

SISTEMA DE EXTRAÇÃO E SELEÇÃO DE ATRIBUTOS EM IMAGENS

Flávia Gonçalves Fernandes, João Ludovico Maximiano Barbosa, Ana Cláudia Patrocínio

Universidade Federal de Uberlândia - UFU

Faculdade de Engenharia Elétrica - FEELT

Uberlândia – MG, Brasil

flavia.fernandes92@gmail.com, joaolmbarbosa@gmail.com, ana.patrocinio@gmail.com

Resumo – A seleção de atributos é um problema de otimização e busca pelo menor subconjunto com a melhor acurácia no processo de classificação. O processo de seleção de atributos é executado com base em distâncias estatísticas entre pares de classes. Há várias formas de medir a distância entre conjuntos de classes diferentes no espaço de atributos. Nessa perspectiva, o objetivo deste trabalho é apresentar o desenvolvimento de um sistema para extração de atributos de intensidade, atributos de textura, atributos geométricos e atributos wavelets do conjunto de imagens disponível, a fim de tentar resolver o problema de separação de classes de imagens representadas no conjunto dado.

Palavras-Chave – atributos, extração, imagens.

EXTRACTION SYSTEM AND ATTRIBUTES SELECTION IN IMAGES

Abstract – The selection of attributes is an optimization problem and search for smaller subset with the best accuracy in the classification process. The attributes selection process is performed based on statistical distances between classes pairs. There are several ways to measure the distance between sets of different classes in the feature space. In this perspective, the objective of this paper is to present the development of a system for intensity attributes extraction, texture attributes, geometric attributes and wavelets attributes the set of available images in order to solve the problem of separation of represented images classes in the given set.

Keywords - attributes, extraction, images.

I. INTRODUÇÃO

A evolução da tecnologia de computação, em termos de hardware, bem como o desenvolvimento de algoritmos mais eficientes para manipulação de imagens digitais, tem permitido um número crescente de aplicações de reconhecimento de padrões. O desenvolvimento de um sistema de reconhecimento de padrões requer: a definição do

padrão das classes, um ambiente de aquisição dos dados, a representação do padrão, a extração e seleção de atributos, a análise de agrupamento, o desenvolvimento e aprendizado do classificador, a seleção das amostras de treinamento e teste, e a avaliação do desempenho do classificador [1].

Extrair as características (atributos) mais importantes numa imagem evidencia as diferenças e similaridades entre os objetos. Algumas características são definidas por uma aparência visual na imagem. Essas características incluem: o brilho e/ou textura de uma determinada região da imagem, amplitude do histograma, entre outros. O principal objetivo da extração de atributos é caracterizar os objetos para serem reconhecidos através de medidas sobre a imagem [2].

Classificadores tradicionais, baseados em princípios espectrais, são os que habitualmente encontram-se implementados na maioria dos softwares utilizados em processos de extração de atributos de uma região da imagem. No processamento digital de imagem, uma representação de uma região não consiste apenas na diferenciação dos níveis de cinza dos objetos, mas também da delimitação de sua fronteira através da forma dos objetos (região) [3].

Nessa linha de raciocínio, este trabalho apresenta um sistema de extração de diversos tipos de atributos em dois grupos de imagens: de ruas arborizadas e de ruas movimentadas, com a finalidade de descobrir quais atributos são melhores para discernir os dois conjuntos.

II. FUNDAMENTOS TEÓRICOS

A seleção de atributos é uma tarefa de difícil realização, pois depende dos dados de entrada, isto é, do domínio da aplicação, assim como do classificador a ser utilizado, por exemplo: paramétrico, não-paramétrico ou redes neurais [4]. Essa fase é destinada à escolha dos atributos que melhor distinguem as classes previamente selecionadas.

A maioria dos métodos de seleção de atributos utiliza princípios estatísticos, ou seja, medidas estatísticas entre os atributos para cada conjunto de classes, selecionando os atributos que contém informações relevantes para a separabilidade das classes.

A. Atributos de Intensidade em Imagens

Os atributos de intensidade visam caracterizar as imagens pelos seus tons de cinza. Assim, as medidas devem ser extraídas das imagens em tons de cinza e não segmentadas, podendo ser extraídas a partir do histograma da imagem [5].

Um histograma, também conhecido como distribuição de frequências ou diagrama das frequências, é a representação gráfica, em colunas (retângulos), de um conjunto de dados previamente tabulado e dividido em classes uniformes. A base de cada retângulo representa uma classe e a altura de



XIV CEEL - ISSN 2178-8308
03 a 07 de Outubro de 2016
Universidade Federal de Uberlândia - UFU
Uberlândia - Minas Gerais - Brasil

cada retângulo representa a quantidade ou frequência com que o valor dessa classe ocorreu no conjunto de dados. Além de ser uma importante ferramenta da estatística.

Os atributos extraídos do histograma de uma imagem são [5]:

1- Média: Média de intensidade dos tons de cinza do histograma; representando o brilho da imagem.

2- Desvio-Padrão: Medida de dispersão dos valores de uma distribuição normal em relação à sua média de intensidade dos tons de cinza do histograma; representando o contraste da imagem.

3- Valor Mínimo: Menor valor de intensidade do histograma.

4- Valor Máximo: Maior valor de intensidade do histograma.

5- Pico: Valor de intensidade do maior pico do histograma.

6- Porcentagem do Menor Valor: Porcentagem do menor valor de intensidade do histograma em relação a escala de níveis de cinza.

7- Porcentagem do Maior Valor: Porcentagem do maior valor de intensidade do histograma em relação a escala de níveis de cinza.

8- Diferença entre a Média e o Menor Valor: Subtração entre a média de intensidade dos tons de cinza do histograma e o menor valor de intensidade do histograma.

9- Diferença entre a Média e o Maior Valor: Subtração entre a média de intensidade dos tons de cinza do histograma e o maior valor de intensidade do histograma.

10- Quantidade de Pixels Menores que o Pico: Quantidade de pixels com intensidades menores que a intensidade de pico do histograma.

11- Quantidade de Pixels Maiores que o Pico: Quantidade de pixels com intensidades maiores que a intensidade de pico do histograma.

12- Quantidade de Níveis de Cinza: Quantidade de níveis de cinza da imagem.

B. Atributos de Textura em Imagens

Segundo [6], os descritores de textura são calculados a partir da determinação da matriz de co-ocorrência da imagem em quatro ângulos (0°, 45°, 90°, 135°), que fornece a distribuição de probabilidades de uma sequência de pixels ocorrer na imagem, em cada um dos ângulos.

Com base nos cálculos realizados sobre os valores da matriz de co-ocorrência, forma-se um conjunto de 14 medidas sendo elas [6]:

1 - Uniformidade ou Energia: indica uniformidade. Texturas homogêneas terão valor de energia mais alto, pois as texturas suaves possuem densidades mais concentradas. Texturas rugosas têm densidades com alta variância.

2 - Contraste: estimativa da variação de intensidade entre pares de pontos da imagem. Para texturas de baixo contraste, essa medida terá um baixo valor e, para texturas de alto contraste, o valor será alto.

3 - Correlação: é um indicador de uma estrutura implícita na textura ou um fundo suave.

4 - Variância: indicador da variação da intensidade de fundo da imagem.

5 - Momento da Diferença Inversa: medida de homogeneidade local. Enfatiza texturas sutis e pequenas mudanças.

6 - Média da Soma: média dos tons do fundo da imagem.

7 - Variância da Soma: variação dos tons de fundo da imagem.

8 - Entropia da Soma: indica quantidade de informação entre pares de pixels.

9 - Entropia: indica quantidade de informação resultante das interações entre os pixels da imagem.

10 - Variância da diferença: variância calculada com a média centrada em zero.

11 - Entropia da diferença: é um indicador de quantidade de desorganização entre os pixels de um fundo (semelhante a Soma da Entropia).

12 - Medida de Informação de Correlação 1: é um indicador da correlação baseado na medida da entropia para elementos independentes e pares de elementos na imagem.

13 - Medida de Informação de Correlação 2: é a média da correlação baseada na similaridade entre entropias de elementos independentes da imagem e pares de elementos da imagem.

14 - Máximo Coeficiente de Correlação: é um indicador da não homogeneidade da distribuição de níveis de cinza.

C. Atributos Geométricos em Imagens

Técnicas qualitativas e quantitativas são desenvolvidas para caracterizar a geometria dos objetos nas imagens. Há várias outras maneiras de representar e descrever a variação da forma dos objetos, como através da teoria do código da cadeia, teoria das assinaturas, dos números de formas, circularidade, entre outras [7].

Assim, os atributos geométricos são: área, perímetro, compacidade, irregularidade e os momentos invariantes e centrais [7].

1-Área: É a medida mais simples de uma imagem. Consiste na contagem de pixels brancos na imagem e caracteriza a área global ocupada por objetos. Logo, a área de cada objeto é definida pela quantidade de pixels pertencentes a um objeto.

2-Perímetro: Corresponde a contagem dos pixels pertencente a borda do objeto. Para isso, antes de realizar a medida de distâncias deve-se primeiro isolar a forma do resto da imagem. Depois, conectar todos os pixels que pertençam ao seu contorno para, em seguida, poder medir o seu perímetro.

3- Compacidade: É uma medida derivada do perímetro P e área A de um objeto, conforme pode ser visto na Equação 1:

$$C = \frac{P}{4\pi A} \quad (1)$$

4- Irregularidade: É outro atributo extraído da área e do perímetro, dada pela Equação 2:

$$I = \frac{A}{P^2} \quad (2)$$

Momentos:

A teoria dos momentos é um método para decompor uma forma arbitrária em características capazes de serem interpretadas e comparadas. Ela é aplicável somente a

imagens binárias e os atributos resultantes da aplicação da técnica são baseados em transformações lineares diretas e fornecem informações sobre: localização dos objetos, reconhecimento de formato, orientação, tamanho e características invariantes quanto à rotação, translação e escala, no caso dos momentos normalizados [7].

O momento bidimensional m para uma imagem $f(x,y)$ de M linhas por N colunas é calculado conforme a Equação 3 [7].

$$m_{p,q} = \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} x^p y^q f(x, y) \quad (3)$$

Dessa forma, por meio da Equação 3, são calculados os seguintes momentos bidimensionais:

5- Momento $m_{0,0}$

6- Momento $m_{1,0}$

7- Momento $m_{0,1}$

8- Momento $m_{2,0}$

9- Momento $m_{0,2}$

10- Momento $m_{1,1}$

11- Momento $m_{1,2}$

12- Momento $m_{2,1}$

13- Momento $m_{3,0}$

14- Momento $m_{0,3}$

A coordenada X do centro de massa de uma imagem é calculado conforme Equação 4 e a coordenada Y conforme Equação 5 descritas abaixo, nas quais $m_{p,q}$ é o momento

linear p,q da imagem [7].

15- Coordenada X : $\bar{x} = \frac{m_{1,0}}{m_{0,0}} \quad (4)$

16- Coordenada Y : $\bar{y} = \frac{m_{0,1}}{m_{0,0}} \quad (5)$

Os momentos centrais ou invariantes podem ser calculados a partir dos momentos lineares, em que $m_{p,q}$ é o momento linear p,q da imagem, \bar{x}, \bar{y} é a coordenada do centro de massa e $\mu_{p,q}$ é o momento central p,q [7]:

17- Momento $\mu_{0,0}$: $\mu_{0,0} = m_{0,0} = \mu$

18- Momento $\mu_{1,0}$: $\mu_{1,0} = \mu_{1,1} = 0$

19- Momento $\mu_{0,1}$: $\mu_{2,0} = m_{2,0} - \mu \bar{x}^2$

20- Momento $\mu_{2,0}$: $\mu_{2,0} = m_{2,0} - \mu \bar{x}^2$

21- Momento $\mu_{0,2}$: $\mu_{0,2} = m_{0,2} - \mu \bar{y}^2$

22- Momento $\mu_{1,1}$: $\mu_{1,1} = m_{1,1} - \mu \bar{x} \bar{y}$

23- Momento $\mu_{1,2}$:

$$\mu_{1,2} = m_{1,2} - m_{0,2} \bar{x} - 2 * m_{1,1} \bar{y} + 2 * \mu \bar{x} \bar{y}^2$$

24- Momento $\mu_{2,1}$:

$$\mu_{2,1} = m_{2,1} - m_{2,0} \bar{y} - 2 * m_{1,1} \bar{x} + 2 * \mu \bar{x}^2 \bar{y}$$

25- Momento $\mu_{3,0}$:

$$\mu_{3,0} = m_{3,0} - 3 * m_{2,0} \bar{x} + 2 * \mu \bar{x}^3$$

26- Momento $\mu_{0,3}$:

$$\mu_{0,3} = m_{0,3} - 3 * m_{0,2} \bar{y} + 2 * \mu \bar{y}^3$$

D. Atributos Wavelets

Wavelet é uma função capaz de decompor e descrever ou representar outra função (ou uma série de dados) originalmente descrita no domínio do tempo (ou outras variáveis independentes, como o espaço), de forma que pode ser analisada em diferentes escalas de frequência e de tempo. A decomposição de uma função com o uso de wavelets é conhecida como transformada wavelet e tem suas variantes contínua e discreta. Graças a capacidade de decompor as funções tanto no domínio da frequência quanto no domínio do tempo, as funções wavelets são ferramentas poderosas de processamento de sinais, muito aplicadas na compressão de dados, eliminação de ruído, separação de componentes no sinal, identificação de singularidades, detecção de auto semelhança, e muito mais [8].

No processo de decomposição dos sinais são gerados dois coeficientes:

- Aproximação (A) – componentes de baixa frequência;
- Detalhes (D) – componentes de alta frequência.

Portanto, a Transformada Wavelet permite dar um “zoom” nos sinais.

Assim, os coeficientes mais utilizados como extração de atributos de imagens por Wavelets são [8]:

- CA: Coeficiente de Aproximação;
- CH: Coeficiente de Detalhes Horizontais;
- CV: Coeficiente de Detalhes Verticais;
- CD: Coeficiente de Detalhes Diagonais.

Cada coeficiente representa o grau de correlação ou similaridade entre o sinal $f(x)$ e a Wavelet em uma particular escala s e translação l .

III. DESENVOLVIMENTO E ANÁLISE DOS RESULTADOS

Primeiramente, foram selecionadas dez imagens de ruas arborizadas, representando a Classe 1, conforme visto na Figura 1, e dez imagens de ruas movimentadas, representando a Classe 2, de acordo com a Figura 2.




Fig. 1. Imagens da Classe 1 – ruas arborizadas.

Em seguida, através do MATLAB, um software interativo de alta performance voltado para o cálculo numérico, processamento de sinais e construção de gráficos, sendo bastante utilizado devido a sua facilidade para manipular matrizes e vetores. Foram desenvolvidos diversos algoritmos para a realização da extração e seleção dos atributos de imagens citados neste trabalho. Assim, foram extraídos os

atributos de intensidade, textura, geométricos e wavelets de cada uma das imagens mostradas nas Figuras 1 e 2.




Fig. 2. Imagens da Classe 2 – ruas movimentadas.

Após a extração dos atributos, os valores de cada um foram normalizados individualmente utilizando a fórmula de normalização pelo valor máximo dos elementos, conforme Equação 6.

$$A' = \frac{A}{Max} \quad (6)$$

- A': valor normalizado;
- A: valor original do atributo;
- Max: valor máximo do atributo.

O propósito da normalização é minimizar os problemas oriundos do uso de unidades e dispersões distintas entre as variáveis, as quais podem ser normalizadas segundo a amplitude ou a distribuição.

Após a normalização dos dados, fez-se uma média de cada atributo para as imagens da classe 1, representadas pela cor azul no gráfico de barras comparativo e também para as imagens da classe 2, representadas pela cor vermelha. Esses gráficos são exibidos nas Figuras 3, 4, 5 e 6.

Na Figura 3, é apresentado o gráfico comparativo das médias dos atributos de intensidade normalizados.




Fig. 3. Gráfico das médias dos atributos de intensidade.

Na Figura 4, é apresentado o gráfico comparativo das médias dos atributos de textura normalizados.




Fig. 4. Gráfico das médias dos atributos de textura.

Na Figura 5, é apresentado o gráfico comparativo das médias dos atributos geométricos normalizados.




Fig. 5. Gráfico das médias dos atributos geométricos.

Na Figura 6, é apresentado o gráfico comparativo das médias dos atributos wavelets normalizados.

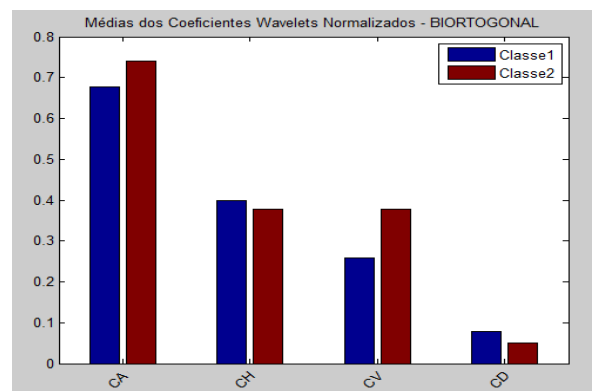


Fig. 6. Gráfico das médias dos atributos wavelets.

Após a extração dos atributos, foi realizada uma seleção a fim de verificar qual dos atributos possui melhor acurácia para a separação das imagens. Para realizar este procedimento, foi adotado o algoritmo K-means como técnica de seleção de atributos.

A ideia do algoritmo K-Means (também chamado de K-Médias) é fornecer uma classificação de informações de acordo com os próprios dados. Esta classificação é baseada em análise e comparações entre os valores numéricos dos

dados. Desta maneira, o algoritmo automaticamente vai fornecer uma classificação automática sem a necessidade de nenhuma supervisão humana, ou seja, sem nenhuma pré-classificação existente. Por causa desta característica, o K-Means é considerado como um algoritmo de mineração de dados não-supervisionado [8].

Para entender como o algoritmo funciona, cita-se como exemplo uma tabela com linhas e colunas que contém os dados a serem classificados. Nesta tabela, cada coluna é chamada de dimensão e cada linha contém informações para cada dimensão, que também são chamadas de ocorrências ou pontos. Geralmente, trabalha-se com dados contínuos neste algoritmo, mas nada impede que dados discretos sejam utilizados, desde que eles sejam mapeados para valores numéricos correspondentes [8].

Assim, o algoritmo vai analisar todos os dados desta tabela e criar classificações. Isto é, o algoritmo vai indicar uma classe (cluster) e vai dizer quais linhas pertencem a esta classe. O usuário deve fornecer ao algoritmo a quantidade de classes que ele deseja. Este número de classes que deve ser passada para o algoritmo é chamado de k e é daí que vem a primeira letra do algoritmo: K-Means.

Para gerar as classes e classificar as ocorrências, o algoritmo faz uma comparação entre cada valor de cada linha por meio da distância. Geralmente utiliza-se a distância euclidiana para calcular o quão 'longe' uma ocorrência está da outra. A maneira de calcular esta distância vai depender da quantidade de atributos da tabela fornecida. Após o cálculo das distâncias o algoritmo calcula centroides para cada uma das classes. Conforme o algoritmo vai iterando, o valor de cada centroide é refinado pela média dos valores de cada atributo de cada ocorrência que pertence a este centroide. Com isso, o algoritmo gera k centroides e coloca as ocorrências da tabela de acordo com sua distância dos centroides [8].

Assim, para esta aplicação, os pontos ou ocorrências são as imagens das Classes 1 e 2, sendo as dez primeiras ocorrências correspondentes às imagens da Classe 1 e as dez últimas ocorrências correspondentes às imagens da Classe 2, totalizando vinte pontos ou ocorrências para cada execução do algoritmo.

Por exemplo, a dimensão (coluna) dos pontos do algoritmo de k -means é um atributo de textura de intensidade. Desse modo, para este método, o algoritmo foi executado 12 vezes: uma vez para cada atributo de intensidade.

Partindo do pressuposto de que as imagens estão pré-classificadas em duas classes, sendo a Classe 1 como imagens de ruas arborizadas e a Classe 2 como imagens de ruas movimentadas, adotou-se o $k = 2$, que é o número de grupos a serem formados, em que um grupo seria composto por imagens de ruas arborizadas, o outro grupo por imagens de ruas movimentadas.

Dessa maneira, através dos grupos formados para cada método de extração de atributos a partir do algoritmo K-means, verifica-se qual dos atributos teve o melhor acerto na formação dos grupos, onde os grupos formados foram comparados com as Classes 1 e 2 para verificar os acertos.

Então, os valores normalizados referentes aos doze atributos de intensidade, os quatorze atributos de textura, os vinte e seis atributos geométricos e os quatro atributos wavelets foram aplicados no algoritmo de k -means para os dois conjuntos de imagens. Dessa forma, cada atributo foi utilizado para seleção e classificação das imagens, com a

finalidade de separar os dois grupos de imagens disponíveis para este trabalho. Nas Tabelas I, II, III e IV, encontram-se os resultados obtidos para este teste, em que é apresentada a porcentagem de acerto de cada atributo de acordo com a funcionalidade de separação de classes das imagens.

Tabela I - K-means para a seleção de atributos de intensidade.

Atributo	1	2	3	4	5	6
Acerto (%)	60	50	50	60	60	50
Atributo	7	8	9	10	11	12
Acerto (%)	50	60	60	65	60	50

Tabela II - K-means para a seleção de atributos de textura.

Atributo	1	2	3	4	5	6	7
Acerto (%)	55	50	60	50	45	60	50
Atributo	8	9	10	11	12	13	14
Acerto (%)	60	50	55	45	60	60	55

Tabela III - K-means para a seleção de atributos geométricos.

Atributo	1	2	3	4	5	6	7	8	9
Acerto (%)	50	55	55	60	50	60	55	60	55
Atributo	10	11	12	13	14	15	16	17	18
Acerto (%)	65	55	70	70	55	75	55	55	50
Atributo	19	20	21	22	23	24	25	26	
Acerto (%)	50	60	60	55	50	60	60	50	

Tabela IV - K-means para a seleção de atributos wavelets.

Atributo	CA	CH	CV	CD
Acerto (%)	55	60	75	55

Além da seleção de atributos pelo método de k -means, também foi adotado outro procedimento para classificação e separação dessas classes de imagens, o qual é denominado distribuição gaussiana.

A distribuição de Gauss ou Gaussiana é uma das mais importantes da estatística, além de descrever uma série de fenômenos físicos e financeiros, possui grande uso na estatística inferencial. É inteiramente descrita por seus parâmetros de média e desvio padrão, ou seja, conhecendo-se estes valores consegue-se determinar qualquer probabilidade em uma distribuição Normal [5].

Para processamento de imagens, a distribuição gaussiana é utilizada como filtro Gaussiano, o qual pode ser usado como um filtro passa-baixa. Para isso, usa-se a função Gaussiana para obter valores de uma máscara a ser definida digitalmente.

Considerando que a imagem é armazenada como uma coleção de pixels discretos necessários para produzir uma forma discreta da distribuição Gaussiana para obter um núcleo de convolução (máscara ou kernel), este seria teoricamente infinitamente grande, mas na prática se zera aproximadamente a uma distância de três unidades (ou pixels) do centro [5].

Para filtros Gaussianos com maiores desvios padrões, pode-se montar outra máscara, porém, o mais usual é passar a mesma máscara mais de uma vez na imagem.

O uso do filtro Gaussiano é suavizar a imagem, quase da mesma forma que o filtro de média. O resultado será tão mais suave quanto maior o valor de sigma, desvio padrão da função Gaussiana usada. Desvios-padrões maiores também fazem com que a máscara deva ser maior para uma representação adequada.

Então, foi aplicado o algoritmo da distribuição gaussiana para todos os atributos dos quatro tipos de atributos de

imagens abordados neste trabalho: intensidade, textura, geométricos e wavelets.

Os melhores resultados encontrados são apresentados nas Figuras 7 e 8, os quais correspondem ao Momento $m_{2,1}$ e ao Momento $m_{3,0}$, onde há uma maior separação das classes de imagens em relação aos outros atributos analisados.




Fig. 7. Distribuição gaussiana para o Momento $m_{2,1}$.




Fig. 8. Distribuição gaussiana para o Momento $m_{3,0}$.

IV. CONCLUSÕES E TRABALHOS FUTUROS

Portanto, a partir do desenvolvimento, dos testes e dos resultados encontrados, conclui-se que os melhores atributos para separar/distinguir os grupos são o atributo geométrico Coordenada X do Centro de Massa e o atributo wavelet CV, ambos com 75% de acerto. Em seguida, há os atributos “Momento $m_{2,1}$ ” e “Momento $m_{3,0}$ ”, com taxa de acerto de 70%. Porém, com o objetivo de encontrar uma porcentagem de acerto maior na separabilidade das classes, resolveu-se combinar mais de um atributo (mais de uma dimensão) no algoritmo de K-means. O Critério para agrupar os atributos foi a combinação dos atributos que apresentaram maior porcentagem de acerto. Dessa maneira, atingiu-se 85% de acurácia, combinando os 3 (três) melhores atributos geométricos. Assim, para as imagens utilizadas neste trabalho, os melhores atributos que caracterizam, separam, selecionam e discernem ambas as classes são os atributos geométricos.

Logo, a partir dos estudos e testes realizados no decorrer da realização deste trabalho, percebe-se a importância da extração de diversos tipos de atributos em imagens, a saber: de intensidade, de textura, geométricos e wavelets, e do seu aprendizado para realização passo-a-passo dos algoritmos implementados. Também se verifica que não há um melhor método de extração de atributos, pois, para cada caso, determinado atributo tem uma funcionalidade e um resultado

melhor. Por isso, é importante a prática de vários métodos em conjunto.

Em virtude do que foi pesquisado, o uso de descritores de intensidade, textura, forma e wavelets de modo computacional vem sendo muito estudado atualmente. Embora fique difícil o entendimento da utilização de textura para a classificação de contorno, por exemplo, os descritores de textura fornecem medidas, como suavidade, rugosidade e regularidade, as quais, isoladamente, não produzem bons resultados para a classificação de contorno; mas, junto com outras técnicas, podem contribuir no que diz respeito a informações sobre a variação de intensidade ou alterações sutis entre o objeto e o fundo da imagem.

A tarefa de classificação ocorre em várias áreas da atividade humana e as pesquisas na área têm sido bastante direcionadas à construção de procedimentos automáticos de classificação. Além dos estudos envolvendo a classificação, outras técnicas vêm sendo estudadas para melhorar a separação de classes, reconhecimento de padrões e tomada de decisões.

Além disso, a análise realizada pelo especialista continua sendo bastante subjetiva e a identificação de uma lesão como suspeita ou não de sua detecção dependem muito da experiência do médico. Essa é mais uma motivação para o uso de ferramentas automáticas para o auxílio ao diagnóstico, que tentam fornecer uma análise baseada em dados mais objetivos através de valores extraídos da própria imagem.

Para cada caso, recomenda-se utilizar um método específico para a análise de atributos de imagens, dependendo do objetivo, visto que cada abordagem possui determinados tipos de funções.

REFERÊNCIAS

- [1] A. K. Jain; P. W. Robert; D. Moa; J. Moa. *Statistical Pattern Recognition: A Review*. IEEE Trans. On Pattern Analysis And Machine Intelligence, Vol. 22, Nº.1, 2000.
- [2] W. K. Pratt. *Digital Image Processing*. Wiley Interscience, 1991. 698 p.
- [3] R. O. Duda; P. E. Hart; D. G. Stork. *Pattern Classification*. 2 ed. New York, Wiley, 2001.
- [4] L. V. Dutra; R. Huber. *Feature Extraction and Selection for ERS 1/2 InSAR Classification*. Int. J. Remote Sensing, 1999, vol. 20, nº. 5, 993-1016.
- [5] M. A. Hall. *Correlation-based feature selection for discrete and numeric class machine learning*. In: Proceedings of the Seventeenth International Conference on Machine Learning. Morgan Kaufmann Publishers Inc., pp. 359-366, 2000.
- [6] R. M. Haralick; K. Shanmugam; I. Dinstein. *Textural features for image classification*. IEEE Transactions on Systems, Man and Cybernetics 3, 6 (Novembro 1978), 610-621.
- [7] R. C. Gonzalez; R. E. Woods. *Processamento de Imagens Digitais*, tradução do original Digital Image Processing. Edgard Blucher, São Paulo, 2000.
- [8] Y. Q. Chen. *Novel techniques for image texture classification*. PhD thesis, University of Southampton, Department of Electronics and Computer Science, 1995.