

## Capítulo 7

### Algoritmos de Visão Computacional

Existem diversos algoritmos de processamento de imagens que podem ser utilizados para o tratamento de imagens médicas, especificamente de imagens de úlceras dermatológicas. Esse tratamento de imagens compreende o pré-processamento, para se corrigir deficiências provenientes da aquisição das imagens e extração de características, que têm por função fornecer resultados computacionais significativos das imagens.

Neste capítulo são enumerados algoritmos utilizados neste trabalho, com o pré-processamento compreendendo a equalização de histogramas, e a extração de características sendo realizada através de texturas e características de Haralick. Alguns exemplos de aplicações em medicina utilizando a análise por texturas para a extração de características são também discutidos.

#### 7.1. Equalização de Histograma

A equalização do histograma em níveis de cinza é conveniente quando se deseja corrigir o contraste em imagens que apresentam um baixo contraste. Desse modo, consegue-se uniformizar a distribuição apresentada pelo histograma, sobressaindo, assim, diversos níveis de cinza que anteriormente quase não eram notados (PHILIPS, D. (1994)).

Dessa forma, têm-se como resultado um histograma de formato mais plano que o histograma originalmente usado, onde o número (percentual) de pixels de qualquer nível de cinza é praticamente o mesmo. Para isso, é usada uma função auxiliar, denominada função de transformação ou, função de distribuição acumulada da

distribuição de probabilidades original, expressa por (FILHO, O. M.; NETO, H. V. (1999)):

$$s_k = T(r_k) = \sum_{j=0}^k \frac{n_j}{n} = \sum_{j=0}^k P_r(r_j),$$

onde  $0 \leq r_k \leq 1$ ,  $k=0, 1, \dots, L-1$ .

Em imagens médicas, com a equalização do histograma, consegue-se realçar diversos pontos, antes não visíveis, devido ao baixo contraste geral da imagem. Isso permite com que determinadas estruturas da imagem sejam detectadas mais apropriadamente.

## 7.2. Texturas

A análise de imagens através de texturas vêm sendo utilizada para a diferenciação de diversos tipos de estruturas encontrados na natureza. Como exemplo de tais aplicações, pode-se citar aplicações em análise de imagens aéreas ou de satélite, imagens geológicas (HARALICK, R. M.; SHANMUGAM, K. (1973)), imagens médicas para o estudo de microcalcificações e regiões suspeitas em mamografias (MEERSMAN, D. ET AL. (1998)), (GUPTA, R.; UNDRILL P. E. (1996)), detecção e avaliação do mal de Alzheimer em imagens de ressonância magnética (BURRILL, J. H. P. (1999)) ou até na diferenciação e contagem de pólen em plantas, como mostrado em (TRELOAR, W. J. (1993)).

Diversos tipos de características podem ser extraídas a partir de imagens de texturas, tais como características baseadas em estatísticas de segunda ordem, podendo ser as mesmas encaixadas na etapa de extração de características, fornecendo informações de extrema relevância para uso em sistemas que empreguem recursos de visão computacional.

### 7.2.1. Definição de Textura

Texturas podem ser definidas como um conjunto de determinados padrões que podem ocorrer na natureza, apresentando um formato repetitivo ou não. Esses padrões são observados abundantemente no dia-a-dia, onde uma simples parede de tijolos pode ser um exemplo interessante de texturas repetitivas, com o posicionamento de cada tijolo sobreposto um ao outro, juntamente com suas camadas de cimento formando um padrão. Como um exemplo de texturas não repetitivas, pode-se ter estruturas geológicas, como as mostradas em HARALICK, R. M.; SHANMUGAM, K. (1973), onde são capturadas imagens de texturas de reservatórios rochosos, ou seja, texturas completamente diferentes uma das outras, podendo as mesmas serem submetidas à uma diferenciação ou classificação de suas características.


Existem dois tipos de análises básicas em texturas: a análise por micro-granulações e a por macro-granulações. A primeira refere-se ao estudo de micro-padrões de uma determinada imagem, ou textura, onde são analisadas texturas que possam ter uma relevância em termos de suas micro-estruturas. Deve-se atentar para o fato de que, em uma imagem computacional, essas micro-granulações são medidas a partir de valores de pixels, onde o menor valor a ser obtido seria o de um pixel e suas respectivas vizinhanças. Se houvesse a necessidade de se obter uma maior precisão para a análise desse tipo de imagens, deveriam ser utilizados recursos mais eficientes de captura das imagens, onde houvesse uma maior resolução obtida na imagem final a ser utilizada. No caso da análise por macro-granulações, podem ser analisadas estruturas maiores, denominadas macro-estruturas, de modo semelhante ao utilizado na análise de micro-granulações. Para esse fim, utiliza-se imagens com resolução menor que as anteriores ou aumenta-se a distância utilizada entre pixels, de modo a considerar como vizinhos aqueles pixels que estejam a um certo distanciamento  $d$  uns dos outros.

## 7.2.2. Classificação de Texturas


Texturas podem ainda ser classificadas em dois tipos, segundo PRATT, W. K. (1991):

- artificiais
- naturais

As texturas ditas artificiais são aquelas que consistem em arranjos de símbolos, tais como segmentos de linhas, pontos, estrelas, etc., dispostos sobre um fundo neutro, como apresentado na Figura 7.1. Já as texturas naturais são compostas por cenários encontrados na natureza, contendo arranjos de pixels do tipo semi-repetitivos. Alguns exemplos compreendem areia e grama, como mostra a Figura 7.2.



**Figura 7.1: Exemplos de texturas artificiais, onde pode ser observado um certo padrão repetitivo (PRATT, W. K. (1991)).**



**Figura 7.2:** Exemplos de texturas naturais, sendo a primeira, grama e a segunda, areia (PRATT, W. K. (1991)).

### 7.2.3. Abordagens para a descrição de texturas

GONZALEZ, R. C.; WOODS, R. E. (1993) citam a existência de três principais abordagens que podem ser utilizadas na descrição de texturas:

- espectral
- estrutural
- estatística

A abordagem espectral diz respeito às propriedades baseadas no espectro de Fourier, onde pode ser detectada a existência de padrões periódicos ou semi-periódicos (KULKARNI A. D. (1994)).

A abordagem estrutural visualiza cada textura como sendo formada pela repetição de primitivas ou padrões, estes obedecendo à alguma regra de posicionamento para a sua geração. Esse tipo de abordagem aproveita o uso de gramáticas, utilizadas para a descrição dessas primitivas, conforme BALLARD, D. H.; BROWN C. M. (1982).

No caso da abordagem estatística, são utilizadas medidas estatísticas para descrever as texturas. Por serem medidas que podem ser aplicadas às texturas que não apresentam boa regularidade (BALLARD, D. H.; BROWN C. M. (1982)), essa

foi a abordagem escolhida para uso neste trabalho, porque as imagens das úlceras podem ser tratadas como texturas não repetitivas.

#### 7.2.4. Abordagem Estatística

A análise de imagens e extração de suas características através da abordagem estatística propicia uma descrição da mesma através de regras estatísticas que governam a distribuição e a relação entre seus níveis de cinza. Vários tipos de medidas podem ser extraídos de uma distribuição em níveis de cinza das imagens, normalmente sendo utilizadas imagens em 8 bits, ou 256 níveis de cinza.

Alguns tipos de medidas estatísticas podem ser citadas, como o cálculo de média, variância, desvio padrão, energia ou entropia. No entanto, pode-se classificar a abordagem estatística em dois tipos mais importantes, sendo a abordagem de primeira ordem, onde se pode extrair características a partir do uso de histogramas de primeira ordem e a abordagem de segunda ordem, onde são utilizados histogramas de segunda ordem, sendo que estes últimos permitem uma diferenciação espacial da distribuição de níveis de cinza em uma imagem ou uma textura.

#### 7.2.5. Abordagem Estatística de Primeira Ordem

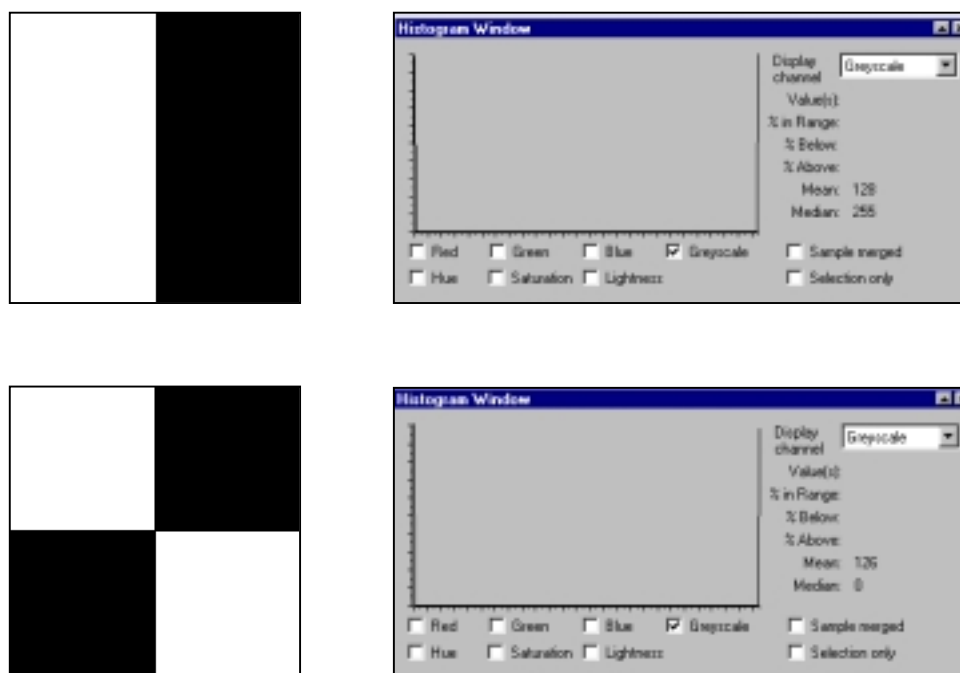
A análise estatística de primeira ordem diz respeito à distribuição de níveis de cinza em uma imagem, onde se usa o histograma de primeira ordem como base para a extração de suas características. Entre essas características podem ser citadas a média, desvio-padrão, coeficiente de assimetria e de curtose.

O histograma de uma imagem pode ser definido pela função discreta  $p(z_i) = n_i / n$ , onde  $z_i$  é o  $i$ -ésimo nível de cinza,  $n_i$  é o número de pixels da imagem com este nível de cinza e  $n$  é o número total de pixels da imagem. Desse modo, pode-se dizer que o histograma de uma imagem fornece as probabilidades de ocorrência dos níveis de cinza  $i$  nessa imagem, sem a preocupação de localização espacial.

### 7.2.6. Abordagem Estatística de Segunda Ordem

A abordagem estatística de segunda ordem leva em conta o posicionamento espacial relativo da ocorrência dos níveis de cinza em uma imagem, característica não atendida quando se faz uso de histogramas de primeira ordem. Desse modo, uma imagem que contenha uma mesma quantidade de diferentes níveis de cinza que outra, diferenciando-se somente em termos do posicionamento dos mesmos, irá apresentar, conforme a abordagem de primeira ordem, um mesmo histograma, ou seja, imagens como as da Figura 7.3 serão avaliadas como a mesma, pois o histograma de primeira ordem das duas é igual. Estatísticas de segunda ordem ou maiores permitem tal diferenciação de imagens.

Seguindo a abordagem de segunda ordem, as duas imagens podem ser diferenciadas, mesmo tendo histogramas de primeira ordem iguais, pois, nesse caso, é levado em conta o posicionamento relativo dos pixels das imagens (HARALICK, R. M. *et al.* (1973)), (PRATT, W. K. (1991)), para a obtenção de medidas estatísticas.



**Figura 7.3: Duas imagens diferentes, compostas de dois níveis de cinza e seus respectivos histogramas de primeira ordem, que não permitem a diferenciação existente entre as mesmas. A distinção entre as imagens só é possível através da análise de segunda ordem, onde é levada em conta a distribuição espacial dos pixels das imagens.**


### 7.3. Características de Haralick

HARALICK, R. M. *et al.* (1973) descrevem uma metodologia de classificação de imagens a partir de estatística de segunda ordem, onde são definidas diversas características advindas do cálculo de matrizes de coocorrência, que são matrizes que contam as ocorrências de níveis de cinza em uma imagem. Essas características servem como medida para a diferenciação de texturas que não seguem um determinado padrão de repetitividade, fornecendo informações relevantes para a classificação das mesmas, como observado em HARALICK, R. M.; SHANMUGAM, K. (1973).

#### 7.3.1. Matrizes de Coocorrência

Matrizes de coocorrência (GLCM - *gray level cooccurrence matrix*) são matrizes que mostram a organização espacial da ocorrência de níveis de cinza em uma imagem. São dispostas em uma organização bi-dimensional (histograma bi-dimensional) de níveis de cinza, onde pares de pixels são separados por uma relação espacial fixa. Esta relação define a distância e a direção ( $d, \theta$ ), que um pixel de referência possui em relação ao pixel vizinho.

Nos cálculos para obtenção dessas matrizes, a variação da direção entre pixels vizinhos é feita em termos angulares, onde são utilizados quatro direcionamentos: 0, 45, 90 e 135 graus. A Figura 7.4 mostra essas variações.



**Figura 7.4: Variações angulares utilizadas nos cálculos das matrizes de coocorrência.**



Como proposto em HARALICK, R. M. *et al.* (1973), esses quatro direcionamentos dão origem a quatro matrizes de coocorrência distintas. A métrica empregada para o cálculo da distância entre dois pixels é a seguinte:

$$d((k, l), (m, n)) = \max \{|k - m|, |l - n|\}$$

onde  $(k, l)$  e  $(m, n)$  são as coordenadas dos dois pixels em questão.

As equações para a contagem da ocorrência dos pixels em uma imagem  $f$ , dispostos a uma distância  $d$  um do outro, nas quatro direções 0, 45, 90 e 135 graus, são apresentadas abaixo:

$$P(i, j, d, 0^\circ) = \#\{(k, l), (m, n) \in f \mid k - m = 0, |l - n| = d, f(k, l) = i, f(m, n) = j\}$$

$$P(i, j, d, 45^\circ) = \#\{(k, l), (m, n) \in f \mid (k - m = d, l - n = -d) \text{ ou } (k - m = -d, l - n = d), \\ f(k, l) = i, f(m, n) = j\}$$

$$P(i, j, d, 90^\circ) = \#\{(k, l), (m, n) \in f \mid |k - m| = d, l - n = 0, f(k, l) = i, f(m, n) = j\}$$

$$P(i, j, d, 135^\circ) = \#\{(k, l), (m, n) \in f \mid (k - m = d, l - n = d) \text{ ou } (k - m = -d, l - n = -d), \\ f(k, l) = i, f(m, n) = j\}$$

onde  $\#$  denota o número de elementos do conjunto.

Tomando-se uma imagem em termos dos valores dos níveis de cinza em cada pixel da mesma, pode-se iniciar o cálculo para a obtenção das matrizes de coocorrência a partir da escolha de um pixel de referência, respeitando-se a distância  $d$  e o direcionamento (em graus).

São mostrados nas Figuras 7.5, 7.6, 7.7 e 7.8, exemplos de cálculos das quatro matrizes de coocorrência, para os quatro direcionamentos mencionados, a partir de uma matriz numérica representando uma imagem I.

As matrizes de coocorrência são organizadas em  $N_g \times N_g$  dimensões, onde  $N_g$  é a quantidade de níveis de cinza que a imagem  $I$  possui.

$$I = \begin{vmatrix} 0 \leftrightarrow 0 & 1 & 1 \\ 0 \leftrightarrow 0 & 1 & 1 \\ 0 & 2 & 2 & 2 \\ 2 & 2 & 3 & 3 \end{vmatrix}, \quad A(i, j, 1, 0^\circ) = \begin{vmatrix} 4 & 2 & 1 & 0 \\ 2 & 4 & 0 & 0 \\ 1 & 0 & 6 & 1 \\ 0 & 0 & 1 & 2 \end{vmatrix}$$

Figura 7.5: Contagem do número de ocorrências do nível de cinza 0 para  $d=1$  e  $\theta=0$ , como mostrado nas setas.

$$I = \begin{vmatrix} 0 \nearrow 0 & 1 & 1 \\ 0 \nearrow 0 & 1 & 1 \\ 0 & 2 & 2 & 2 \\ 2 & 2 & 3 & 3 \end{vmatrix}, \quad A(i, j, 1, 45^\circ) = \begin{vmatrix} 4 & 1 & 0 & 0 \\ 1 & 2 & 2 & 0 \\ 0 & 2 & 4 & 1 \\ 0 & 0 & 1 & 0 \end{vmatrix}$$

Figura 7.6: Contagem do número de ocorrências do nível de cinza 0 para  $d=1$  e  $\theta=45^\circ$ .

$$I = \begin{vmatrix} 0 \updownarrow 0 & 1 & 1 \\ 0 \updownarrow 0 & 1 & 1 \\ 0 & 2 & 2 & 2 \\ 2 & 2 & 3 & 3 \end{vmatrix}, \quad A(i, j, 1, 90^\circ) = \begin{vmatrix} 6 & 0 & 2 & 0 \\ 0 & 4 & 2 & 0 \\ 2 & 2 & 2 & 2 \\ 0 & 0 & 2 & 0 \end{vmatrix}$$

Figura 7.7: Contagem do número de ocorrências do nível de cinza 0 para  $d=1$  e  $\theta=90^\circ$ .

$$I = \begin{vmatrix} 0 & 0 & 1 & 1 \\ 0 & 0 & 1 & 1 \\ 0 & 2 & 2 & 2 \\ 2 & 2 & 3 & 3 \end{vmatrix}, \quad A(i, j, 1, 135^\circ) = \begin{vmatrix} 2 & 1 & 3 & 0 \\ 1 & 2 & 1 & 0 \\ 3 & 1 & 0 & 2 \\ 0 & 0 & 2 & 0 \end{vmatrix}$$

Figura 7.8: Contagem do número de ocorrências do nível de cinza 0 para  $d=1$  e  $\theta = 135^\circ$ .

Portanto, cada elemento da matriz de coocorrência corresponde à contagem do número de ocorrência dos pares de níveis de cinza  $i$  e  $j$ , com uma distância  $d$  e direção  $\theta$ .

A seguir, é feita uma normalização dessas matrizes, onde constantes de normalização  $R$  são definidas para cada  $\theta$ :

$$R / d, 0^\circ = 2 * N * (M - d)$$

$$R / d, 45^\circ = 2 * (N - d) * (M - d)$$

$$R / d, 90^\circ = 2 * M * (N - d)$$

$$R / d, 135^\circ = 2 * (M - d) * (N - d)$$

Por fim, têm-se as matrizes de coocorrência já normalizadas  $P$  calculadas por:

$$P(i, j, d, \theta) = A(i, j, d, \theta) / R / d, \theta$$

Essas matrizes podem, agora, ser utilizadas para diversos cálculos estatísticos de segunda ordem, como no caso da extração de características de Haralick.

### 7.3.2. Descrição de Algumas Características de Haralick

Algumas características de Haralick são descritas a seguir, em termos de sua significância (HARALICK, R. M. *et al.* (1973)) (AKSOY, S; HARALICK, R. M. (1999)) (ROSENFELD, A.; KAK, A. C. (1982)). Outras interpretações dessas características serão discutidas quando aplicadas às imagens de testes ou às imagens de lesões de perna de diversos pacientes.

- Segundo Momento Angular (SMA): medida da homogeneidade local dos níveis de cinza em uma imagem. Em uma imagem homogênea existem poucas transições de níveis de cinza. Nesse caso, a matriz de coocorrência possui baixas entradas de alta magnitude. A fórmula que descreve o Segundo Momento Angular é:

$$\text{SMA} = \sum_{i=0}^{n-1} \sum_{j=0}^{n-1} [P(i, j, d, \theta)]^2$$

- Contraste ou Variância: medida da quantidade de variação local de níveis de cinza em uma imagem. ROSENFELD, A.; KAK, A. C. (1982) afirmam que se este valor for pequeno, os níveis de cinza da imagem analisada são todos próximos de uma média, ou seja, a matriz de coocorrência de níveis de cinza vai possuir a maioria dos valores concentrados na horizontal. Caso contrário, se o valor do contraste for alto, a imagem possui uma maior distribuição dos níveis de cinza em seu histograma. A fórmula que descreve o Contraste é:

$$\text{Contraste} = \sum_{i=0}^{n-1} \sum_{j=0}^{n-1} (i - j)^2 P(i, j, d, \theta)$$

- Entropia: A Entropia ou grau de dispersão de níveis de cinza pode também, juntamente com o SMA, ser utilizada como medida da homogeneidade em uma imagem. O valor da Entropia é alto quando os valores da matriz de coocorrência são iguais e é baixo quando a concentração de valores na diagonal é alta ou quando as entradas da matriz de coocorrência possuem valores baixos (HARALICK, R. M.; SHANMUGAM, K. (1973)). A fórmula que descreve a Entropia é:

$$\text{Entropia} = - \sum_{i=0}^{n-1} \sum_{j=0}^{n-1} P(i, j, d, \theta) \log_2 [P(i, j, d, \theta)]$$

- Momento Diferença Inverso (MDI): Segundo ROSENFELD, A.; KAK, A. C. (1982), o Momento Diferença Inverso atinge seu valor máximo quando a concentração dos valores na diagonal da matriz de coocorrência for máxima. A fórmula que descreve o Momento Diferença Inverso é:

$$\text{MDI} = \sum_{i=0}^{n-1} \sum_{j=0}^{n-1} \frac{1}{1 + (i - j)^2} P(i, j, d, \theta)$$

- Correlação: A Correlação representa uma idéia de linearidade de dependências de tons de cinza em uma imagem. Conforme HARALICK, R. M.; SHANMUGAM, K. (1973), em uma imagem onde exista uma certa ordenação local de níveis de cinza, o valor da correlação é alto. A fórmula que descreve a Correlação é:

$$\text{Correlação} = \frac{\sum_{i=0}^{n-1} \sum_{j=0}^{n-1} ijP(i, j, d, \theta) - \mu_x \mu_y}{\sigma_x \sigma_y}, \text{ sendo}$$

$$\mu_x = \sum_{i=0}^{n-1} \sum_{j=0}^{n-1} iP(i, j, d, \theta), \quad \mu_y = \sum_{i=0}^{n-1} \sum_{j=0}^{n-1} jP(i, j, d, \theta)$$

$$\sigma_x = \sqrt{\sum_{i=0}^{n-1} \sum_{j=0}^{n-1} i^2 P(i, j, d, \theta) - \mu_x^2}, \quad \sigma_y = \sqrt{\sum_{i=0}^{n-1} \sum_{j=0}^{n-1} j^2 P(i, j, d, \theta) - \mu_y^2}$$

onde  $\mu_x$  e  $\mu_y$  representam as médias nas direções x e y, respectivamente e  $\sigma_x$  e  $\sigma_y$  representam os desvios padrão.

Existem diversas outras características de Haralick utilizadas para a extração de características em texturas para a diferenciação de imagens, conforme HARALICK, R. M. *et al.* (1973). As características discutidas acima foram escolhidas de acordo com pesquisa bibliográfica, onde, a partir de diversos trabalhos usando a implementação dessas características, foram, então, selecionadas aquelas que possam levar a resultados mais relevantes. É importante acrescentar que algumas características podem referir à mensurações semelhantes às características anteriormente discutidas, sendo, portanto, não mencionadas aqui por não acrescentar nenhuma significância a mais. Além disso, algumas dessas características caíram em desuso com o passar do tempo, restando somente algumas de maior relevância, entre as quais algumas implementadas aqui (CONNERS, R. W.; TRIVEDI M. M. *et al.* (1984)) (WESZKA, J. S. *et al.* (1976) (CONNERS, R. W. *et al.* (1980)) .

### 7.3.3. Considerações sobre o Cálculo das Características

As imagens ou texturas a serem submetidas a operações de diferenciação ou classificação, com o uso das características de Haralick descritas anteriormente, devem primeiramente ser submetidas a uma equalização de seus histogramas de primeira ordem, conforme afirmam ROSENFELD, A.; KAK, A. C. (1982) e HARALICK, R. M. *et al.* (1973) em seus trabalhos. Essa equalização é importante, de modo a melhorar a distribuição dos níveis de cinza das imagens, acrescentando

assim, relevância aos níveis de cinza que anteriormente possuíam valores insignificantes e também para que as medidas de segunda ordem (características de Haralick) não dependam das propriedades tonais das imagens, pois o histograma equalizado possui formato próximo a plano.

Como observação final, deve ser acrescentado que o cálculo das características de Haralick devem ser feitas nas quatro direções ( $0^\circ$ ,  $45^\circ$ ,  $90^\circ$  e  $135^\circ$ ), de modo a não se trabalhar com uma determinada direção específica, sendo por fim calculada a média dos quatro direcionamentos.

## **7.4. Exemplos de Aplicações do Cálculo de Texturas em Imagens Médicas**

Neste item são mostrados alguns casos de aplicação da abordagem estatística de segunda ordem, utilizada para a descrição e extração de características a partir de texturas. A ênfase é dada para casos médicos, onde estudos confirmam a possibilidade da obtenção de diversas conclusões e auxílio ao diagnóstico médico acerca de diversas patologias, através da análise de texturas.

### **7.4.1. Mapeamento de Texturas de Imagens de Ressonância Magnética Nuclear**

Para essa aplicação desenvolvida por BURRILL, J. H. P. (1999), foram extraídas características baseadas em texturas a partir de imagens de ressonância magnética nuclear, a fim de identificar pacientes portadores do mal de Alzheimer. Diversas rotinas de análise por texturas foram implementadas e submetidas a testes, tais como métodos baseados em histogramas, matrizes de cocorrência, estatísticas diferenciais, momentos e funções de auto-correlação. A idéia básica é partir de diferenças existentes em texturas obtidas de imagens de ressonância de cérebros humanos, em termos de níveis de cinza, para a obtenção de um auxílio ao diagnóstico médico da patologia.

Foram notadas diferenças de texturas entre as imagens dos cérebros, com variações específicas entre o meio cinza e o meio branco, diferenças ocorridas devido à manifestação da patologia. A análise por texturas permite o exame e a quantificação destas pequenas variações regulares em intensidade, onde é levado em conta a vizinhança dos *pixels* para os cálculos estatísticos, com diferentes valores entre *pixels* testados.

A implementação desse sistema foi desenvolvida em um software para UNIX denominado MIDAS (*Medical Image Display and Analysis System*), o qual provê uma interface para visualização e manipulação de imagens médicas, sendo capaz de mostrar até seis imagens ao mesmo tempo para análise. As rotinas foram todas implementadas em linguagem C e adaptadas para uso com o MIDAS.

As rotinas baseadas em histogramas de primeira ordem permitem o cálculo de médias, desvio padrão, distorção (*skew*) e curtose. As rotinas de coocorrência implementam o segundo momento angular (*sma*), momento elemento diferença, momento diferença inverso (*mdi*) e a correlação. Após a obtenção da matriz de coocorrência, foi calculado um vetor de estatísticas diferenciais, usado para calcular outros tipos de características de texturas.

Por fim, foram também implementadas rotinas para o uso com momentos e funções de auto-correlação, as quais fazem uso de transformadas de Fourier para a obtenção de resultados.

Foi notado que todos os métodos utilizados até o presente momento necessitam ser melhor avaliados, pois ainda ocorre um certo ceticismo em relação aos resultados, sendo que nenhum deles sugere prováveis causas da patologia. No entanto, todos apresentam variações em intensidade entre os meios cinza e branco do cérebro, permitindo uma diferenciação entre imagens de pacientes portadores do mal e pacientes sãos.

#### 7.4.2. O Uso da Análise por Texturas para Identificação de Pontos Suspeitos em Mamografias



No estudo feito por GUPTA, R.; UNDRILL P. E. (1996), foi proposta a análise de imagens mamográficas (raios-x) para a detecção de microcalcificações e massas suspeitas a partir da análise por texturas. Vários métodos de determinação de texturas foram aplicados à uma sequência de imagens para classificação, levando-se em conta a análise através de regiões de interesse.

Para a implementação, foi feita a equalização do histograma das imagens adquiridas, para se proceder à etapa de análise de texturas. Essa etapa consistiu da aplicação de filtros de Laws juntamente com a obtenção de matrizes de coocorrência. Foram também utilizadas duas funções morfológicas, abertura e fechamento (opening e closing), além de um detector de bordas Sobel, para a definição de contornos das regiões de interesse. Com isso, pode-se separar regiões com uma maior homogeneidade de regiões de menor homogeneidade.

Diversos resultados quantitativos foram obtidos e permitiram a diferenciação de mamogramas com massas suspeitas de mamogramas não-suspeitos.

### 7.4.3. Classificação de Microcalcificações utilizando Características de Texturas

No trabalho desenvolvido por MEERSMAN, D. *et al.* (1998) foram feitos experimentos com uma base de dados de imagens mamográficas, onde a detecção de pontos de microcalcificações foi feita a partir de mecanismos de filtragem não-linear, que também permitiam uma melhora do sinal inicial das imagens originais. Uma dificuldade presente aqui é a de se lidar com o tamanho das microcalcificações, da ordem de 0,1 a 1 mm de diâmetro, além da resolução espacial das imagens (100 micrômetros), o que dificulta a representação das microcalcificações para o formato de *pixels*.

Para a classificação de diferentes regiões foi utilizada a abordagem por redes neurais a partir de características provenientes de matrizes de coocorrência e uso de texturas, tais como características de Haralick.

Um *cluster* ou região detectada foi definido quando duas ou mais regiões eram detectadas em uma área circular de 1 cm de diâmetro. O mesmo foi chamado de positivo quando o seu centro caía em uma das regiões marcadas por radiologistas. Isso permitiu uma análise dos resultados, contribuindo também para o treinamento da rede neural.

Curvas ROC (*Receiver Operating Characteristic*) também foram utilizadas para calcular os diferentes conjuntos de características e auxiliar no desenvolvimento de algoritmos. Foi concluído que as imagens processadas pelo sistema contaram com uma detecção das microcalcificações melhorada em relação às imagens sem processamento, vistas pelos radiologistas. A classificação usando matrizes de coocorrência levaram a taxas de 15% menos erros durante o treinamento, em relação às imagens sem processamento.