

Extração de características: textura

Image Processing — scc0251

`www.icmc.usp.br/~moacir` — `moacir@icmc.usp.br`

ICMC/USP — São Carlos, SP, Brazil

2011

- 1 Textura
 - Análise de textura
 - Matrizes de co-ocorrência
 - Local Binary Patterns (LBP)

Agenda

- 1 Textura
 - Análise de textura
 - Matrizes de co-ocorrência
 - Local Binary Patterns (LBP)


Textura

A textura para os humanos se refere ao tato: diferenças nas superfícies ásperas ou lisas

- Texturas em imagens são as diferenças locais nos níveis de intensidade:
 - Diferenças em níveis de cinza (contraste)
 - Tamanho de área definido onde essas diferenças ocorrem (janela)
 - Direcionalidade (ou falta de direcionalidade)

Textura

- Representa detalhes numa imagem





Texture with repeated local patterns




Local pattern


Textura — características



Repetição




Estocástica



Ambas


Análise de Textura

- Comparar texturas e decidir se elas são iguais ou diferentes.




Análise de Textura: abordagens

- 1 Abordagem estrutural (top-down)
 - decompor imagem em elementos básicos: texels (*texture elements*) ou textons
 - adequado para texturas artificiais
- 2 Abordagem estatística (bottom-up)
 - caracterizar a textura por propriedades estatísticas de pequenos grupos de pixels
 - adequado para texturas naturais



Abordagem estrutural: textel

- Textura é um conjunto de textels primitivos com uma relação regular ou de repetição
 - textel é um grupo de pixels com propriedades de intensidade similares: intensidade média, contraste, regiões planas, etc.
 - a granularidade da textura é dada pelo tamanho da primitiva.



Abordagem estatística

- Definir e segmentar textels pode ser difícil para cenas naturais
 - texturas naturais parecem semelhantes, mas é difícil extrair uma **estrutura** de textel.
 - comparar **estatísticas** pode ser uma saída!



- Medidas numéricas e estatísticas podem descrever uma textura e serem computadas em níveis de cinza ou cores.
 - computacionalmente eficiente
 - pode ser usado para classificação e segmentação

Abordagem estatística: medidas de primeira ordem

- Momentos como visto para intensidades (os 3 primeiros são os mais usados), mas agora para uma janela de determinado tamanho.
- Espera-se que texturas similares tenham medidas estatísticas similares como média, desvio padrão e obliquidade
- Outras medidas podem ser usadas como a uniformidade e a entropia

Abordagem estatística: medidas de primeira ordem

- Uniformidade:

$$U(z) = \sum_{i=0}^{L-1} p(z_i)^2, \quad (1)$$

onde z representa os pixels numa determinada janela, $p(z_i)$, $i = 0..L - 1$ é a frequência da intensidade z_i , sendo p um histograma normalizado (soma dos valores é unitária).




- Entropia média

$$e(z) = - \sum_{i=0}^{L-1} p(z_i) \log_2 p(z_i), \quad (2)$$

onde z representa os pixels numa determinada janela $p(z_i)$ é a frequência da intensidade z_i .

Textons

- Textons podem ser extraídos das imagens a partir de pequenos pedaços das imagens (*patches*) e a formação de um dicionário de bases em diversas configurações geométricas e fotométricas.
 - o estudo que mostrou serem “átomos” da percepção visual humana foi publicado na Nature (Julesz, 1981)
 - há diversas maneiras de se extrair os textons: sparse coding over-complete basis (Olshausen; Field, 1997), micro-image patches (Lee et al., 2000).




Textons

- Uma janela (patch) da imagem se torna um vetor de características
- Elementos de mesma textura devem se agrupar no espaço de características

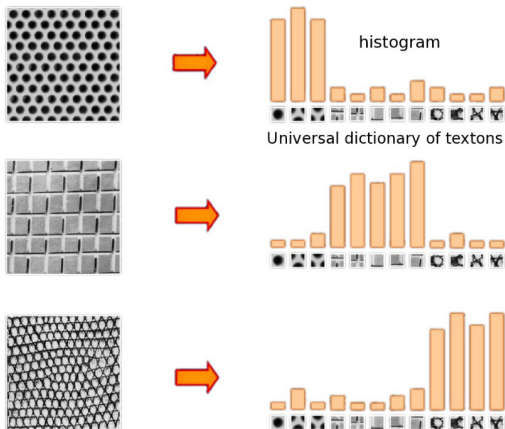
Abordagem: filtros

- um conjunto de filtros podem ser utilizados para capturar padrões
 - em geral filtros com bases altamente correlacionadas (diferente de bases Wavelet ortogonais)
 - na literatura são sugeridos no mínimo 4 escalas e 6 orientações



Abordagem estrutural: textons


- Uma das formas de se utilizar textons para classificar imagens é: uma vez formado um dicionário universal de textons, contar o número de vezes que eles aparecem em cada imagem



Textura: matriz de co-ocorrência

- Medidas de segunda ordem consideram o relacionamento entre grupos de dois pixels (usualmente vizinhos)
- A matriz de co-ocorrência considera a relação Q entre dois pixels:
 - pixel **referência** e pixel **vizinho**.
- Exemplo: $Q = (0, 1)$ significa deslocamento de 1 pixel na direção y (coluna), 0 na direção x (linha), ou seja, o pixel da direita.

Textura: matriz de co-ocorrência




```

0 0 1 1 1
0 0 1 1 1
0 2 2 2 2
2 2 3 3 3
2 2 3 3 3
  
```

- Considere a imagem ao lado (níveis de cinza) e um $Q = (0, 1)$.
- Cada pixel dentro da janela vai se tornar o pixel referência, começando pelo pixel do canto superior esquerdo.
- No exemplo os pixels da borda direita não possuem vizinho da direita e portanto não serão usados para o cálculo.
- Monte uma matriz G para um dado deslocamento d e L intensidades i, j , por:

$$G(i, j) = |\{(x, y) | f(x, y) = i, f(x + dx, y + dy) = j\}|$$

Textura: matriz de co-ocorrência



Considerando a configuração da posição relativa $Q = (0, 1)$:

pixel	viz. 0	viz. 1	viz. 2	viz. 3
ref. 0	2	2	1	0
ref. 1	0	4	0	0
ref. 2	0	0	5	2
ref. 3	0	0	0	4


```

0 0 1 1 1
0 0 1 1 1
0 2 2 2 2
2 2 3 3 3
2 2 3 3 3

```

Matriz tende a ser esparsa para mais níveis de intensidade. É comum usar 8 ou 16 níveis de cinza apenas para diminuir o tamanho da matriz e a complexidade computacional.

Textura: matriz de co-ocorrência



O número total de pares de pixels que satisfazem Q é igual a soma dos elementos da matriz G , e $p_{i,j} = g_{i,j}/n$ é a estimativa da probabilidade que um par de pontos que satisfaçam Q tenham valores (z_i, z_j) .

```

0 0 1 1 1
0 0 1 1 1
0 2 2 2 2
2 2 3 3 3
2 2 3 3 3

```

pixel	viz. 0	viz. 1	viz. 2	viz. 3
ref. 0	0.100	0.100	0.050	0.000
ref. 1	0.000	0.200	0.000	0.000
ref. 2	0.000	0.000	0.250	0.100
ref. 3	0.000	0.000	0.000	0.200

Textura: descritores de Haralick

Sejam as **médias** m e **variâncias** σ^2 das linhas r e colunas c dadas por:

$$m_r = \sum_{i=1}^L i \sum_{j=1}^L p_{i,j}$$

$$m_c = \sum_{j=1}^L j \sum_{i=1}^L p_{i,j}$$

$$\sigma_r^2 = \sum_{i=1}^L (i - m_r)^2 \sum_{j=1}^L p_{i,j}$$

$$\sigma_c^2 = \sum_{j=1}^L (j - m_c)^2 \sum_{i=1}^L p_{i,j}$$

Textura: descritores de Haralick

- Descritores que caracterizam matrizes de co-ocorrência são chamados de descritores de **Haralick** pelo método ter sido proposto por Robert Haralick (Haralick et al. 1973):
- Probabilidade máxima: resposta mais forte de G , intervalo $[0, 1]$

$$\max_{i,j} p_{i,j} \quad (3)$$

- Correlação: entre pixels referência e seus vizinhos na imagem inteira, intervalo $[-1, 1]$

$$\sum_{i=1}^L \sum_{j=1}^L \frac{(i - m_r)(j - m_c)p_{i,j}}{\sigma_r \sigma_c}, \quad (4)$$

requer $\sigma_r \neq 0$ e $\sigma_c \neq 0$,

Textura: descritores de Haralick

- Contraste: de intensidade entre pixels referência e seus vizinhos na imagem inteira, intervalo $[0, (L - 1)^2]$

$$\sum_{i=1}^L \sum_{j=1}^L (i - j)^2 p_{i,j} \quad (5)$$

- Uniformidade (energia): da imagem, intervalo $[0, 1]$, sendo 1 para imagem constante.

$$\sum_{i=1}^L \sum_{j=1}^L p_{i,j}^2 \quad (6)$$

Textura: descritores de Haralick

- Homogeneidade: medida da autocorrelação espacial, intervalo $[0, 1]$, sendo 1 para G diagonal.

$$\sum_{i=1}^L \sum_{j=1}^L \frac{p_{i,j}}{1 + |i - j|} \quad (7)$$

- Entropia: aleatoriedade de elementos de G , intervalo $[0, 2 \log_2 L]$, sendo máxima para $p_{i,j}$ constante e mínima quando $p_{i,j} = 0$.

$$- \sum_{i=1}^L \sum_{j=1}^L p_{i,j} \log_2 p_{i,j} \quad (8)$$

Textura: descritores de Haralick



- Homogeneidade: medida da autocorrelação espacial, intervalo $[0, 1]$, sendo 1 para G diagonal.

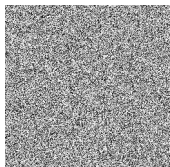
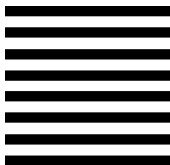

$$\sum_{i=1}^L \sum_{j=1}^L \frac{p_{i,j}}{1 + |i - j|} \quad (9)$$

- Entropia: aleatoriedade de elementos de G , intervalo $[0, 2 \log_2 L]$, sendo máxima para $p_{i,j}$ constante e mínima quando $p_{i,j} = 0$.

$$- \sum_{i=1}^L \sum_{j=1}^L p_{i,j} \log_2 p_{i,j} \quad (10)$$


Textura: descritores de Haralick — exemplo




	P.Max	Corr.	Cont.	Unif.	Homog.	Entrop.
	0.099	0.007	1273.68	0.019	0.328	5.741
	0.437	0.884	230.71	0.445	0.512	1.320
	0.330	0.802	99.97	0.130	0.639	4.323

Local Binary Patterns (LBP)


- Proposto por Ojala (1996), baseia-se na ideia de que texturas podem ser descritas por duas medidas complementares:
 - padrões espaciais locais; e
 - contraste dos níveis de cinza.
- LBP resume as estruturas locais na imagem gerando uma representação estatística dessas estruturas.
- Considera P, R a vizinhança de pixel com P pontos de amostragem em um círculo de raio R .



$$P = 8, R = 1$$



$$P = 12, R = 2$$



$$P = 16, R = 4$$

Local Binary Patterns (LBP)


- O valor de um código LBP para um pixel central c , de coordenada (x_c, y_c) , com amostragem de P vizinhos no raio R é:

$$LBP_{P,R} = \sum_{p=0}^{P-1} s(g_p - g_c) 2^p \quad (11)$$

$$s(x) = \begin{cases} 1, & \text{se } x > 0; \\ 0, & \text{caso contrário,} \end{cases} \quad (12)$$

onde g_p e g_c são os níveis de cinza dos pontos da vizinhança p e central c

Local Binary Patterns (LBP)



http://www.bytefish.de/blog/local_binary_patterns/

Local Binary Patterns (LBP)


Para $c = (1, 1)$, com $g_c = 0$, temos:



$$\begin{aligned}
 LBP_{8,1} &= s(1 - 0)2^0 + s(2 - 0)2^1 + s(2 - 0)2^2 + s(0 - 0)2^3 + \\
 &\quad s(0 - 0)2^4 + s(0 - 0)2^5 + s(0 - 0)2^6 + s(1 - 0)2^7 \\
 &= 1 \cdot 1 + 1 \cdot 2 + 1 \cdot 4 + 0 + 0 + 0 + 0 + 1 \cdot 128 = \mathbf{135}
 \end{aligned}$$

Para $c = (2, 3)$, com $g_c = 2$, temos:

$$LBP_{8,1} = 0 + 2 + 4 + 8 + 0 + 0 + 0 + 0 = \mathbf{14}$$



Para $c = (3, 3)$, com $g_c = 3$, temos:


$$LBP_{8,1} = 0 + 0 + 0 + 0 + 0 + 0 + 0 + 0 = \mathbf{0}$$

Local Binary Patterns (LBP)

- Um LBP é uniforme ou não uniforme pelo número de transições 0, 1
- Padrões uniformes:
 - 11111111 : nenhuma transição
 - 11110000 : uma transição
 - 11000111 : duas transições
- Padrões não uniformes:
 - 11001101 : quatro transições
 - 01010010 : seis transições
- Ojala redomenda o uso de rótulos para cada padrão uniforme e um único rótulo para todos os não-uniformes, visto que os uniformes:
 - representam $\sim 90\%$ do total com $LBP_{8,1}$ e $\sim 70\%$ com $LBP_{16,2}$
- Para $LBP_{8,R}$, há 256 padrões possíveis, 58 uniformes, e **59** no total.

Local Binary Patterns (LBP)

- Um vetor de características pode ser calculado por meio do histograma dos LBPs
- Cada LBP pode ser considerado um micro-texton.
- Primitivas locais codificadas por cada posição do histograma incluem diferentes tipos de bordas, pontos, regiões planas e cantos.



http://www.bytefish.de/blog/local_binary_patterns/

Referências

- Gonzalez and Woods. Processamento Digital de Imagens. 3.ed. Capítulo 11. 2010.
- Haralick, R.M.; Shanmugan, K.; Dinstein, I. Textural features for image classification.- IEEE Transactions on Systems, Man and Cybernetics, Los Alamitos, v.SMC-3,n.6, pp. 610-621, 1973. OBS: Citado 8945 vezes (Scholar Google, Abr/2013).
- Dalal, N.; Triggs, B. Histogram of Oriented Gradients for Human Detection. CVPR 2005.
- Hall-Beyer, M. The GLCM Tutorial Home Page:
http://www.fp.ucalgary.ca/mhallbey/the_glcm.htm
- Ojala, T.; Pietikäinen, M.; Harwood, D. A Comparative Study of Texture Measures with Classification Based on Feature Distributions. Pattern Recognition 19(3):51-59, 1996.