

Classificação de Imagens por meio de Extração e Seleção de Atributos

Flávia Gonçalves Fernandes¹, João Ludovico Maximiano Barbosa²

¹Universidade Federal de Goiás (UFG) – Catalão – GO – Brasil

²Universidade Federal de Uberlândia (UFU) – Uberlândia – MG – Brasil

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

Abstract. *The selection of attributes is a problem of optimization and search for the smallest subset with the best accuracy in the classification process. The process of selection of attributes is executed on the basis of distances between pairs of statistics classes. There are several ways to measure the distance between sets of different classes in the attributes space. In this perspective, the objective of this work is to present the development of a system for extracting attributes of intensity, texture attributes, geometric attributes and attributes wavelets of set of images available, in order to try solve the problem of separation of classes of images in the given set.*

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 no conjunto dado.*

1. 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 proporcionado um aumento nas 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 [Jain et al., 2000].

A extração de características (atributos) em uma imagem evidencia as diferenças e similaridades entre os seus objetos. Algumas características são definidas por uma aparência visual na imagem, podendo ser: o brilho e/ou textura de uma determinada região dela, amplitude do histograma, entre outros. O principal objetivo da extração de

atributos é caracterizar os objetos da imagem para serem reconhecidos através de métricas [Pratt, 1991].

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) [Duda; Hart; Stork].

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.

O uso de descritores de intensidade, textura, geométrico e *wavelets* de modo computacional em processamento de imagens já é bem conhecido. 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.

Além disso, o processamento de imagens pode auxiliar na detecção de doenças, como o câncer, por exemplo, fazendo com que o diagnóstico do médico possa ser mais assertivo, uma vez que, a análise realizada pelo especialista continua sendo bastante subjetiva e a identificação de uma lesão como suspeita ou não dependem muito da experiência do médico. Assim, ferramentas automáticas para o auxílio ao diagnóstico, que tentam fornecer uma análise baseada em dados mais objetivos através de valores extraídos da própria imagem tornam-se mais atrativos.

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.

2. Fundamentação Teórica

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 [Gonzalez, 2000].

Os atributos extraídos do histograma de uma imagem são: média, desvio-padrão, valor mínimo, valor máximo, pico, porcentagem do menor valor, porcentagem do maior valor, diferença entre a média e o menor valor, diferença entre a média e o maior valor, quantidade de pixels menores que o pico, quantidade de pixels maiores que o pico e quantidade de níveis de cinza [Gonzalez, 2000].

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 [Haralick, 1998].

Com base nos cálculos realizados sobre os valores da matriz de co-ocorrência, forma-se um conjunto de 14 medidas (atributos), sendo elas: uniformidade ou energia, contraste, correlação, variância, momento da diferença inversa, média da soma,

variância da soma, entropia da soma, entropia, variância da diferença, entropia da diferença, medida de informação de correlação 1, medida de informação de correlação 2 e máximo coeficiente de correlação [Haralick, 1998].

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. Assim, os atributos geométricos encontrados em imagens são: área, perímetro, compacidade, irregularidade e os momentos invariantes e centrais [Gonzalez, 2000].

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 [Chen, 1995].

Assim, os coeficientes mais utilizados como extração de atributos de imagens por *wavelets* são [Chen, 1995]:

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

3. Metodologia

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.




Figura 1: Imagens da Classe 1 – ruas arborizadas.




Figura 2: Imagens da Classe 2 – ruas movimentadas.

Em seguida, através do MATLAB [Matlab, 2016], um *software* que possui uma linguagem baseada em matrizes, voltado para o cálculo numérico, processamento de sinais, construção de gráficos; sendo bastante utilizado para propósitos científicos e de engenharia. Foram desenvolvidos diversos algoritmos para a realização da extração e seleção dos atributos de imagens. Extraíram-se os seguintes atributos: intensidade, textura, geométricos e *wavelets* para cada uma das imagens mostradas nas Figuras 1 e 2.

Após a extração dos atributos, os valores de cada um deles foram normalizados individualmente utilizando a fórmula de normalização pelo valor máximo dos elementos, conforme Equação 1.

$$A' = \frac{A}{Max} \quad (1)$$

A': valor normalizado;

A: valor original do atributo;

Max: valor máximo do atributo, dentre os valores encontrados.

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 [Haralick, 1998].

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 separados por conjuntos de atributos: intensidade, textura, geométricos e *wavelets*.




Figura 3: Gráfico das médias dos atributos de intensidade.




Figura 4: Gráfico das médias dos atributos de textura.




Figura 5: Gráfico das médias dos atributos geométricos.




Figura 6: Gráfico das médias dos atributos wavelets.

Através destes gráficos pode-se ter uma noção de quanto cada atributo se difere de um grupo para outro, ou seja, quanto maior a diferença da barra vermelha para a barra azul, maior é a chance deste atributo ser relevante na separabilidade das classes. É notável que os atributos geométricos apresentam uma maior variação.

4. Resultados

Após a extração dos atributos, foi realizada uma seleção destes, 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 [Chen, 1995].

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* do *K-Means* igual a dois, que é o número de grupos formados na classificação. A partir desta classificação feita pelo algoritmo, observou-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*. Dessa forma, cada atributo foi utilizado para a 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 [Hall, 2000].

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*, a fim de ver qual atributo possui melhor separabilidade entre as classes.

Os melhores resultados encontrados são apresentados nas Figuras 7 e 8, os quais correspondem aos atributos geométricos: 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, ou seja, a curva da distribuição gaussiana estava “menos” sobreposta uma sobre a outra, assim, quantos menos sobreposta, maior é a separabilidade do atributo.




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




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

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.

5. Conclusões e Trabalhos Futuros

Logo, a partir dos estudos e testes realizados no decorrer da realização deste trabalho, os melhores atributos que caracterizam, separam, selecionam e discernem ambas as classes de ruas arborizadas e ruas movimentadas são os atributos geométricos.

Percebe-se também 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 aplicação, determinado atributo tem uma funcionalidade e um resultado melhor. Por isso, é importante a prática de vários métodos em conjunto, e destes selecionar os mais importantes para a sua aplicação, uma vez que para utilizar todos os atributos exige um custo computacional muito grande, e informação demasiada com pouca utilidade atrapalha na interpretação dos resultados.

Referências

- Chen, Y. Q.. Novel techniques for image texture classification. PhD thesis, University of Southampton, Department of Electronics and Computer Science, 1995.
- Duda, R. O.; Hart, P. E.; Stork, D. G.. Pattern Classification. 2 ed. New York, Wiley, 2001.
- Dutra, L. V.; Huber, R.. Feature Extraction and Selection for ERS 1/2 InSAR Classification. Int. J. Remote Sensing, 1999, vol. 20, nº. 5, 993-1016.
- Gonzalez, R. C.; Woods, R. E.. Processamento de Imagens Digitais, tradução do original Digital Image Processing. Edgard Blucher, São Paulo, 2000.
- Hall, M. A.. 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.
- Haralick, R. M.; Shanmugam, K.; Dinstein, I.. Textural features for image classification. IEEE Transactions on Systems, Man and Cybernetics 3, 6 (Novembro 1998), 610-621.
- Jain, A. K.; Robert, P. W.; Moa, D.; Moa, J.. Statistical Pattern Recognition: A Review. IEEE Trans. On Pattern Analysis And Machine Intelligence, Vol. 22, Nº.1, 2000.
- Matlab. 2016. Disponível em: <<https://www.mathworks.com/>>. Acesso em: 22 set. 2016.
- Pratt, W. K.. Digital Image Processing. Wiley Interscience, 1991. 698 p.