

# Segmentação de Imagens

(Processamento Digital de Imagens)

# Fundamentos

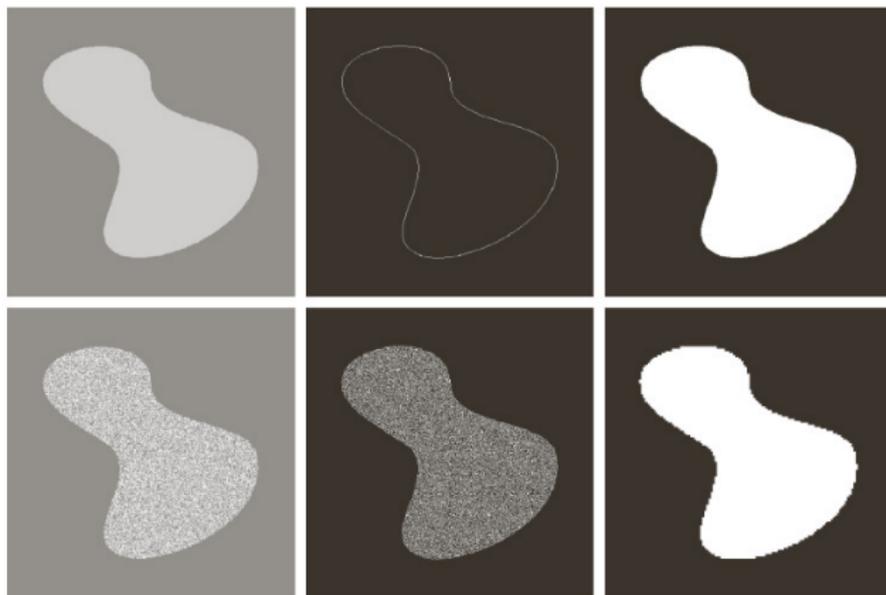
- A segmentação subdivide uma imagem em regiões ou objetos que a compõem;
  - ▶ nível de detalhe depende do problema
  - ▶ segmentação para quando objetos de interesse ao problema são detectados
- A separação dos pixels relativos a cada objeto, ou região, é uma etapa fundamental para o sucesso do processo de análise da imagem;
- Embora o ser humano possa facilmente identificar regiões com as mesmas características ou objetos presentes em uma imagem, para se realizar a mesma tarefa com um computador deve-se implementar algoritmos que analisem as características de cada pixel ou da distribuição da população de pixels.

## Fundamentos

A segmentação é um processo que particiona uma região espacial (imagem)  $R$  em  $n$  subregiões,  $R_1, R_2, \dots, R_n$ , de tal forma que:

- $\bigcup_{i=1}^n R_i = R$ 
  - ▶ cada pixel deve estar em uma região
- $R_i$  é um conjunto conectado,  $i = 1, 2, \dots, n$ 
  - ▶ pixels de uma região devem estar conectados
- $R_i \cap R_j = \emptyset$ , para todo  $i$  e  $j$ ,  $i \neq j$ 
  - ▶ regiões devem estar separadas
- $Q(R_i) = \text{VERDADEIRA}$  para  $i = 1, 2, \dots, n$ 
  - ▶ propriedades que os pixels de uma região devem cumprir (ex.: intensidade)
- $Q(R_i \cup R_j) = \text{FALSA}$  para quaisquer regiões adjacentes  $R_i$  e  $R_j$ 
  - ▶ regiões adjacentes devem ser diferentes na propriedade  $Q$

## Segmentação: exemplo



**FIGURE 10.1** (a) Image containing a region of constant intensity. (b) Image showing the boundary of the inner region, obtained from intensity discontinuities. (c) Result of segmenting the image into two regions. (d) Image containing a textured region. (e) Result of edge computations. Note the large number of small edges that are connected to the original boundary, making it difficult to find a unique boundary using only edge information. (f) Result of segmentation based on region properties.

# Conceito

- O processo de agrupamento dos pixels pertencentes a um mesmo objeto ou região é chamado de segmentação;
- As técnicas de segmentação de imagens podem ser classificadas nas seguintes categorias:
  - ▶ detecção descontinuidades
  - ▶ técnicas de limiar
  - ▶ métodos baseados em região
  - ▶ métodos híbridos

# Métodos Baseados em Descontinuidades

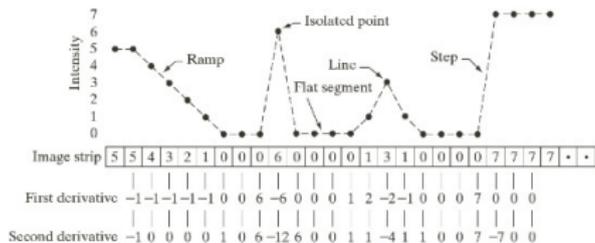
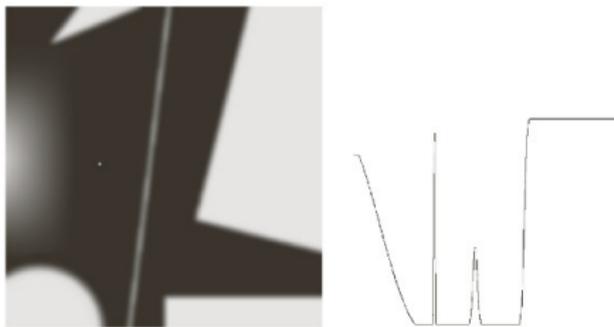
- Métodos baseados em detecção de descontinuidades levam em consideração o fato de que entre duas regiões deve existir uma fronteira;
- Procura-se identificar descontinuidades significativas na imagem que possam representar as bordas da região;
- A operação clássica: gradiente
  - ▶ intensifica variações de tonalidade presentes resultando em uma imagem com pixels mais intensos
  - ▶ permitindo a binarização da imagem e a identificação dos contornos
- Problema na aplicação do gradiente:
  - ▶ obtenção de regiões com bordas abertas devido a ruídos ou uso de iluminação não uniforme no processo de aquisição da imagem

## Gradiente de uma Função Digital

- Derivadas de uma função digital são definidas por diferenças;
- Tais aproximações devem considerar que a derivada deve ser:
  - ▶ zero em áreas de intensidade constante;
  - ▶ zero no início de um degrau ou rampa de intensidade;
  - ▶ diferente de zero ao longo de uma rampa de intensidade.
- A derivada de primeira ordem de uma função  $f(x)$  é obtida expandindo a função  $f(x + \Delta x)$  em uma série de Taylor, assumindo  $\Delta x = 1$  e mantendo apenas os termos lineares:

$$\frac{\delta f}{\delta x} = f'(x) = f(x + 1) - f(x)$$

# Gradiente de uma Função Digital



a b  
c

**FIGURE 10.2** (a) Image. (b) Horizontal intensity profile through the center of the image, including the isolated noise point. (c) Simplified profile (the points are joined by dashes for clarity). The image strip corresponds to the intensity profile, and the numbers in the boxes are the intensity values of the dots shown in the profile. The derivatives were obtained using Eqs. (10.2-1) and (10.2-2).

## Gradiente de uma Função Digital

A melhor estratégia para o cálculo de derivadas é a utilização de filtros espaciais. Para um filtro  $3 \times 3$ :

$$\begin{aligned} R &= w_1 z_1 + w_2 z_2 + \cdots + w_9 z_9 \\ &= \sum_{k=1}^9 w_k z_k \end{aligned}$$

$w_1$	$w_2$	$w_3$
$w_4$	$w_5$	$w_6$
$w_7$	$w_8$	$w_9$

## Detecção de Pontos Isolados

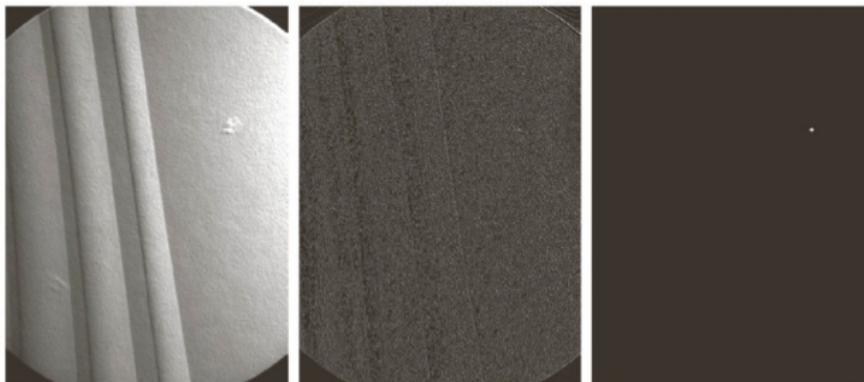
- Derivadas de segunda ordem consistem em boas técnicas para a detecção de pontos isolados;
- Isso implica em utilizar o laplaciano:

$$\begin{aligned}\nabla^2 f(x, y) &= \frac{\delta^2 f}{\delta x^2} + \frac{\delta^2 f}{\delta y^2} \\ &= f(x + 1, y) + f(x - 1, y) + f(x, y + 1) \\ &\quad + f(x, y - 1) - 4f(x, y)\end{aligned}$$

- A máscara utilizada pode ser estendida incluindo os termos diagonais.

# Detecção de Pontos Isolados

1	1	1
1	-8	1
1	1	1



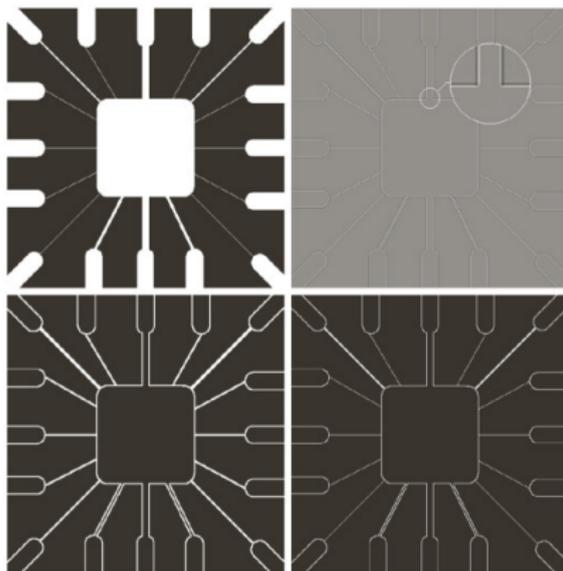
a  
b c d

**FIGURE 10.4**

(a) Point detection (Laplacian) mask. (b) X-ray image of turbine blade with a porosity. The porosity contains a single black pixel. (c) Result of convolving the mask with the image. (d) Result of using Eq. (10.2-8) showing a single point (the point was enlarged to make it easier to see). (Original image courtesy of X-TEK Systems, Ltd.)

## Detecção de Linhas

Para a detecção de linhas, as derivadas de segunda ordem resultem em uma resposta mais forte e produzem linhas mais finas do que as derivadas de primeira ordem.



a b  
c d

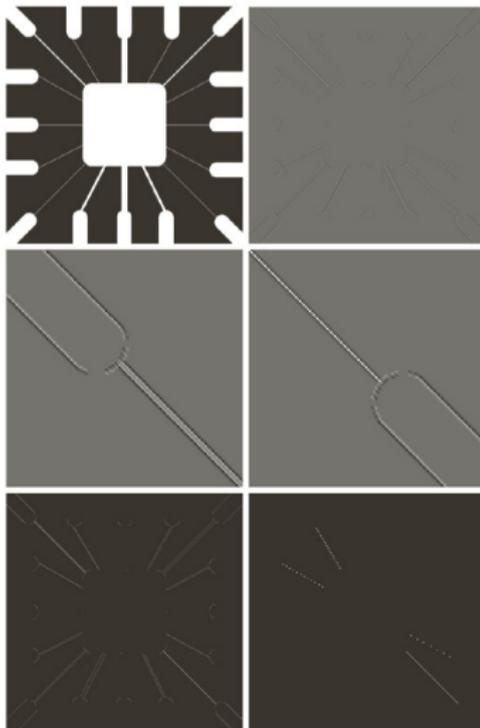
**FIGURE 10.5**  
(a) Original image.  
(b) Laplacian image; the magnified section shows the positive/negative double-line effect characteristic of the Laplacian.  
(c) Absolute value of the Laplacian.  
(d) Positive values of the Laplacian.

## Deteccção de Linhas: Direções Específicas

-1	-1	-1	2	-1	-1	-1	2	-1	-1	-1	2
2	2	2	-1	2	-1	-1	2	-1	-1	2	-1
-1	-1	-1	-1	-1	2	-1	2	-1	2	-1	-1
Horizontal			+45°			Vertical			-45°		

**FIGURE 10.6** Line detection masks. Angles are with respect to the axis system in Fig. 2.18(b).

# Detecção de Linhas: Exemplo



a b  
c d  
e f

**FIGURE 10.7**

(a) Image of a wire-bond template.

(b) Result of processing with the  $+45^\circ$  line detector mask in Fig. 10.6.

(c) Zoomed view of the top left region of (b).

(d) Zoomed view of the bottom right region of (b).

(e) The image in (b) with all negative values set to zero.

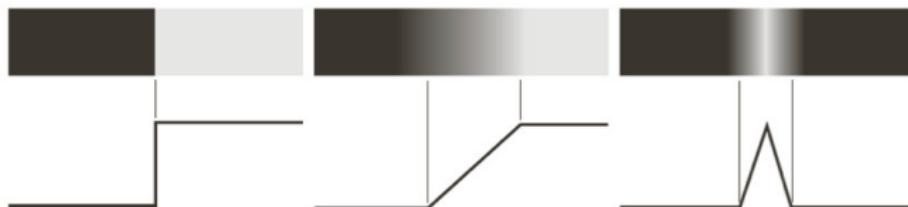
(f) All points (in white) whose values satisfied the condition  $g \geq T$ ,

where  $g$  is the image in (e).

(The points in (f) were enlarged to make them easier to see.)

# Detecção de Bordas

- Método mais usado para segmentar imagens com base em variações abruptas de intensidade;
- Modelos de borda:
  - ▶ degrau
  - ▶ rampa
  - ▶ telhado



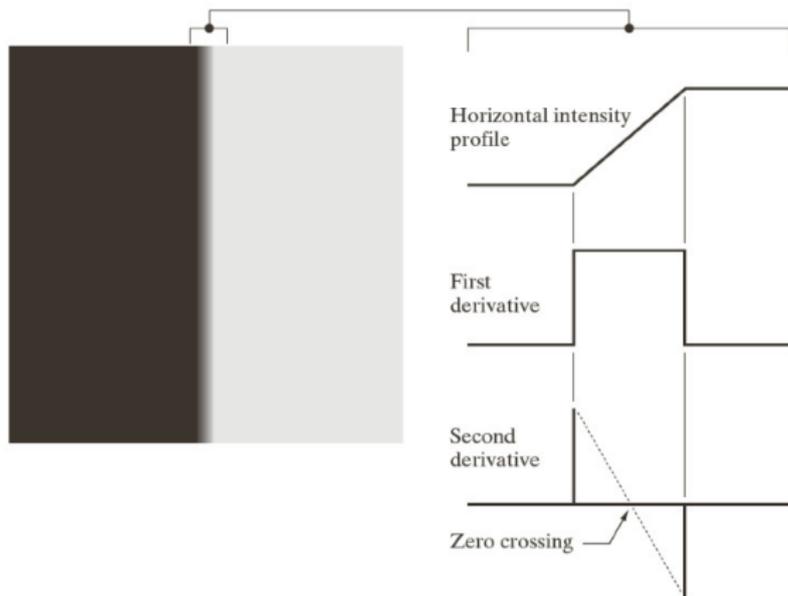
a b c

**FIGURE 10.8**

From left to right, models (ideal representations) of a step, a ramp, and a roof edge, and their corresponding intensity profiles.

# Detecção de Bordas: comportamento da derivada

Considere uma região de borda livre de ruído:



a b

**FIGURE 10.10**

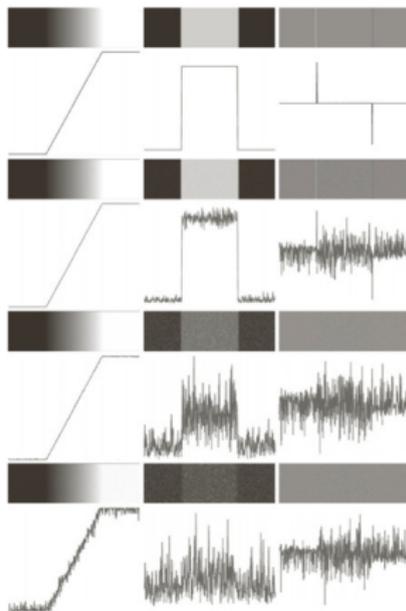
(a) Two regions of constant intensity separated by an ideal vertical ramp edge.

(b) Detail near the edge, showing a horizontal intensity profile, together with its first and second derivatives.

# Detecção de Bordas

- Três passos fundamentais devem ser considerados:
  - ▶ Suavização da imagem para redução de ruído
  - ▶ Detecção dos pontos de borda
  - ▶ Localização da borda

## Detecção de Bordas: interferência do ruído



**FIGURE 10.11** First column: Images and intensity profiles of a ramp edge corrupted by random Gaussian noise of zero mean and standard deviations of 0.0, 0.1, 1.0, and 10.0 intensity levels, respectively. Second column: First-derivative images and intensity profiles. Third column: Second-derivative images and intensity profiles.

## Propriedades do Gradiente

- O gradiente, definido a seguir, é a ferramenta ideal para encontrar a intensidade e a direção da borda:

$$\nabla f = \text{grad}(f) = \begin{bmatrix} g_x \\ g_y \end{bmatrix} = \begin{bmatrix} \frac{\delta f}{\delta x} \\ \frac{\delta f}{\delta y} \end{bmatrix}$$

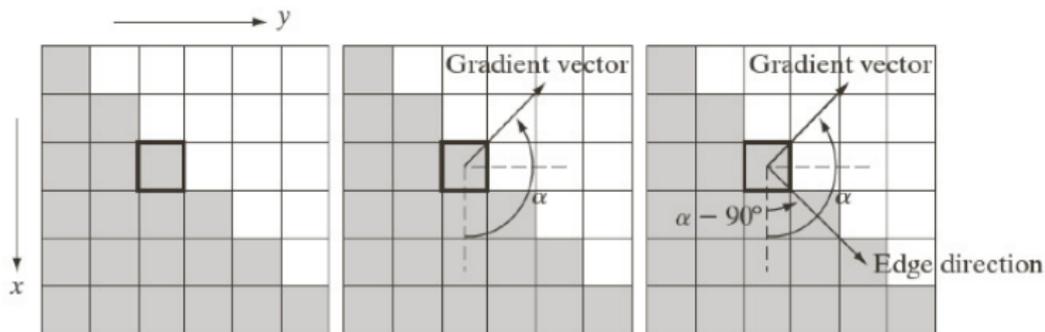
- A magnitude (tamanho) do vetor gradiente:

$$M(x, y) = \text{mag}(\nabla f) = \sqrt{g_x^2 + g_y^2}$$

- A direção do vetor gradiente:

$$\alpha(x, y) = \text{tg}^{-1} \begin{bmatrix} g_y \\ g_x \end{bmatrix}$$

# Propriedades do Gradiente



a b c

**FIGURE 10.12** Using the gradient to determine edge strength and direction at a point. Note that the edge is perpendicular to the direction of the gradient vector at the point where the gradient is computed. Each square in the figure represents one pixel.

# Operadores de Gradiente

a  
b c  
d e  
f g

**FIGURE 10.14**

A  $3 \times 3$  region of an image (the  $z$ 's are intensity values) and various masks used to compute the gradient at the point labeled  $z_5$ .

$z_1$	$z_2$	$z_3$
$z_4$	$z_5$	$z_6$
$z_7$	$z_8$	$z_9$

-1	0	0	-1
0	1	1	0

Roberts

-1	-1	-1	-1	0	1
0	0	0	-1	0	1
1	1	1	-1	0	1

Prewitt

-1	-2	-1	-1	0	1
0	0	0	-2	0	2
1	2	1	-1	0	1

Sobel

0	1	1	-1	-1	0
-1	0	1	-1	0	1
-1	-1	0	0	1	1

Prewitt

0	1	2	-2	-1	0
-1	0	1	-1	0	1
-2	-1	0	0	1	2

Sobel

a b  
c d

**FIGURE 10.15**

Prewitt and Sobel masks for detecting diagonal edges.

## Detecção de Bordas: exemplo usando Sobel



a b  
c d

**FIGURE 10.16**

(a) Original image of size  $834 \times 1114$  pixels, with intensity values scaled to the range  $[0, 1]$ . (b)  $|g_x|$ , the component of the gradient in the  $x$ -direction, obtained using the Sobel mask in Fig. 10.14(f) to filter the image. (c)  $|g_y|$ , obtained using the mask in Fig. 10.14(g). (d) The gradient image,  $|g_x| + |g_y|$ .

# Detecção de Bordas: exemplo usando Sobel

Utilização de suavização antes da detecção.



a b

c d

**FIGURE 10.18**

Same sequence as in Fig. 10.16, but with the original image smoothed using a  $5 \times 5$  averaging filter prior to edge detection.

# Ligação de Bordas

- Detecção de bordas produz conjuntos:
  - ▶ exclusivamente nas bordas
  - ▶ raramente caracterizam completamente as bordas
    - ★ ruído
    - ★ quebras nas bordas
    - ★ iluminação não uniforme
    - ★ descontinuidades espúrias nos valores de intensidade

# Ligação de Bordas

- Abordagem mais simples:
  - ▶ analisar características dos pixels em uma vizinhança pequena sobre cada ponto
  - ▶ pontos semelhantes de acordo com critérios definidos são "ligados"
- Propriedades utilizadas:
  - ▶ magnitude e direção do vetor gradiente
- Desvantagem:
  - ▶ computacionalmente cara
  - ▶ todos os vizinhos de um pixel devem ser examinados

## Ligação de Bordas: exemplo

Utilização de suavização antes da detecção.



a b c  
d e f

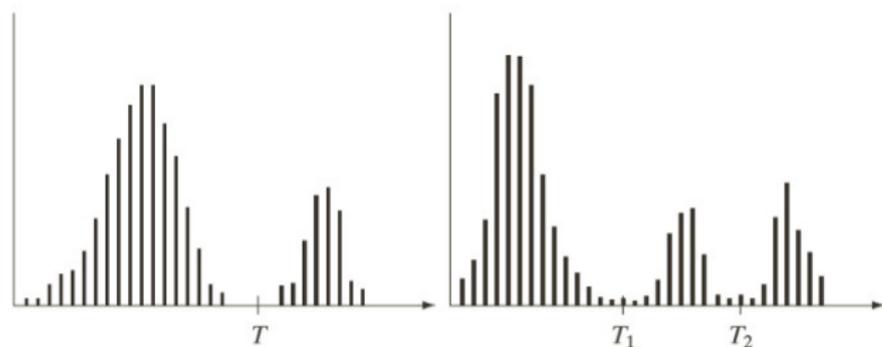
**FIGURE 10.27** (a) A  $534 \times 566$  image of the rear of a vehicle. (b) Gradient magnitude image. (c) Horizontally connected edge pixels. (d) Vertically connected edge pixels. (e) The logical OR of the two preceding images. (f) Final result obtained using morphological thinning. (Original image courtesy of Perceptics Corporation.)

# Limiarização

- Características:
  - ▶ propriedades intuitivas
  - ▶ simplicidade de implementação
  - ▶ velocidade computacional
- As bases da limiarização de intensidade:
  - ▶ Suponha objetos claros em um fundo escuro. Uma maneira de separá-los, seria gerar uma imagem segmentada, baseada na análise do histograma da imagem original, onde:

$$g(x, y) = \begin{cases} 1 & \text{se } f(x, y) > T \\ 0 & \text{se } f(x, y) \leq T \end{cases}$$

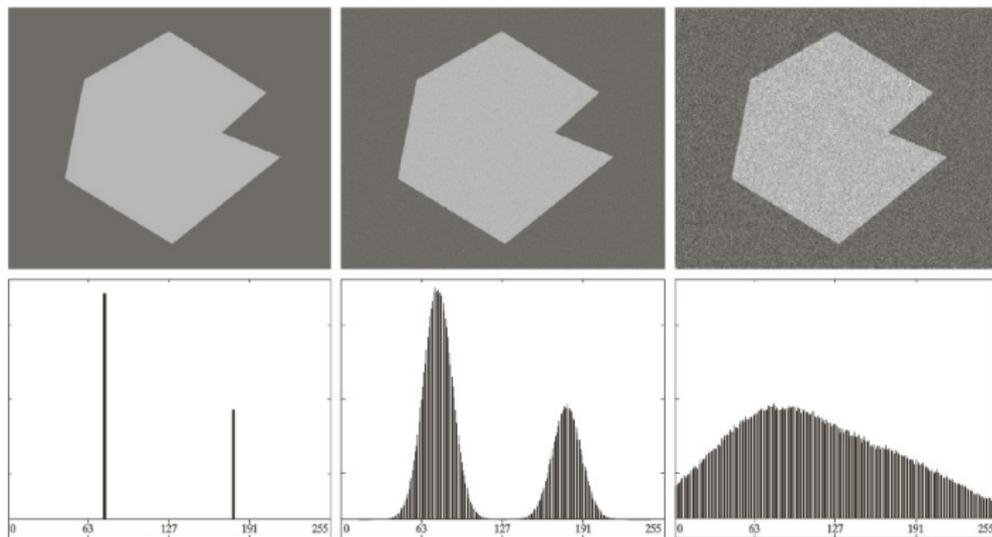
## Limiarização: exemplo



a b

**FIGURE 10.35**  
Intensity histograms that can be partitioned (a) by a single threshold, and (b) by dual thresholds.

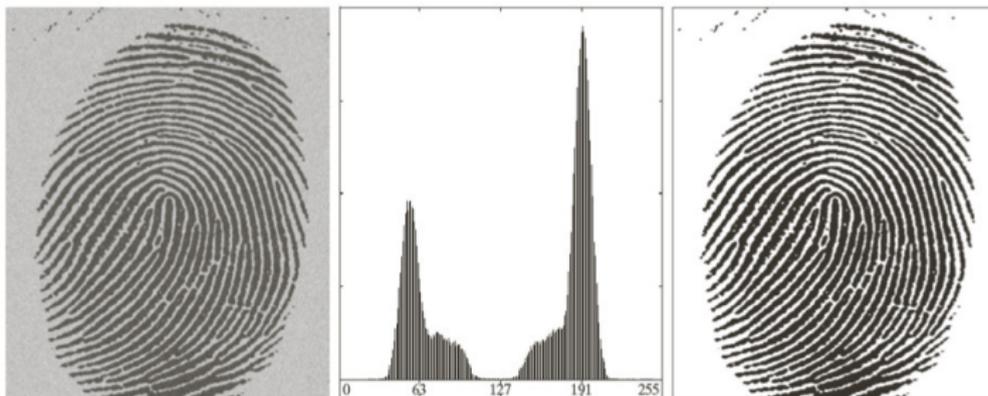
## Limiarização: exemplo



a b c  
d e f

**FIGURE 10.36** (a) Noiseless 8-bit image. (b) Image with additive Gaussian noise of mean 0 and standard deviation of 10 intensity levels. (c) Image with additive Gaussian noise of mean 0 and standard deviation of 50 intensity levels. (d)–(f) Corresponding histograms.

## Limiarização: exemplo



a b c

**FIGURE 10.38** (a) Noisy fingerprint. (b) Histogram. (c) Segmented result using a global threshold (the border was added for clarity). (Original courtesy of the National Institute of Standards and Technology.)

## O Algoritmo K-Means

- Técnica de agrupamento de regiões;
- *Clustering*: conjunto de dados  $\rightarrow$  classes disjuntas;
- K-means: particionar  $n$  objetos em  $K$  agrupamentos;
- Características:
  - ▶ possibilidade de trabalhar com grandes bases de dados
  - ▶ tempo de ordem  $O(n)$
  - ▶ mudança de pertinência durante o processo
  - ▶ sensível à escolha das classes iniciais
  - ▶ **classe**: representada por um centro (ponto)
  - ▶ número de classes iniciais pode impor estrutura errônea

## O Algoritmo K-Means

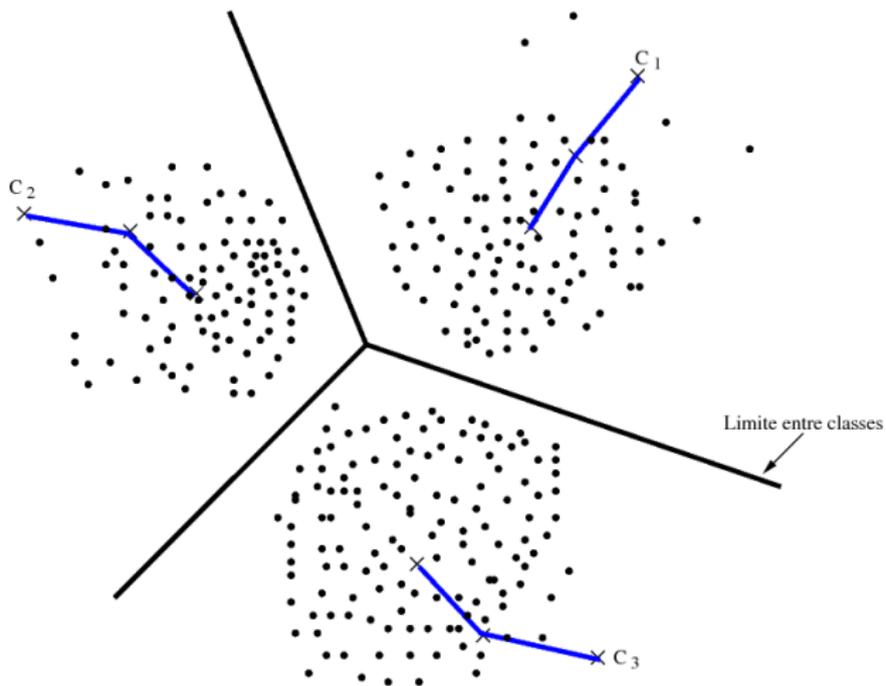
- 1 Inicializar os  $K$  centros ( $w_1, \dots, w_k$ ), que representam as classes, e definir o número  $N$  de iterações;
- 2 Associar cada classe  $C_j$  a um centro  $w_j$ ;
- 3 Assinalar cada dado  $p_l$  como pertencente à classe  $C_j$ , caso  $w_j$  seja o centro mais próximo a esse dado;
- 4 Atualizar cada centro  $w_j$  através da média de todas as amostras assinaladas como pertencentes à cada classe  $C_j$ ;

- 5 Calcular o erro:

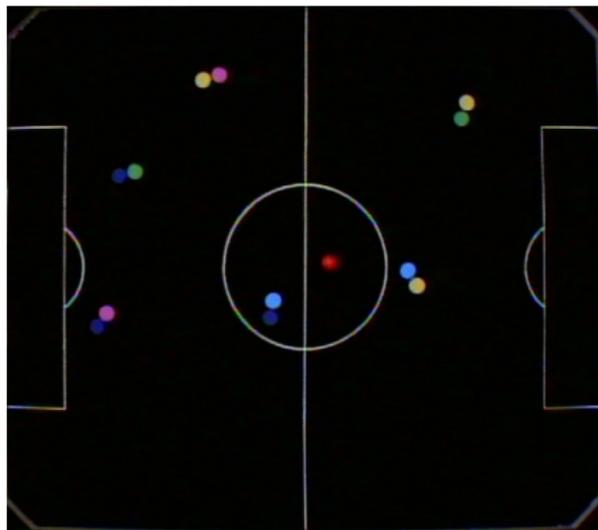
$$E = \sum_{j=1}^k \sum_{p_l \in C_j} |p_l - w_j|^2$$

- 6 Repetir 3, 4 e 5 até que o erro  $E$  não mude significativamente, ou o término das  $N$  iterações.

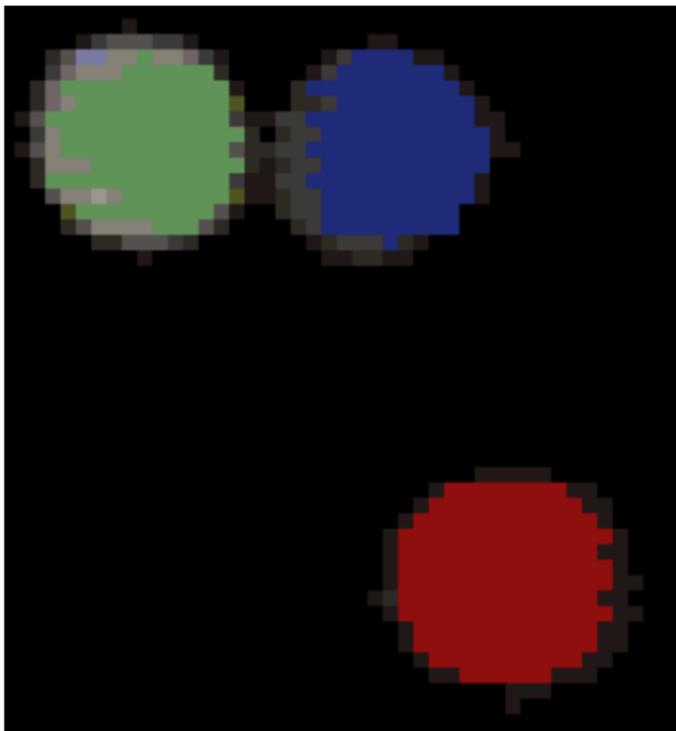
# O Algoritmo K-Means



## ○ Algoritmo K-Means: exemplo



## ○ Algoritmo K-Means: exemplo



# O Algoritmo K-Means: exemplo

