

# Image Descriptors: color

## Image Processing — scc0251

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

ICMC/USP — São Carlos, SP, Brazil

2011

# Agenda

- 1 Introdução
- 2 Histograma de cor
- 3 Momentos
- 4 Correlograma de cores

# Agenda

- 1 Introdução
- 2 Histograma de cor
- 3 Momentos
- 4 Correlograma de cores

# Descritores visuais

**Problema** — computar de forma eficiente valores que possam descrever uma imagem (ou parte de uma imagem)

- **Discriminativos**
- **Robusto com relação à:** transformações na imagem e nos objetos, ponto de visão e oclusão.
- **Robusto com relação à:** transformações nos objetos, ponto de visão e oclusão.

É importante que os descritores sejam comparáveis, por alguma métrica de similaridade ou dissimilaridade.

# Descritores visuais

- Cor
- Textura
- Características Locais
- Bag-of-visual-words

# Agenda


- 1 Introdução
- 2 Histograma de cor**
- 3 Momentos
- 4 Correlograma de cores

# Histograma de cor

Representa a distribuição de cores, ou a frequência de cada cor na imagem:



- Cada barra corresponde a uma cor no espaço de cores quantizado.

# Histograma de cor





# Histograma de cor



# Histograma de cor

Para usar o histograma como descritor:

- 1 Selecionar o espaço de cores (RGB, HSV, ...)
- 2 Quantizar o espaço de cores
- 3 Computar o histograma
- 4 Selecionar métricas de distância entre histogramas

# Histograma de cor

## Quantizar o espaço de cores

- Comumente transforma três canais de cor em um canal com 64 cores.
  - Pode ser feito pegando os 2 bits mais significativos de cada canal
- Se o tamanho da imagem for muito pequeno (largura  $< 124$  pixels), essa escolha (número de cores) deve ser melhor estudada (Picon; Rossi; Ponti-Jr, 2011).

# Histograma de cor

Selecionar métricas de distância entre histogramas:

- Minkowski (norma  $L^p$ )
- Euclidiana (norma  $L^2$ )
- Manhattan (norma  $L^1$ )
- Logaritmica
- outras

# Histograma de cor

Sejam  $q$  e  $d$  histogramas com  $M$  cores cada.

Distância Tipo-Minkowski:

$$dTM(q, d) = \left[ \sum_{i=0}^M (q[i] - d[i])^p \right]^{1/p}, \quad (1)$$

Distância Euclidiana:

$$dEuclid(q, d) = \sqrt{\sum_{i=0}^M (q[i] - d[i])^2}, \quad (2)$$

Distância Manhattan:

$$dManhattan(q, d) = \sum_{i=0}^M |(q[i] - d[i])|, \quad (3)$$

## Histograma de cor

Distância Logaritmica:

$$dLog(q, d) = \sum_{i=0}^{i < M} |f(q[i]) - f(d[i])| \quad (4)$$

onde

$$f(x) = \begin{cases} 0, & \text{se } x = 0 \\ 1, & \text{se } 0 < x < 1 \\ \lceil \log_2 x \rceil + 1, & \text{caso contrário} \end{cases}, \quad (5)$$

A distância Logaritmica visa prevenir que a soma das diferenças seja dominada por cores muito presentes em um histograma e pouco em outro.

# Histograma de cor

## Exemplos de descritores baseados em histogramas

- Global Color Histogram (GCH): computa um único histograma para cada imagem
- Local Color Histogram (LCH): particiona a imagem em um número fixo de células e computa o histograma de cada célula
- Border/Interior Classification (BIC): computa dois histogramas — um para os pixels classificados como borda e outro para os pixels classificados como interior.
- Color Coherence Vectors (CCV): encontra os componentes (cores) conectados na imagem classificando pixels em coerente ou incoerentes (determinado por um limiar), monta um histograma com o número de pixels coerentes e incoerentes de cada cor.

# Histograma de cor

## Vantagens

- Fácil de implementar
- Rápido de calcular
- Representação compacta da informação de cor
- Pode (e deve) ser normalizado de forma que diferentes histogramas de imagens possam ser comparados. Exemplo: soma dos valores unitária.



# Histograma de cor

## Desvantagens

- Não extrai informação local de objetos e da cena
- Estruturas de tamanho fixo

# Agenda

- 1 Introdução
- 2 Histograma de cor
- 3 Momentos**
- 4 Correlograma de cores

# Momentos de Cor/Intensidade

Usar momentos se baseia na suposição de que é possível interpretar a distribuição de cor numa imagem como uma distribuição de probabilidade.

- Diferentes distribuições de probabilidade são caracterizadas por um número de momentos: Normal = (média, variância), i.e.  $\mathcal{N}(\mu, \sigma^2)$ .

Seja  $i$  um canal de cor e  $j$  um pixel de uma imagem  $f$  com  $N$  pixels.

Primeiro momento — Média

$$E_i = \frac{1}{N} \sum_{j=1}^N f_{i,j} \quad (6)$$

## Momentos de Cor/Intensidade

Momentos  $d > 1$ 

$$m_i = \left[ \frac{1}{N} \sum_{j=1}^N (f_{i,j} - E_i)^d \right]^{1/d} \quad (7)$$

Segundo momento: desvio padrão

$$\sigma_i = \sqrt{\frac{1}{N} \sum_{j=1}^N (f_{i,j} - E_i)^2} \quad (8)$$

## Momentos de Cor/Intensidade

Terceiro momento: obliquidade (*skewness*)

Medida da assimetria de uma determinada distribuição de frequência

$$s_i = \left[ \frac{1}{N} \sum_{j=1}^N (f_{i,j} - E_i)^3 \right]^{1/3} \quad (9)$$

Quarto momento: curtose (*kurtosis*)

Medida de dispersão e da relação entre pico e achatamento da distribuição de frequência

$$k_i = \left[ \frac{1}{N} \sum_{j=1}^N (f_{i,j} - E_i)^4 \right]^{1/4} \quad (10)$$

## Distância entre momentos

A soma ponderada das diferenças entre os momentos de duas distribuições:

$$DOM(a, b) = \sum_{i=1}^C w_{i,1} |E_i^a - E_i^b| + w_{i,2} |\sigma_i^a - \sigma_i^b| + w_{i,3} |s_i^a - s_i^b| + w_{i,4} |k_i^a - k_i^b| \quad (11)$$

onde:

- $a$  e  $b$  são duas imagens sendo comparadas por seus momentos
- $i = 1 \dots C$  é o número de canais de cor na imagem
- $w_i$  são os pesos de cada momento

Podem ser usados diversos sistemas de cor. Em geral o HSV é utilizado e ponderado de forma que o canal H possua peso maior.

# Agenda


- 1 Introdução
- 2 Histograma de cor
- 3 Momentos
- 4 Correlograma de cores**

# Correlograma de cores

Descreve a distribuição global da correlação entre a localização espacial de cores.

- Uma tabela indexada de pares de cores  $P(c_i, c_j, d)$  especifica a probabilidade de encontrar um pixel de cor  $c_j$  a uma distância  $d$  de um pixel de cor  $c_i$  na imagem.

Exemplo:  $P(\text{'vermelho'}, \text{'laranja'}, 4.42)$  é a probabilidade de existir



- Um **autocorrelograma** captura a correlação espacial entre cores idênticas (é um subconjunto de correlogramas).



## Autocorrelograma de cores

Dado um pixel  $p_1$  de cor  $c_i$  numa imagem  $f$  e um outro pixel  $p_2$  a uma distância de  $k$  de  $p_1$ .

- Qual a probabilidade de  $p_2$  também ser de cor  $c_i$ ?
- O autocorrelograma de uma imagem  $f$  para a cor  $c_i$  e uma distância  $k \in [d]$ :

$$\gamma_{c_i}^k(f) \equiv Pr(|p_1 - p_2| = k, p_2 \in f_{c_i} | p_1 \in f_{c_i}), \quad (12)$$

ou ainda:

$$\Gamma_{c_i}^k(f) \equiv |\{p_2 \in f_{c_i}, p_1 \in f_{c_i} \mid |p_1 - p_2| = k\}|, \quad (13)$$

um algoritmo simples considera cada  $p_1 \in f$  de cor  $c_i$  e, para cada  $k \in [d]$ , conta todo  $p_2 \in f$  de cor  $c_i$ , com  $|p_1 - p_2| = k$ .

# Autocorrelograma de cores

Implementação:


- A complexidade computacional depende da escolha de  $d$ .
- Há no entanto versões lineares (e mais complicadas) propostas pelos autores do algoritmo (Huang et al, 1997), baseadas em programação dinâmica e multiplicação matricial.
- Pode ser usada a distância Euclidiana – kernel circular –, ou chessboard (distância de Chebyshev, norma  $L^\infty$ ) – kernel quadrado.

$$d_{Chess}(p, q) = \max(|p_x - q_x|, |p_y - q_y|), \quad (14)$$


ou seja, o máximo da distância nas direções  $x$  e  $y$  entre os pixels  $p$  e  $q$ .

- Uma escolha comum é para o caso da  $d_{Chess}()$  é  $d = [1, 3, 5, 7]$  resultando em complexidade  $O(134 * n^2)$ .

## Autocorrelograma de cores




radius  $r$  = distance between regions



other radii

**Correlation** =  
pixel match between  
two regions covered  
by kernel



**Maximum Correlation:**  
(radius of kernel  $r$  =  
distance between  
regions)

Correlation decreases  
as difference between  
radius and distance  
increase

# Autocorrelograma de cores

## Propriedades

- Invariante à translação
- Robusto à transformações afins e de perspectiva
- Robusto à mudança de ponto de vista.
- Não é invariante à escala.

# Referências

- Gonzalez and Woods. Processamento Digital de Imagens. 3.ed. Capítulo 6. 2010.
- Huang, Kumar, Mitra, Zhu and Zabih. Image Indexing using Color Correlograms. IEEE Proc. Conf. on Computer Vision and Pattern Recognition, 1997, pp. 762–768.
- Swain and Ballard. Color Indexing. Inter. Journal of Computer Vision, vol.7, n.1, 1991.
- Picon, Rossi and Ponti-Jr. Análise da classificação de imagens por descritores de cor utilizando várias resoluções. XXIV SIBGRAPI — Conference on Graphics, Images and Patterns, 2011, Workshop of Undergraduate Work.