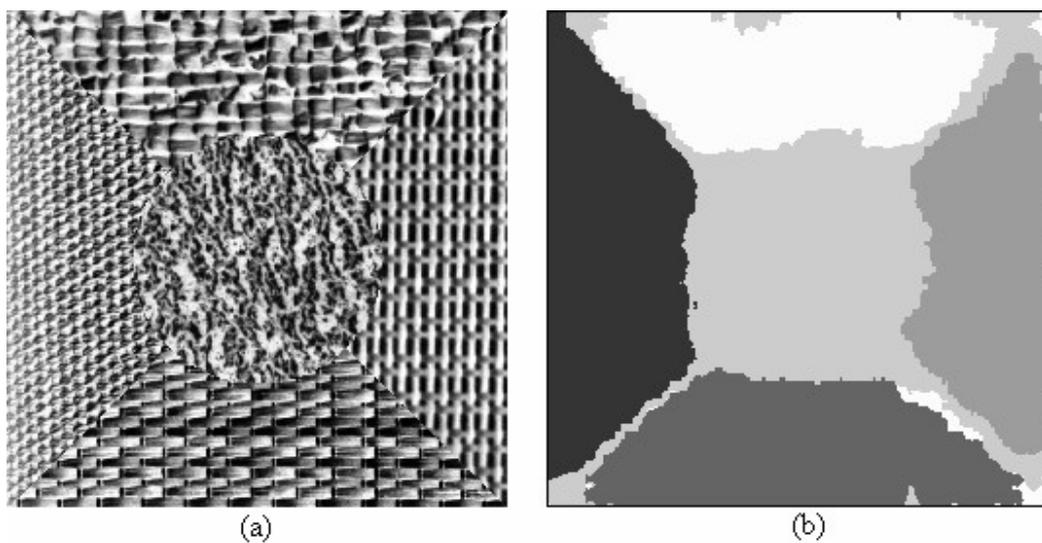


Figura 19 – (a) Imagem original (5 padrões texturais); (b) Imagem segmentada [30].

Pode-se observar que houve pequenos erros na segmentação final, principalmente nas regiões de fronteira entre as diferentes texturas.

A Figura 20 ilustra o resultado do algoritmo de segmentação aplicado a uma imagem com dois diferentes padrões de textura. Nesta imagem houve menos erros de agrupamento, o resultado final pode ser considerado satisfatório.

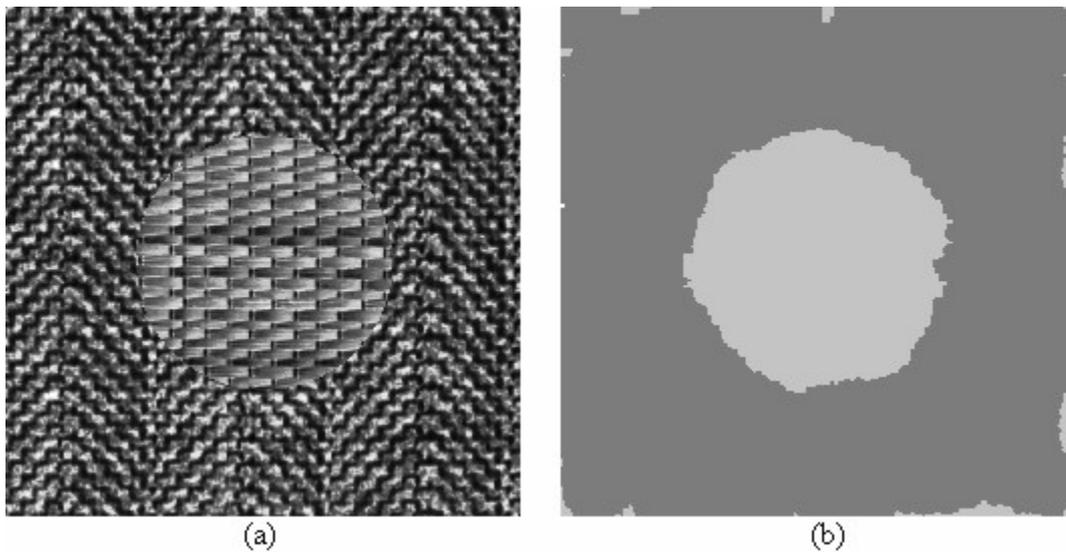


Figura 20 - (a) Imagem original (2 padrões texturais); (b) Imagem segmentada [30].

Na Figura 21 observamos, na coluna da esquerda, imagens obtidas por ultra-som de superfícies atingidas por corrosão e, na coluna da direita a segmentação obtida [5].

Através dos resultados mostrados, podemos verificar nas Figuras 21 (b), (d) e (f) que as diferentes texturas foram bem segmentadas e os pontos de corrosão foram bem localizados.

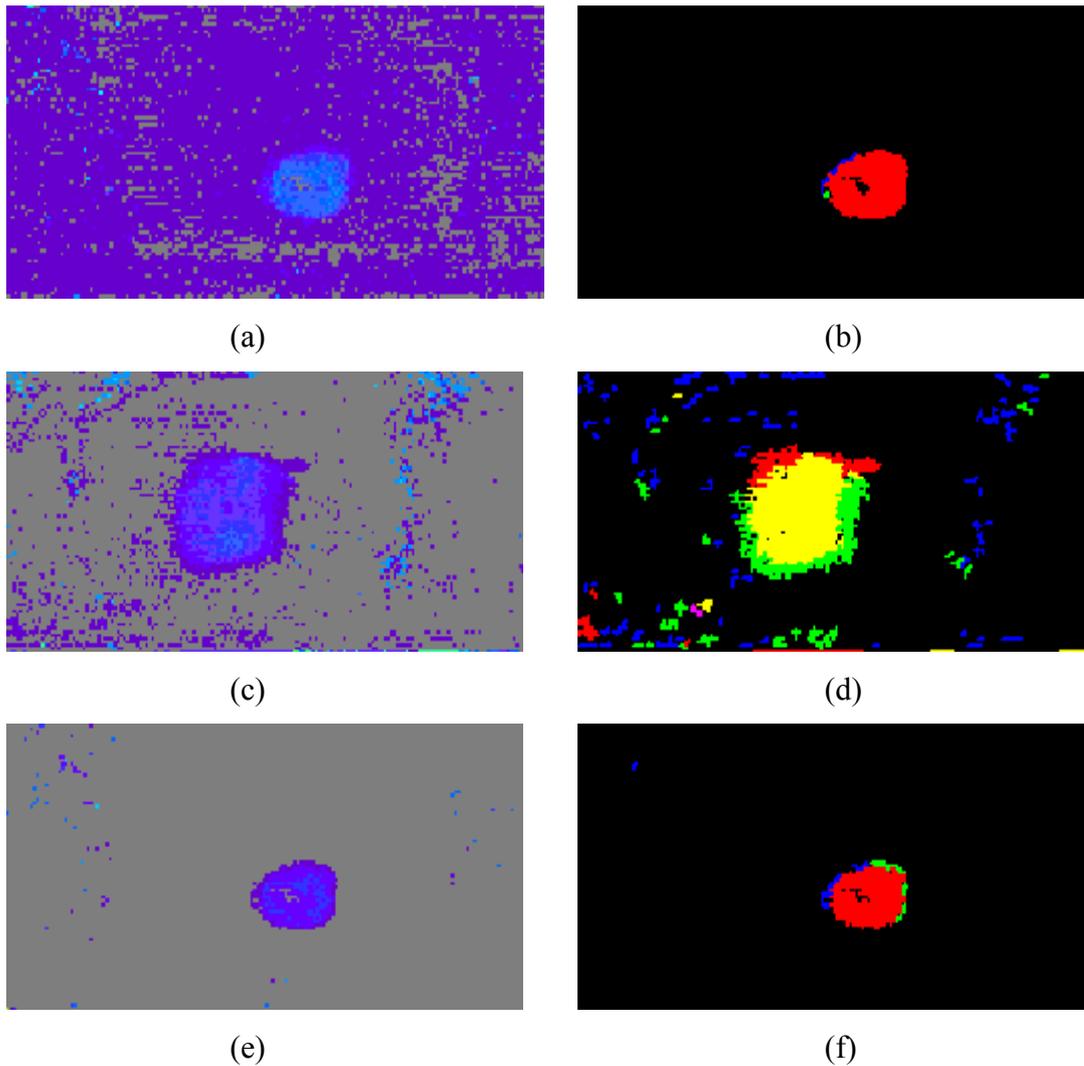


Figura 21 - (a), (c), (e) Imagens originais; (b), (d), (f) Suas respectivas versões segmentadas [5].

Utilizando a segmentação da imagem da superfície submetida à corrosão atmosférica, podemos obter a localização da corrosão e numa outra etapa de processamento quantificar a área da região corroída. Essas informações podem ser utilizadas para descoberta e/ou acompanhamento de processos corrosivos.

6.2. Conclusão

Neste trabalho foi apresentada uma metodologia disponibilizada na literatura e usada em [20, 30] para segmentação de imagens de superfícies metálicas submetidas à corrosão atmosférica com base na informação de textura que foi investigada e estudada. Observamos que uma superfície metálica quando atingida por corrosão é possível avaliar e até mesmo quantificar o desgaste do material utilizando a informação textural e fazendo uso da metodologia descrita neste trabalho. Foram apresentados resultados que mostram a eficácia do algoritmo para o qual o mesmo é proposto. A grande vantagem da metodologia exposta consiste no fato de que estando as áreas atingidas pela corrosão devidamente identificadas, providências técnicas para que a mesma não cause maiores danos podem ser tomadas.

A utilização de técnicas de processamento digital de imagens para avaliação do processo corrosivo em superfícies metálicas possibilita a redução de gastos com manutenção de equipamentos, efeitos indesejáveis decorrentes da fadiga de técnicos e a subjetividade da avaliação inerente à experiência dos mesmos.

Os experimentos apresentados neste trabalho envolvem apenas a corrosão atmosférica, mas a análise textural pode ser aplicada no estudo de outros tipos de corrosão e em outras áreas de processamento digital de imagens como sensoriamento remoto por imagens.

6.3. Perspectivas

Este trabalho pode ser adaptado para a detecção de outros processos corrosivos em superfícies metálicas ou concreto sujeitas a ação de corrosão. Sistemas de monitoramento de corrosão em diversas aplicações industriais, inspeção de fuselagem de aeronaves, dutos de transporte de óleo e gás, cascos de navios, podem constituir outras aplicações para o sistema apresentado.

Com este estudo preliminar pretendo prosseguir na linha de estudos em processamento digital de imagens na pós-graduação e assim me aprofundar mais nesta área.

Bibliografia

- [1] LIVENS, S. *Image Analysis for Material Characterization*. Tese de Doutorado (PHD), Departamento de Física, Universidade de Antuérpia, Holanda, 1998.
- [2] LIVENS, S. *et al. A texture analysis approach to corrosion image classification*. *Microscopy, Microanalysis, Microstructures*, v. 8, n. xx, p. 57–72, 1996.
- [3] SERRA, J. *Image Analyses and Mathematical Morphology*, Londres, Reino Unido, Academic Press, 1982.
- [4] WOUWER, G. V. *Wavelets for Multiscale Texture Analysis*. Tese de Doutorado (PHD), Departamento de Física, Universidade de Antuérpia, Holanda, 1998.
- [5] REBBAPRAGADA, S. *Intelligent Computational Methods for Corrosion Damage*. Dissertação de Mestrado, Universidade de Purdue, 2000.
- [6] ANTONINI, M.; BARLAUD, M. *Image Coding Using Wavelet Transform*. *IEEE Trans. on Image Processing*, v. 1, n. 2, p. 205-219, 1992.
- [7] STARCK, J. L.; MURTAGH, F.; BIJAOU, A. *Image Processing and Data Analysis: The Multiscale Approach*. Cambridge, Cambridge Univ. Press, 1998.
- [8] MORETTIN, P. A. *Ondas e Ondaletas: Da Análise de Fourier a Análise de Ondaletas*. São Paulo, Editora da Universidade de São Paulo, 1999.
- [9] MALLAT, S. G. *A Theory for Multiresolution Signal Decomposition: The Wavelet Transform*. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, v. 2, n. 7, p. 674-693, jul. 1989.
- [10] OLIVEIRA, L. F., OLIVEIRA, A. F., CAVALCANTI, C. E. *Compressão de Imagens Usando Wavelet e Curva de Peanno-Hilbert*. Disponível em <http://virtual.inesc.pt/virtual/8epcg/actas/c22/index.htm>. Acesso em 02 de novembro de 2007.
- [11] MULCAHY, C. *Image Compression Using the Haar Wavelet Transform*. *Spelman College Science & Mathematics Journal*, v. 1, n. 1, p. 22-31, 1997.
- [12] GRAPS, A. *An introduction to wavelets*. Em *IEEE Computational Science and Engineering*, Los Vaqueros Circle, Los Alamitos, EUA, 1995.
- [13] NADLER, M. E SMITH, E. P. *Pattern Recognition Engineering*. John Wiley & Sons, Inc, Nova Iorque, EUA, 1993.
- [14] CRUZ, J. V. *Método adaptativo de compressão de imagens monocromáticas por usando a entropia como critério de seleção*. Dissertação de Mestrado. Universidade Federal do Ceará, Fortaleza, 2004.

- [15] STOLLNITZ, E.; DEROSE, T.; SALESIN, D. *Wavelets for Computer Graphics: A Primer Part 1*. IEEE Computer Graphics and Applications, v. 15, n. 3, p. 76-84, 1995.
- [16] PALM, C. *Color Texture Classification by Integrative Co-occurrence Matrices*. Pattern Recognition 37, 965-976, Maio 2004.
- [17] JAIN, A. K.; ROBERT P. W. D.; JIANCHANG M. *Statistical pattern recognition: A review*. IEEE Trans. on Pattern Analysis and Machine Intelligence, v. 22(1), p. 4-37, Janeiro, 2000.
- [18] KIRBY, M.; SIROVICH, L. *Application of the karhunen-loève procedure for the characterization of human faces*. IEEE Trans. on Pattern Analysis and Machine Intelligence, v. 12(1), p. 103-108, Janeiro, 1990.
- [19] NOBLE, B. Applied Linear Algebra, Prentice-Hall, Englewood Cliffs, N. J., 1969.
- [20] PRINCE, S.; PETKOVIĆ, T.; *et al.* *Texture analysis using Wavelet Transform*. SSIP, 2001.
- [21] JAIN, A.; ZONGKER, D. *Feature selection: Evaluation, application and small shape performance*. IEEE Trans. on Pattern Analysis and Machine Intelligence, v. 19, n. 2, p. 153–158, Fevereiro 1997.
- [22]
http://www.imasters.com.br/artigo/4709/sql_server/data_mining_na_pratica_algoritmo_k-means/. Acesso em 03 de novembro de 2007.
- [23] GONZALEZ, R.; WOODS, R. *Processamento de Imagens Digitais*. São Paulo, Brasil: Edgard Blücher Ltda, 2000.
- [24] GENTIL, V. *Corrosão*, Ed. 14, LTC, Brasil, 1996.
- [25] CHOI, C. *Morphological analysis and classification of types of surface corrosion damage by digital image processing*. Corrosion Science, p. 1–15, 2005.
- [26] DUTRA, A. *Petroleum pipeline inspection*. Proceedings of 15th Symposium on Integrated Circuits and Systems, p. 1–4, 2002.
- [27] H.BARBOSA, C. *et al.* *Automation of squid nondestructive evaluation of steel plates by neural networks*. IEEE Trans. on Applied Superconductivity, v. 9, n. 2, p. 3475–3478, 1999.
- [28] MARTINS, M. P.; Guimarães L. N. F. *Classificador de texturas por redes neurais*, II Congresso Brasileiro de Computação – CBComp 2002 Inteligência Artificial.
- [29] DAUBECHIES, I. *Orthonormal bases of compactly supported wavelets*. Comm. on pure and applied math., XLI:909-996, 1988.

[30] PIMENTEL FILHO, C. A. F. ; MONTALVÃO J.; REHEM, A. *Um estudo de segmentação de imagens baseado em textura*. Disponível em fragapimentel.googlepages.com/Umestudodesegmentacaodeimagensbasead.pdf acessado em 12 de novembro de 2007.