

# Tópico 6 - Descritores de Texturas

João B. Florindo

Instituto de Matemática, Estatística e Computação Científica  
Universidade Estadual de Campinas - Brasil  
jbflorindo@ime.unicamp.br

# Outline

1 Matrizes de Co-ocorrência / Haralick

2 Medidas Estatísticas

# Descritores de Imagens

Matrizes de coocorrência propostas por Haralick em 1973 para imagens de textura

Abordagem estatística mais refinada do que histograma

Estatísticas obtidas a partir de como *pixels* se organizam em vizinhanças -  
Dá origem a toda uma família de métodos, e.g. LBP

Seja o conjunto de pontos  $\mathbf{X} = \mathbb{Z}_m \times \mathbb{Z}_n$  e  $G$  o número de valores possíveis para os *pixels* e uma imagem  $\mathbf{a} \in \mathbb{Z}_G^{\mathbf{X}}$

# Descritores de Imagens

Definimos então a seguinte distribuição conjunta:

$$s(\Delta x, \Delta y : i, j) = \text{probabilidade}\{\mathbf{a}(x, y) = i \text{ e } \mathbf{a}(x + \Delta x, y + \Delta y) = j\}$$

em que  $\Delta x, \Delta y \in \mathbb{Z}$ .

Podemos também usar coordenadas polares, definindo  $\theta = \arctan\left(\frac{\Delta y}{\Delta x}\right)$  e  $d = \sqrt{(\Delta x)^2 + (\Delta y)^2}$ .

Temos assim:

$$s(d, \theta : i, j) = \text{probabilidade}\{\mathbf{a}(x, y) = i \text{ e } \mathbf{a}(x + d \cos \theta, y + d \sin \theta) = j\}$$

Temos assim a distribuição da coocorrência de pares de valores para cada distância e cada direção.

## Descritores de Imagens

É usual que se discretize  $\theta$  para  $0^\circ$ ,  $45^\circ$ ,  $90^\circ$  e  $135^\circ$ . Distâncias não-Euclidianas (*chessboard* ou *cityblock* por exemplo) são também comuns.

Define-se então uma matriz  $\mathbf{s}(d, \theta)$ , chamada de **dependência espacial**, com dimensões  $G \times G$  tal que

$$\mathbf{s}(d, \theta)_{ij} = \mathbf{s}(d, \theta : i, j)$$

Note que a indexação desta matriz começa em  $(0, 0)$ :  $0 \leq i, j \leq G - 1$ .

Na prática, a matriz é calculada usando  $\Delta x$  e  $\Delta y$  de acordo com a distância e ângulo (horizontal, vertical ou diagonal para intervalos de  $45^\circ$ ).

# Descritores de Imagens

Temos de fato:

$$s(\Delta x, \Delta y : i, j) = \text{card}\{(x, y) : \mathbf{a}(x, y) = i \text{ e } \mathbf{a}(x + \Delta x, y + \Delta y) = j\}$$

Considere por exemplo  $\mathbf{X} = \mathbb{Z}_4 \times \mathbb{Z}_4$  e a imagem  $\mathbf{a} \in \mathbb{Z}_3^{\mathbf{X}}$  abaixo:

1	0	0	2
0	1	1	1
2	2	1	0
1	0	1	0

Usando distância *chessboard*  $\max\{|\Delta x|, |\Delta y|\}$  teríamos

$$s(1, 0^\circ) = \begin{bmatrix} 1 & 2 & 1 \\ 2 & 2 & 1 \\ 1 & 2 & 1 \end{bmatrix} \quad s(1, 45^\circ) = \begin{bmatrix} 0 & 2 & 1 \\ 2 & 2 & 0 \\ 1 & 1 & 0 \end{bmatrix}$$

$$s(1, 135^\circ) = \begin{bmatrix} 1 & 2 & 0 \\ 1 & 1 & 2 \\ 0 & 2 & 0 \end{bmatrix} \quad s(2, 90^\circ) = \begin{bmatrix} 1 & 1 & 1 \\ 1 & 2 & 0 \\ 1 & 1 & 0 \end{bmatrix}$$

## Descritores de Imagens

Na **matriz de coocorrência** não se distingue entre  $\mathbf{s}(d, \theta : i, j)$  e  $\mathbf{s}(d, \theta : j, i)$ , gerando assim:

$$\mathbf{c}(d, \theta) = \mathbf{s}(d, \theta) + \mathbf{s}'(d, \theta)$$

No nosso exemplo:

$$\mathbf{c}(1, 0^\circ) = \begin{bmatrix} 2 & 4 & 2 \\ 4 & 4 & 3 \\ 2 & 3 & 0 \end{bmatrix} \quad \mathbf{c}(1, 45^\circ) = \begin{bmatrix} 0 & 4 & 2 \\ 4 & 4 & 1 \\ 2 & 1 & 0 \end{bmatrix}$$

$$\mathbf{c}(1, 135^\circ) = \begin{bmatrix} 2 & 3 & 0 \\ 3 & 2 & 4 \\ 0 & 4 & 0 \end{bmatrix} \quad \mathbf{c}(2, 90^\circ) = \begin{bmatrix} 2 & 2 & 2 \\ 2 & 4 & 1 \\ 2 & 1 & 0 \end{bmatrix}$$

A simetria da coocorrência implica que

$$\mathbf{c}(d, \theta) = \mathbf{c}(d, \theta + \pi)$$

e por isso apenas ângulos entre 0 e  $\pi$  bastam.

# Outline

1 Matrizes de Co-ocorrência / Haralick

2 Medidas Estatísticas



## Descritores de Imagens

Da coocorrência obtemos distribuições marginais:

$$\mathbf{c}_x(d, \theta : i) = \sum_j \mathbf{c}(d, \theta : i, j)$$

$$\mathbf{c}_y(d, \theta : j) = \sum_i \mathbf{c}(d, \theta : i, j)$$

bem como suas médias e variâncias:

$$\mu_x(d, \theta) = \sum_i i \mathbf{c}_x(d, \theta : i)$$

$$\mu_y(d, \theta) = \sum_j j \mathbf{c}_y(d, \theta : j)$$

$$\sigma_x^2(d, \theta) = \sum_i (i - \mu_x(d, \theta))^2 \mathbf{c}_x(d, \theta : i)$$

$$\sigma_y^2(d, \theta) = \sum_j (j - \mu_y(d, \theta))^2 \mathbf{c}_y(d, \theta : j).$$

# Descritores de Imagens

Algumas das medidas mais comumente extraídas da matriz de coocorrências são:

Energia:

$$\sum_i \sum_j \{c(d, \theta : i, j)\}^2$$

Entropia:

$$\sum_i \sum_j c(d, \theta : i, j) \log(c(d, \theta : i, j))$$

Correlação:

$$\frac{\sum_i \sum_j (i - \mu_x(d, \theta))(j - \mu_y(d, \theta))c(d, \theta : i, j)}{\sigma_x(d, \theta)\sigma_y(d, \theta)}$$

Momento diferencial inverso:

$$\sum_i \sum_j \frac{1}{1 + (i - j)^2} c(d, \theta : i, j)$$

# Descritores de Imagens

Inércia:

$$\sum_i \sum_j (i - j)^2 \mathbf{c}(d, \theta : i, j).$$

Formulação Algébrica:

Seja  $\mathbf{X}$  uma grade retangular  $m \times n$  e  $G$  o número de níveis de cinza.

A imagem original é então  $\mathbf{a} \in \mathbb{Z}_G^{\mathbf{X}}$ .

Usamos ainda distâncias do tipo *chessboard*  $d \in \mathbb{Z}^+$  e direções  $\theta \in \{0^\circ, 45^\circ, 90^\circ, 135^\circ\}$ .

Em seguida definimos a função de vizinhança

$$N(x, y) = \{(x + \Delta x, y + \Delta y)\}$$

# Descritores de Imagens

Então a “imagem” da matriz de dependência  $\mathbf{s}$  é obtida por

```

for  $i := 0$  to  $G - 1$  loop
    for  $j := 0$  to  $G - 1$  loop
         $\mathbf{s}(\Delta x, \Delta y)(i, j) := \sum \chi_2[\chi_i(\mathbf{a}) + \chi_j(\mathbf{a}) \oplus M]$ 
    end loop
end loop
  
```

No caso da coocorrência temos

$$\mathbf{c}(\Delta x, \Delta y) := \mathbf{s}(\Delta x, \Delta y) + \mathbf{s}'(\Delta x, \Delta y).$$

# Descritores de Imagens

Para as probabilidades marginais teremos

```

for  $i := 0$  to  $G - 1$  loop
    for  $j := 0$  to  $G - 2$  loop
         $c_x(\Delta x, \Delta y)(i) := c(\Delta x, \Delta y)(i, j) + c(\Delta x, \Delta y)(i, j + 1)$ 
    end loop
end loop

```

```

for  $i := 0$  to  $G - 1$  loop
    for  $j := 0$  to  $G - 2$  loop
         $c_y(\Delta x, \Delta y)(j) := c(\Delta x, \Delta y)(i, j) + c(\Delta x, \Delta y)(i + 1, j)$ 
    end loop
end loop

```

# Descritores de Imagens

Podemos definir agora a imagem identidade  $\mathbf{i} \in (\mathbb{Z}_G)^{\mathbb{Z}_G}$  e assim as médias e variâncias:

$$\mu_x(\Delta x, \Delta y) = \sum \mathbf{i} \cdot \mathbf{c}_x(\Delta x, \Delta y)$$

$$\mu_y(\Delta x, \Delta y) = \sum \mathbf{i} \cdot \mathbf{c}_y(\Delta x, \Delta y)$$

$$\sigma_x^2(\Delta x, \Delta y) = \sum (\mathbf{i} - \mu_x(\Delta x, \Delta y))^2 \cdot \mathbf{c}_x(\Delta x, \Delta y)$$

$$\sigma_y^2(\Delta x, \Delta y) = \sum (\mathbf{i} - \mu_y(\Delta x, \Delta y))^2 \cdot \mathbf{c}_y(\Delta x, \Delta y).$$

## Descritores de Imagens

Finalmente temos as medidas estatísticas:

Energia:

$$E := \sum [\mathbf{c}(\Delta x, \Delta y)]^2$$

Entropia:

$$Entrop := \sum \mathbf{c}(\Delta x, \Delta y) \cdot \log(\mathbf{c}(\Delta x, \Delta y))$$

Correlação:

$$C := \frac{[\sum (\mathbf{p}_1 - \mu_x(\Delta x, \Delta y))(\mathbf{p}_2 - \mu_y(\Delta x, \Delta y))\mathbf{c}(\Delta x, \Delta y)]}{\sigma_x(\Delta x, \Delta y)\sigma_y(\Delta x, \Delta y)}$$

em que  $\mathbf{p}_1, \mathbf{p}_2 \in (\mathbb{Z}_G)^{\mathbf{Y}}$  são projeções em uma grade  $\mathbf{Y}$  de dimensões  $G \times G$  dadas por

$$\mathbf{p}_1(i, j) = i \quad \mathbf{p}_2(i, j) = j.$$

Momento diferencial inverso:

$$IDM := \sum \frac{\mathbf{c}(\Delta x, \Delta y)}{\mathbf{1} + (\mathbf{p}_1 - \mathbf{p}_2)^2}$$

# Descritores de Imagens

Inércia:

$$I := \sum (\mathbf{p}_1 - \mathbf{p}_2)^2 \cdot \mathbf{c}(\Delta x, \Delta y).$$