

Processamento de Imagens

Análise de Texturas

Thelmo de Araujo

Semestre 2013-2

1 abc

1 Sumário

Esta apresentação baseia-se no Capítulo 8 do livro [?]
Análise de Imagens Digitais,
de Hélio Pedrini e William Robson Schwartz.

Medidas baseadas na distribuição dos níveis de cinza

As principais medidas da distribuição dos níveis de cinza em imagem com n pixels são:

- Média:

$$\mu = \frac{1}{n} \sum_{i=1}^n g_i.$$

- Variância:

$$\sigma^2 = \frac{1}{n} \sum_{i=1}^n (g_i - \mu)^2.$$

- Simetria:

$$s = \frac{1}{n\sigma^3} \sum_{i=1}^n (g_i - \mu)^3.$$

- Curtose:

$$k = \left(\frac{1}{n\sigma^4} \sum_{i=1}^n (g_i - \mu)^4 \right) - 3.$$

Medidas baseadas na distribuição dos níveis de cinza

As principais medidas da distribuição dos níveis de cinza em imagem com n pixels são:

- Média:

$$\mu = \frac{1}{n} \sum_{i=1}^n g_i.$$

- Variância:

$$\sigma^2 = \frac{1}{n} \sum_{i=1}^n (g_i - \mu)^2.$$

- Simetria:

$$s = \frac{1}{n\sigma^3} \sum_{i=1}^n (g_i - \mu)^3.$$

- Curtose:

$$k = \left(\frac{1}{n\sigma^4} \sum_{i=1}^n (g_i - \mu)^4 \right) - 3.$$

Medidas baseadas na distribuição dos níveis de cinza

As principais medidas da distribuição dos níveis de cinza em imagem com n pixels são:

- Média:

$$\mu = \frac{1}{n} \sum_{i=1}^n g_i.$$

- Variância:

$$\sigma^2 = \frac{1}{n} \sum_{i=1}^n (g_i - \mu)^2.$$

- Simetria:

$$s = \frac{1}{n\sigma^3} \sum_{i=1}^n (g_i - \mu)^3.$$

- Curtose:

$$k = \left(\frac{1}{n\sigma^4} \sum_{i=1}^n (g_i - \mu)^4 \right) - 3.$$

Medidas baseadas na distribuição dos níveis de cinza

As principais medidas da distribuição dos níveis de cinza em imagem com n pixels são:

- Média:

$$\mu = \frac{1}{n} \sum_{i=1}^n g_i.$$

- Variância:

$$\sigma^2 = \frac{1}{n} \sum_{i=1}^n (g_i - \mu)^2.$$

- Simetria:

$$s = \frac{1}{n\sigma^3} \sum_{i=1}^n (g_i - \mu)^3.$$

- Curtose:

$$k = \left(\frac{1}{n\sigma^4} \sum_{i=1}^n (g_i - \mu)^4 \right) - 3.$$

Medidas baseadas na distribuição dos níveis de cinza

As principais medidas da distribuição dos níveis de cinza em imagem com n pixels são:

- Média:

$$\mu = \frac{1}{n} \sum_{i=1}^n g_i.$$

- Variância:

$$\sigma^2 = \frac{1}{n} \sum_{i=1}^n (g_i - \mu)^2.$$

- Simetria:

$$s = \frac{1}{n\sigma^3} \sum_{i=1}^n (g_i - \mu)^3.$$

- Curtose:

$$k = \left(\frac{1}{n\sigma^4} \sum_{i=1}^n (g_i - \mu)^4 \right) - 3.$$

Matriz de co-ocorrência

Matriz de co-ocorrência com $d = 1$ e $\theta = 0^\circ$:

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

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

	0	1	2	3
0	0.15	0.10	0.05	0.05
1	0.10	0.00	0.10	0.05
2	0.05	0.05	0.00	0.10
3	0.10	0.05	0.05	0.00

Matriz de co-ocorrência

Matriz de co-ocorrência com $d = 1$ e $\theta = 0^\circ$:

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

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

	0	1	2	3
0	0.15	0.10	0.05	0.05
1	0.10	0.00	0.10	0.05
2	0.05	0.05	0.00	0.10
3	0.10	0.05	0.05	0.00

Matriz de co-ocorrência

Matriz de co-ocorrência com $d = 1$ e $\theta = 0^\circ$:

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

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

	0	1	2	3
0	0.15	0.10	0.05	0.05
1	0.10	0.00	0.10	0.05
2	0.05	0.05	0.00	0.10
3	0.10	0.05	0.05	0.00

Matriz de co-ocorrência

Matriz de co-ocorrência com $d = 1$ e $\theta = 0^\circ$:

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

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

	0	1	2	3
0	0.15	0.10	0.05	0.05
1	0.10	0.00	0.10	0.05
2	0.05	0.05	0.00	0.10
3	0.10	0.05	0.05	0.00

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

Pode-se normalizar os elementos da matriz de co-ocorrência para que representem probabilidades fazendo:

$$p(i, j) = \frac{P(i, j)}{\sum_{p=0}^{H_g} \sum_{q=0}^{H_g} P(p, q)},$$

sendo H_g o nível de cinza máximo na imagem.

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

Pode-se normalizar os elementos da matriz de co-ocorrência para que representem probabilidades fazendo:

$$p(i, j) = \frac{P(i, j)}{\sum_{p=0}^{H_g} \sum_{q=0}^{H_g} P(p, q)},$$

sendo H_g o nível de cinza máximo na imagem.

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

Pode-se normalizar os elementos da matriz de co-ocorrência para que representem probabilidades fazendo:

$$p(i, j) = \frac{P(i, j)}{\sum_{p=0}^{H_g} \sum_{q=0}^{H_g} P(p, q)},$$

sendo H_g o nível de cinza máximo na imagem.

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

Pode-se normalizar os elementos da matriz de co-ocorrência para que representem probabilidades fazendo:

$$p(i, j) = \frac{P(i, j)}{\sum_{p=0}^{H_g} \sum_{q=0}^{H_g} P(p, q)},$$

sendo H_g o nível de cinza máximo na imagem.

Tipos de Sinais – Exemplos

Uma imagem pode ser vista como um sinal que é, por sua vez, uma função de duas variáveis espaciais: x e y .



Tipos de Sinais – Exemplos

Uma imagem pode ser vista como um sinal que é, por sua vez, uma função de duas variáveis espaciais: x e y .



