



Representação e Descrição

Guillermo Cámara-Chávez

Introdução



- Objetos ou Segmentos são representados como uma coleção de pixels em uma imagem
- Para o reconhecimento do objeto é necessário descrever as propriedades dos grupos de pixels
- A descrição é muitas vezes apenas um conjunto de números que são chamados de **“descritores do objeto”**

Introdução



- Segmentos ou Objetos de uma imagem possuem fundamentalmente as propriedades relativas:
 - Forma
 - Cor
 - Textura

Introdução



- A medida de qualquer destas propriedades é denominada de Características ou Descritor
- Estas características podem formar um vetor de escalares, denominado **Vetor de Características**

Introdução



- Descritores:
 - Pode-se reconhecer objetos comparando-se simplesmente os descritores de objetos em uma imagem com os descritores de objetos conhecidos
- Os descritores devem ter quatro propriedades importantes
 1. Devem definir um conjunto completo. Dois objetos devem ter os mesmos descritores se e somente se eles tiveram as mesmas caract.

Introdução



2. Devem ser congruentes. Deve-se reconhecer objetos como similares quando estes objetos têm descritores semelhantes
3. Devem ter propriedades invariantes. Deve ser possível reconhecer objetos independente de rotação, escala, posição e também de transformações afins e perspectiva

Introdução



4. Devem ser um conjunto compacto. Um conjunto de descritores deve representar a essência de um objeto de maneira eficiente

Introdução



- Após a segmentação, os agrupamentos resultantes são usualmente representados e descritos em um formato apropriado
- Trata-se de representar e descrever uma determinada região da imagem de forma apropriada para posterior processamento
- Representa-se em termos de
 - Características externas (fronteira)
 - Características internas (pixels que compõem um região)

Introdução



Representa-se em termos de:


- Características externas (fronteira)
 - Escolhida quando a atenção primária está voltada para a forma da região
- Características internas (pixels que compõem uma região)
 - Escolhida quando a análise se concentrará em propriedades como cor ou textura.

Introdução



- Código de Cadeia
 - Usada para representar fronteiras
 - Fronteiras são consideradas sequências conectadas (conectividade de 4 ou 8) de segmentos de linha reta
 - A direção de cada segmento é codificada por um esquema de numeração.

Introdução



a b




FIGURE 11.3
Direction
numbers for
(a) 4-directional
chain code, and
(b) 8-directional
chain code.

- Escolhe-se um ponto aleatório na fronteira e percorre-se a mesma no sentido horário.
- Esta abordagem é inapropriada, pois as cadeias resultantes são muito longas e suscetíveis a ruídos

Introdução



- Reamostra-se a fronteira utilizando-se uma grade de espaçamento maior



a b c

FIGURE 11.4

(a) Digital boundary with resampling grid superimposed.
(b) Result of resampling.
(c) 8-directional chain-coded boundary.

Introdução




- Dependência do ponto inicial: rotaciona-se a cadeia até que se obtenha o inteiro de menor magnitude
- Rotação: utiliza-se a primeira diferença ao invés do código, a qual se calcula contando (no sentido horário) as direções que separam dois códigos adjacentes na cadeia.

Introdução




- A diferença é obtida contando-se em sentido horário
- Seja $a_0a_1\dots a_{n-1}$ o código da cadeia que representa a borda
- A primeira diferença é dada por $b_0b_1\dots b_{n-1}$, em que $b_k = a_k - a_{k-1}$
- A diferença é realizada de forma circular, módulo 4 ou 8, conforme a vizinhança adotada

Introdução



(a)



(b)

Figura 7.4: Normalização do código da cadeia com respeito à rotação. (a) borda original do objeto, (b) borda após rotação do objeto em 90° .

- Cadeia 1: 11112232333000
- Cadeia 2: 22223303000111

Introdução




- Cadeia 1: 11112232333000
- Diferença 1 : 0001013100100
- Cadeia 2: 22223303000111
- Diferença 2 : 0001013100100
- Portanto, esses dois códigos representam a mesma borda.
- Invariância à escala: reamostra-se a grade

Assinaturas



- Uma assinatura é uma representação funcional unidimensional de uma fronteira
- Reduzindo-se a representação da fronteira a um domínio unidimensional, espera-se que a mesma se torne mais simples de descrever
- Uma das formas de assinatura mais simples é a dada pela distância dos pontos da fronteira ao centróide em função do ângulo.

Assinaturas



a b

FIGURE 11.10

Distance-versus-angle signatures.

In (a) $r(\theta)$ is constant. In (b), the signature consists of repetitions of the pattern


$r(\theta) = A \sec \theta$ for $0 \leq \theta \leq \pi/4$ and $r(\theta) = A \csc \theta$ for $\pi/4 < \theta \leq \pi/2$.

Assinaturas



- A invariância com relação à rotação pode ser obtido pela seleção de um ponto inicial.
 - Uma maneira é escolher o ponto mais distante do centróide
- A invariância com relação à escala pode ser obtida pela normalização dos valores de $r(\vartheta)$

Assinaturas por Projeções



- Assinatura Vertical
$$h(y) = \sum_y f(x, y)$$
- Assinatura Horizontal
$$v(x) = \sum_x f(x, y)$$
- Assinatura Diagonal
$$d(t) = \sum_t f(x, y)$$

Descritores de Fronteiras



1. Comprimento da Fronteira (Perímetro)
 - Contagem do número de píxels da Fronteira
 - Usando o código de cadeia:
 - de 4 direções: número de elementos
 - de 8 direções: número de elementos pares (horizontais e verticais) mais $\sqrt{2}$ x (número de elementos ímpares) elementos diagonais

Descritores de Fronteiras




2. Diametro da Fronteira:

$$Diam(B) = \max_{i,j} [D(p_i, p_j)]$$

onde: $D(p_i, p_j)$ é a distância entre os píxels i e j sobre a fronteira B

- O valor do Diâmetro e a orientação da linha que conecta os dois pontos da fronteira mais distantes são descritores úteis

Descritores de Fronteiras




- Esta linha é também chamada de Eixo Maior da fronteira

Descritores de Fronteiras



3. Excentricidade da Fronteira

- É a razão entre o Eixo maior (D) e o Eixo Menor (d) da fronteira. $E = D/d$
- Eixo Menor é a maior distância entre dois pontos da fronteira B sobre uma perpendicular ao Eixo Maior
- Usar função **regionprops**



Descritores de Fronteiras




D = regionprops(L, properties)

L: matriz de etiquetas

**properties: 'Area', 'BoundingBox', 'Centroid',
'ConvexArea', 'ConvexHull', 'ConvexImage',
'Eccentricity', 'EquivDiameter', 'FilledArea',...,
'MajorAxisLength', 'MinorAxisLength',
'Perimeter'**

Descritores de Fronteiras



Descritores de Fronteiras



- Descritores de Fourier
 - São formados pelos coeficientes da transformada discreta de Fourier
 - Expressa as informações globais da curvatura de um objeto
 - Uma sequência de número é obtida a partir do plano cartesiano através das coordenadas do contorno do objeto

Descritores de Fronteiras



- Essas coordenadas podem ser representadas pela função unidimensional definida como:

$$s(k) = x(k) + jy(k)$$

- Sendo que $K = 0, 1, 2, \dots, N-1$ é o número de pontos, x é a coordenada real e y a coordenada imaginária

Descritores de Fronteiras



- A transformada de Fourier para $s(k)$

$$a(u) = \sum_{k=0}^{N-1} s(k) e^{-j2\pi uk / N}$$

- A transformada inversa

$$s(k) = \sum_{u=0}^{N-1} a(u) e^{j2\pi uk / N}$$

Descritores de Fronteiras



```
b = bwboundaries(img, 'noholes');
```

```
b = b{1};
```

```
z = frdescp(b);
```

```
nimg = ifrdescp(z, 100);
```


```
nimgg = bound2im(nimg, 145, 153);
```

```
imshow(nimgg);
```


Descritores de Fronteiras



Original



100



10

Descritores Regionais



1. Texturas:

- Fornece medidas de propriedades como suavidade, rugosidade e regularidade
- Abordagens principais: estatística, estrutural, espectral e análise local
- A abordagem estatística caracteriza as texturas como suave, áspera, granular, etc


Descritores Regionais




- Reconhecer o tipo de tecido.
- Segmentar as bordas.



(a)



(b)



(c)

Descritores Regionais



- A abordagem estrutural descreve as Texturas como arranjos de primitivas de imagem, tais como linhas regularmente espaçadas
- A abordagem espectral baseia-se em propriedades do espectro de Fourier
- A análise local é baseada na distribuição dos pixels em torno da vizinhança de cada pixel

Descritores Regionais

Abordagem Estatística

Descriptor	Explanation	Formula
Maximum probability	Measures the strongest response of G . The range of values is $[0, 1]$.	$\max_{ij}(p_{ij})$
Correlation	A measure of how correlated a pixel is to its neighbor over the entire image. Range of values is 1 to -1 , corresponding to perfect positive and perfect negative correlations. This measure is not defined if either standard deviation is zero.	$\frac{\sum_{i=1}^K \sum_{j=1}^K (i - m_r)(j - m_c)p_{ij}}{\sigma_r \sigma_c}$ $\sigma_r \neq 0; \sigma_c \neq 0$
Contrast	A measure of intensity contrast between a pixel and its neighbor over the entire image. The range of values is 0 (when G is constant) to $(K - 1)^2$.	$\sum_{i=1}^K \sum_{j=1}^K (i - j)^2 p_{ij}$
Uniformity (also called Energy)	A measure of uniformity in the range $[0, 1]$. Uniformity is 1 for a constant image.	$\sum_{i=1}^K \sum_{j=1}^K p_{ij}^2$
Homogeneity	Measures the spatial closeness of the distribution of elements in G to the diagonal. The range of values is $[0, 1]$, with the maximum being achieved when G is a diagonal matrix.	$\sum_{i=1}^K \sum_{j=1}^K \frac{p_{ij}}{1 + i - j }$
Entropy	Measures the randomness of the elements of G . The entropy is 0 when all p_{ij} 's are 0 and is maximum when all p_{ij} 's are equal. The maximum value is $2 \log_2 K$. (See Eq. (11.3-9) regarding entropy).	$-\sum_{i=1}^K \sum_{j=1}^K p_{ij} \log_2 p_{ij}$



Z_i : intensidade dos pixels

$P(z)$: histograma das intensidades

L : número dos possíveis níveis de cinza

Função matlab
graycoprops

Descritores Regionais



a b c

FIGURE 11.28
The white squares mark, from left to right, smooth, coarse, and regular textures. These are optical microscope images of a superconductor, human cholesterol, and a microprocessor. (Courtesy of Dr. Michael W. Davidson, Florida State University.)

Descritores Regionais



4. Momentos

- O momento de ordem $(p+q)$ de uma função contínua bi-dimensional é definido como:

$$m_{pq} = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} x^p y^q f(x, y) dx dy \quad \text{para } p, q = 0, 1, 2, \dots$$

$$m_{00} = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} x^0 y^0 f(x, y) dx dy = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x, y) dx dy$$

$$m_{00} = \text{área da Região}$$

Descritores Regionais



$$m_{01} = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} x^0 y^1 f(x, y) dx dy = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} y f(x, y) dx dy$$

$$m_{10} = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} x^1 y^0 f(x, y) dx dy = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} x f(x, y) dx dy$$

m_{01} e m_{10} são as coordenadas do Centro de Massa da Região

Descritores Regionais



Momentos centrais

- São momentos centralizados em regiões e podem ser expresso como:

$$\mu_{pq} = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} (x - \bar{x})^p (y - \bar{y})^q f(x, y) dx dy$$

Onde: $\bar{x} = \frac{m_{10}}{m_{00}}$ e $\bar{y} = \frac{m_{01}}{m_{00}}$ São as coordenadas do Centro de Massa, normalizadas pela área da região.

Descritores Regionais



- Para uma imagem digital

$$\mu_{pq} = \sum_x \sum_y (x - \bar{x})^p (y - \bar{y})^q f(x, y)$$

Descritores Regionais



Momentos Centrais até a ordem 3:

$$\mu_{00} = \sum_x \sum_y (x - \bar{x})^0 (y - \bar{y})^0 f(x, y) = \sum_x \sum_y f(x, y) = m_{00}$$

Ordem 1

$$\mu_{10} = \mu_{01} = 0$$

Ordem 2

$$\mu_{20} = m_{20} - \bar{x}m_{10}$$

$$\mu_{02} = m_{02} - \bar{y}m_{01}$$

$$\mu_{11} = m_{11} - \bar{y}m_{10}$$

Ordem 3

$$\mu_{12} = m_{12} - 2\bar{y}m_{11} - \bar{x}m_{02} + 2\bar{y}^2m_{10}$$

$$\mu_{21} = m_{21} - 2\bar{x}m_{11} - \bar{y}m_{20} + 2\bar{x}^2m_{01}$$

$$\mu_{30} = m_{30} - 3\bar{x}m_{20} + 2\bar{x}^2m_{10}$$

$$\mu_{03} = m_{03} - 3\bar{y}m_{02} + 2\bar{y}^2m_{01}$$

São Invariantes com relação à escala.

Descritores Regionais



Momentos Invariantes:

- Conjunto de momentos (Momentos Invariantes de Hu) que são relativamente invariantes à translação, rotação e escala.
- Momentos centrais normalizados pela área:

$$\eta_{pq} = \frac{\mu_{pq}}{\mu_{00}^\gamma}$$

Onde:

$$\gamma = \frac{p+q}{2} + 1$$

Para $p+q=2,3,4,\dots$

Momentos Invariantes de Hu:

$$\phi_1 = \eta_{20} + \eta_{02}$$

$$\phi_2 = (\eta_{20} - \eta_{02})^2 + 4\eta_{11}^2$$

$$\phi_3 = (\eta_{30} - 3\eta_{12})^2 + (3\eta_{21} - \eta_{03})^2$$

$$\phi_4 = (\eta_{30} + \eta_{12})^2 + (\eta_{21} + \eta_{03})^2$$

$$\phi_5 = (\eta_{30} - 3\eta_{12})(\eta_{30} + \eta_{12})[(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2] + \\ (3\eta_{21} - \eta_{03})(\eta_{21} + \eta_{03})[3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2]$$

$$\phi_6 = (\eta_{20} - \eta_{02})[(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2] + \\ 4\eta_{11}(\eta_{30} + \eta_{12})(\eta_{21} + \eta_{03})$$

$$\phi_7 = (3\eta_{21} - \eta_{03})(\eta_{30} + \eta_{12})[(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2] + \\ (3\eta_{12} - \eta_{30})(\eta_{21} + \eta_{03})[3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2]$$

Descritores Regionais



Descritores Regionais




Invariante (log)	Original	Metade	Espelhado	Rotacionado 2°	Rotacionado 45°
ϕ_1	6,249	6,226	6,919	6,253	6,318
ϕ_2	17,180	16,954	19,955	17,270	16,803
ϕ_3	22,655	23,531	26,689	22,836	19,724
ϕ_4	22,919	24,236	26,901	23,130	20,437
ϕ_5	45,749	48,349	53,724	46,136	40,525
ϕ_6	31,830	32,916	37,134	32,068	29,315
ϕ_7	45,589	48,343	53,590	46,017	40,170

Descritores Regionais



- O conteúdo da imagem é transformada em coordenadas de características locais que são invariantes à translação, rotação e escala.



Descritores Regionais




Aprendizagem




- Supervisionada
 - Neste tipo de aprendizagem existe um "professor" que avalia a resposta do classificador.
- Não Supervisionada
 - Nesta forma de aprendizagem não existe "professor". O clusterizador tem de descobrir sozinho relações, padrões, regularidades ou categorias nos dados que lhe vão sendo apresentados.

Linear Classifiers



• denotes +1


◦ denotes -1



$$f(\mathbf{x}, \mathbf{w}, b) = \text{sign}(\mathbf{w}\mathbf{x} + b)$$

How would you classify this data?


Linear Classifiers



$$f(\mathbf{x}, \mathbf{w}, b) = \text{sign}(\mathbf{w} \mathbf{x} + b)$$


• denotes +1

○ denotes -1




How would you classify this data?

Linear Classifiers



• denotes +1


○ denotes -1



$$f(\mathbf{x}, \mathbf{w}, b) = \text{sign}(\mathbf{w} \mathbf{x} + b)$$


How would you
classify this data?

Linear Classifiers



• denotes +1

○ denotes -1




$$f(\mathbf{x}, \mathbf{w}, b) = \text{sign}(\mathbf{w} \mathbf{x} + b)$$

Any of these
would be fine..

..but which is
best?


Linear Classifiers



• denotes +1

○ denotes -1


$$f(\mathbf{x}, \mathbf{w}, b) = \text{sign}(\mathbf{w} \mathbf{x} + b)$$



How would you
classify this data?

Misclassified
to +1 class


Classifier Margin



$$f(\mathbf{x}, \mathbf{w}, b) = \text{sign}(\mathbf{w} \mathbf{x} + b)$$


• denotes +1

○ denotes -1



Define the **margin** of a linear classifier as the width that the boundary could be increased by before hitting a datapoint.

Maximum Margin




1. Maximizing the margin is good according to intuition and PAC theory
2. Implies that only support vectors are important; other training examples are ignorable.
3. Empirically it works very very well.

• denotes +1

○ denotes -1

Support Vectors

are those datapoints that the margin pushes up against




linear classifier
with the, um,
maximum margin.

This is the
simplest kind of
SVM (Called an
LSVM)

Linear SVM

Linear SVM Mathematically



What we know:

- $\mathbf{w} \cdot \mathbf{x}^+ + b = +1$
- $\mathbf{w} \cdot \mathbf{x}^- + b = -1$
- $\mathbf{w} \cdot (\mathbf{x}^+ - \mathbf{x}^-) = 2$

$$M = \frac{(\mathbf{x}^+ - \mathbf{x}^-) \cdot \mathbf{w}}{|\mathbf{w}|} = \frac{2}{|\mathbf{w}|}$$

Exemplo SVM



```
D = load('fisheriris');
```

```
Data = D.meas;
```


```
grupo = ismember(species,'setosa');
```

```
[train, test] = crossvalind('holdOut',grupo, 0.5);
```

```
svmStruct = svmtrain(data(train,:),grupo(train);
```

```
classes = svmclassify(svmStruct,data(test,:));
```

Descritor HOG



Descriptor HOG



$(x_0, x_1 \dots x_n)$



SVM



VLP

No VLP

Descriptor HOG






Fig. 2. Main modules of a method using sliding window and HOG descriptor in a multiscale way.

Descriptor HOG



Descriptor HOG




Fig. 11. DET Curve for the multiscale sliding windows approach using HOG features.

Descriptor HOG



Fim!



- Obrigado pela atenção!!
- Dúvidas??

Contato:

pratesufop@gmail.com