

Capítulo 6

Extração de Características e Reconhecimento de Padrões e Objetos

Capítulo 6

6.1. Segmentação

6.2. Tipos de características

6.3. Descritores de forma

6.4. Reconhecimento de Padrões em Imagens

6.5. Conclusão

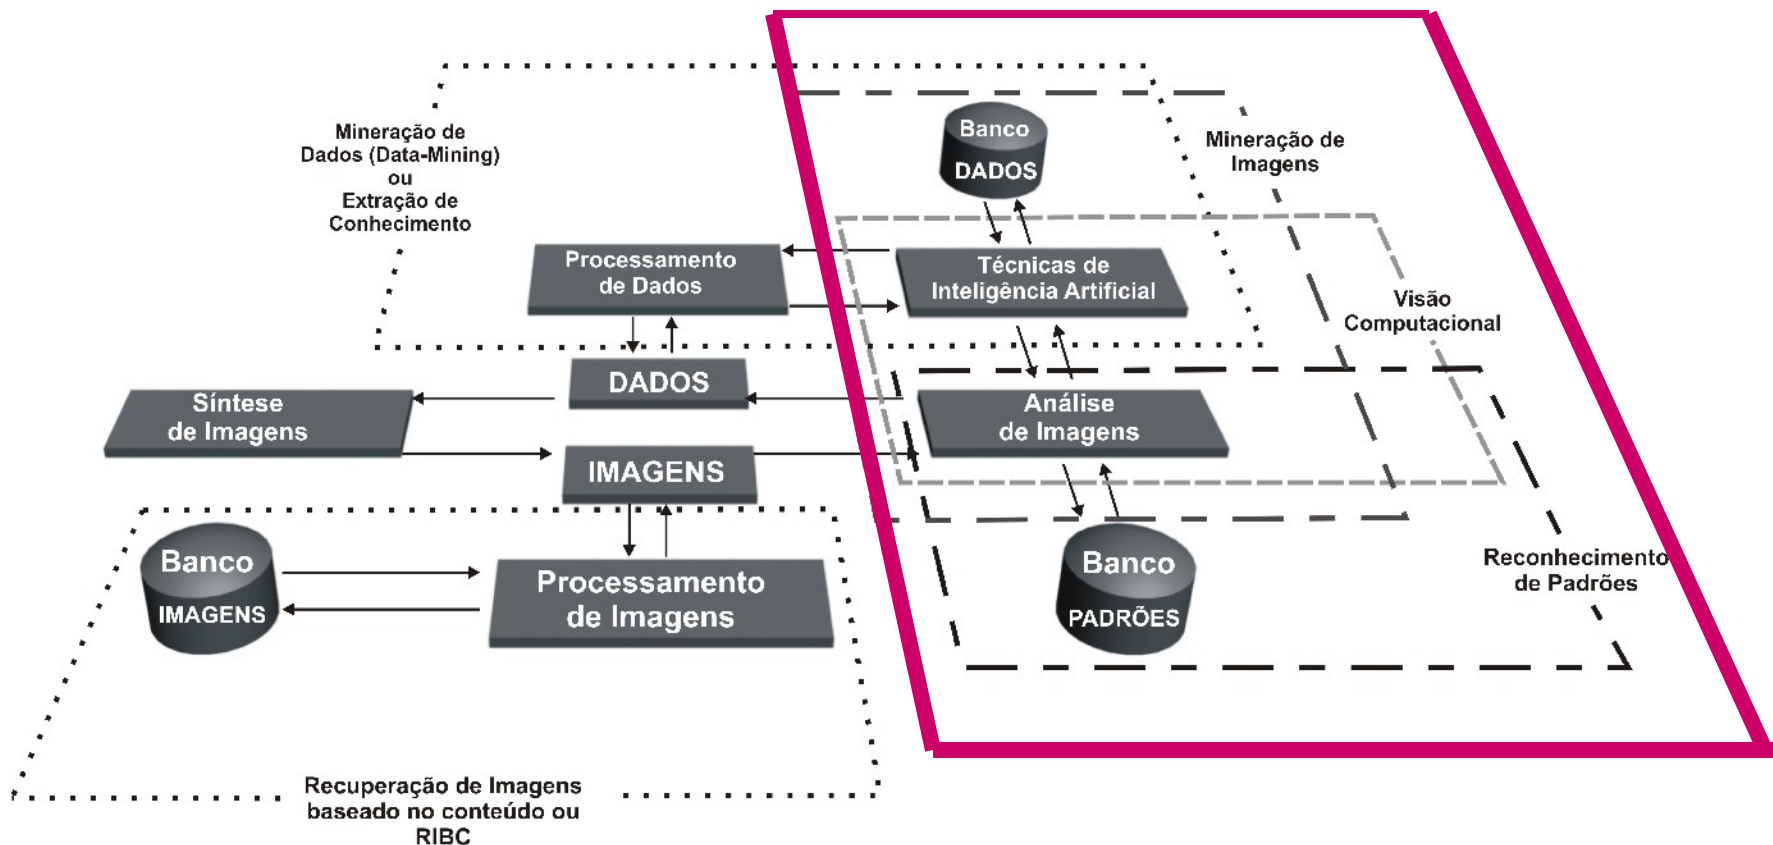


Figura 1.2. Interação entre as diversas áreas, como a mineração em banco de dados, a Visão de Computacional e a Inteligência Artificial.

Padrão, em reconhecimento de imagens, se refere a qualquer elemento que possa ser definido **quantitativamente** mesmo que sujeito a variações.

O reconhecimento pode ser feito por **diferenciação** ou por **classificação** (ou mesmo ambos).

As **classes padrão** que se deseja reconhecer são formadas a partir de **características** que serão extraídas da imagem.

Utilizam-se **descritores** para caracterizar o objeto/padrão. Cada tipo de descritor será mais adequado a **determinado aspecto** como: forma, dimensões, cor, textura, etc.



Figura 6.1 – Estapas de um sistema de reconhecimento de padrões.

6.1. Segmentação

O processo de segmentação consiste em dividir uma imagem em regiões que possuem o mesmo conteúdo no contexto de uma aplicação.

A segmentação pode ser baseada em:

- descontinuidades;
- similaridades dos diferentes aspectos da imagem.


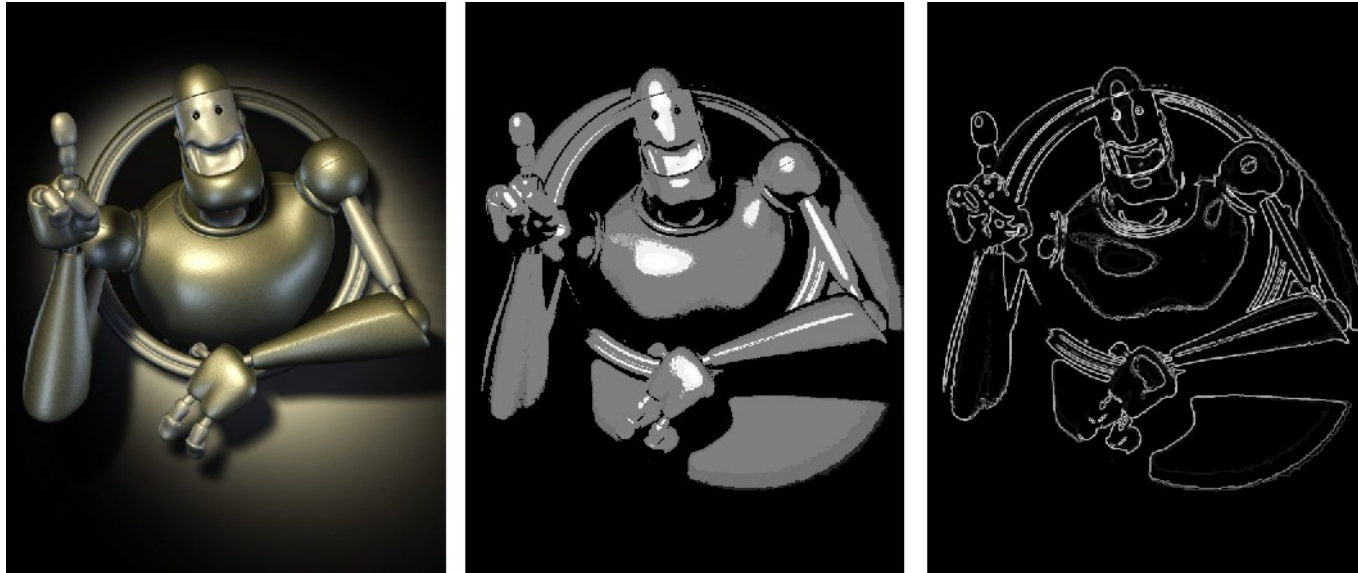


Figura 6.2 – Em imagem coloridas têm-se 3 cores associada a cada *pixel* da imagem.



(a)

(b)

(c)

Figura 6.3 - Imagem original (a) e sua segmentação baseada em semelhança de cores (b) e em fronteiras ou bordas (c).

6.1. Segmentação

6.1.1. Segmentação Baseada em Regiões

6.1.2 - Outras Técnicas de Segmentação

6.1.3. Propriedades do *Pixel*

6.1.4 Rotulação

6.1.1. Segmentação Baseada em Regiões

Premissas:

- (1) a região deve ser homogênea considerando algum fator de tolerância e algumas características predefinidas;
- (2) só se consideram regiões fechadas aquelas delimitadas por fronteiras contínuas que separam seu interior dos outros segmentos;
- (3) as características devem ser adequadas para indicar univocamente a região; e
- (4) o conjunto de todas as regiões deve formar a imagem.

6.1.1.1. Técnicas de segmentação baseadas em crescimento de regiões

- O processo de segmentação se inicia a partir de um *pixel* ou um conjunto de *pixels* (denominado de “*semente*”).
- Para cada semente avalia-se o predicado dos *pixels* vizinhos (ou região).
- A agregação das regiões é feita quando o critério de similaridade ou de decisão do predicado for verdadeiro.

6.1.1.2. Técnicas de segmentação baseadas em divisão e fusão de regiões

- Subdivide uma imagem em quatro blocos e verifica se os *pixels* atendem a algum critério de homogeneidade.
- Os blocos que atenderem ao critério não serão mais divididos.
- O bloco que não atender será subdividido em blocos menores.
- Realiza a junção dos blocos vizinhos homogêneos.

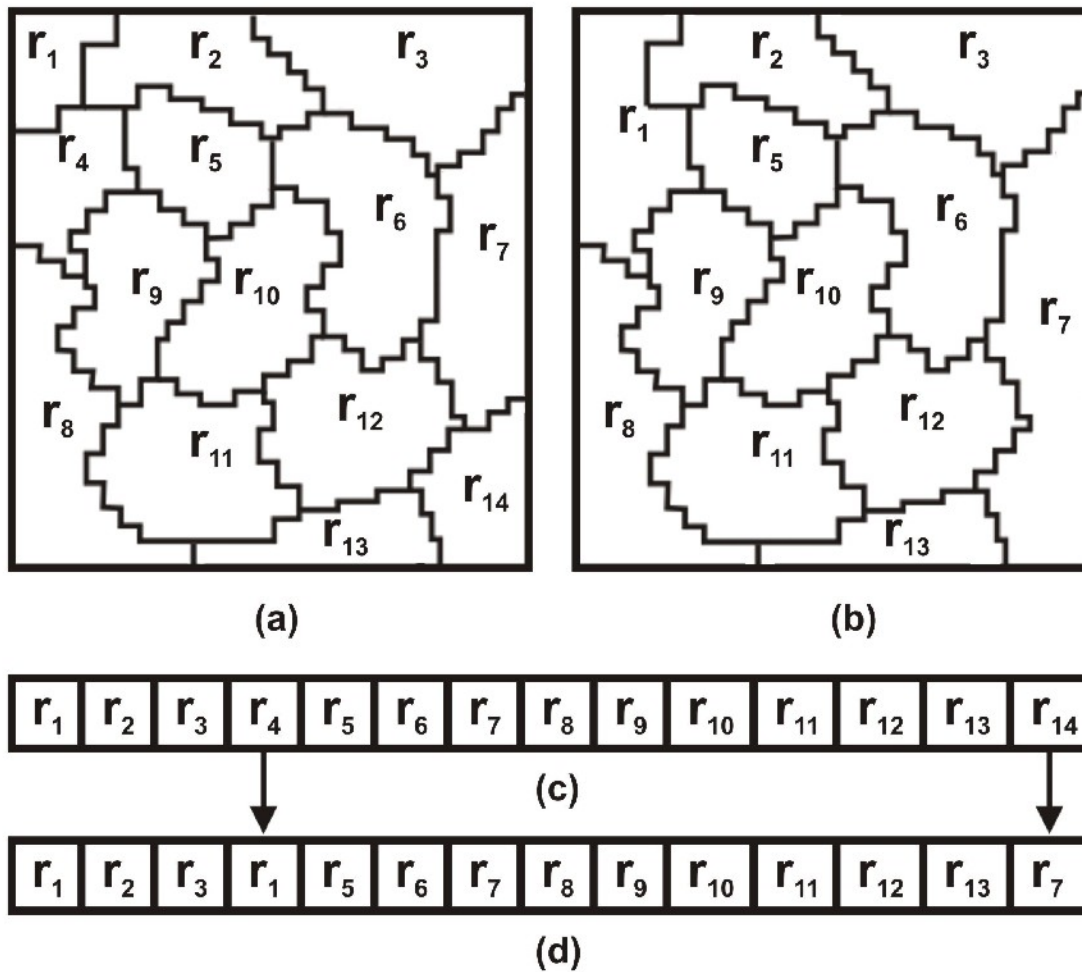


Figura 6.4 - Processo de divisão e fusão de regiões baseado em *quadrees*.

6.1.1.3. Técnicas de segmentação baseadas em “clusterização”

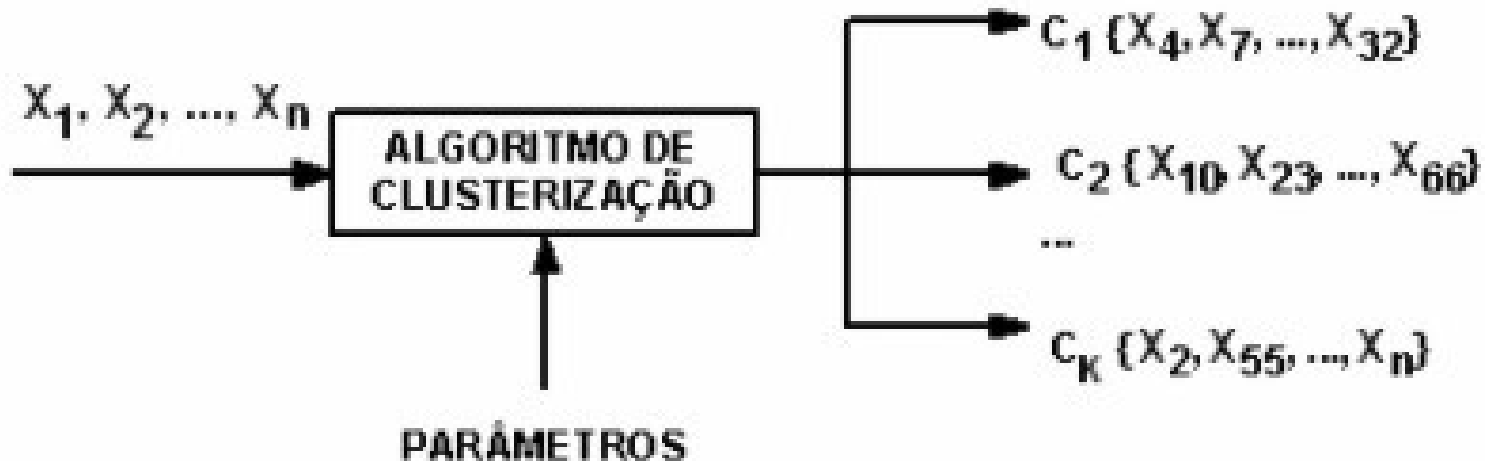


Figura 6.5 - Esquema funcional de um algoritmo de “clusterização” (Nunes, 2006).

6.1.1.3.1. Algoritmo K-Means

- Algoritmo de classificação não-supervisionada.
- O critério a ser minimizado é definido em função da distância dos elementos em relação aos centros dos agrupamentos.
- Usualmente, este critério é a soma residual dos quadrados das distâncias, geralmente a distância Euclidiana.
- Quanto menor for este valor, mais homogêneos serão os objetos dentro de cada grupo e melhor será a partição.

6.1.1.3.1. Algoritmo K-Means

Abaixo é apresentado um algoritmo básico:

- (1) Determinar as posições iniciais dos k centróides dos *clusters*.
- (2) Alocar cada elemento ao cluster do centróide mais próximo.
- (3) Recalcular os centros dos *clusters* a partir dos elementos alocados.
- (4) Repetir os passos de 2 a 4 segundo algum critério de convergência.

6.1.1.4. Segmentação baseada em janelas (*windows*)

- Comum em análises de imagens multiresolução ou texturas.
- O método pode ser generalizado para qualquer número de predicados e técnica de decisão mais complexas quanto aos limiares das regiões.

6.1.2 - Outras Técnicas de Segmentação

Outras técnicas:

- (1) filtragem no domínio espacial;
- (2) filtragem no domínio da frequência;
- (3) transformação para um espaço de medida específico;
- (4) baseadas em Morfologia Matemática; e,
- (5) contornos ativos.

6.1.3. Propriedades do *Pixel*

6.1.3.1. Vizinhança em *Pixel* (Vizinhança-4 e Vizinhança-8)

6.1.3.2. Medidas de Distância

6.1.3.3. Conectividade (Propriedade de um pixel está conectado a outro)

6.1.3.1. Vizinhaça em *Pixel* (Vizinhaça-4 e Vizinhaça-8)





Figura 6.6 – Conceitos de (a) *vizinhaça-4* de p ,
(b) *vizinhaça-D* de p , (c) *vizinhaça-8* de p .

Para criar uma vizinhança onde todos os vizinhos fossem equidistantes seria necessário mudar a grade regular quadrada para uma grade hexagonal.



Vizinhança Hexagonal

Figura 6.7 – Vizinhança de um pixel numa grade hexagonal.

6.1.3.2. Medidas de Distância

Distância *city-block*, *Manhatan* ou quarteirão para $r = 1$ e distância Euclidiana para $r = 2$:

$$D(X_i, X_j) = \left[\sum_{l=1}^n |x_{il} - x_{jl}|^r \right]^{\frac{1}{r}} \quad (6.2)$$

A distância Euclidiana, D para $r=2$, entre p e q :

$$D_e(p, q) = \sqrt{(x - s)^2 + (y - t)^2} = D_2(p, q) \quad (6.3)$$

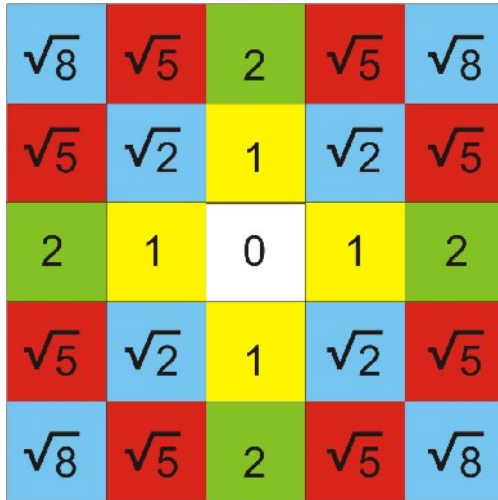


Figura 6.8 – Distância Euclidiana $\leq \sqrt{8}$ do *pixel* central (Nunes, 2006).




Figura 6.9 – Distância D1 (Nunes, 2006).

6.1.3.3. Conectividade

(Propriedade de um pixel está conectado a outro)

Dois *pixels* estão conectados se:

- são adjacentes ($N_4(p)$ ou $N_8(p)$); e,
- seus atributos (níveis de cinza, texturas ou cores) são similares.

Níveis de conectividade:

▪ **Conectividade de 4:** dois *pixels* p e q tem conectividade 4 se seus atributos são iguais e se q está no conjunto $N_4(p)$.

Conectividade de 8: dois *pixels* p e q tem conectividade 8 se seus atributos são iguais e se q está no conjunto $N_8(p)$.

Conectividade de m (mista): dois *pixels* p e q têm conectividade mista se seus atributos são iguais e se: q está no conjunto $N_4(p)$ ou q está no conjunto $N_D(p)$ e o conjunto $N_4(p) \cap N_4(q) =$

Distribuição dos Pixels			N_8			Vizinho de m			N_4		
0	1	1	0	1	1	0	1	1	0	1	1
0	1	0	0	1	0	0	1	0	0	1	0
0	0	1	0	0	1	0	0	1	0	0	1

Figura 6.11 – Exemplo da variação do caminho com o tipo de adjacência.

6.1.4 Rotulação

A rotulação é fundamental para a segmentação e contagem de regiões e objetos.

A cada região ou componente conexo é atribuído um valor único na imagem, usualmente denominado de rótulo (*label*).

6.2. Tipos de características

6.2.1 - Análise de Componentes Principais (PCA)

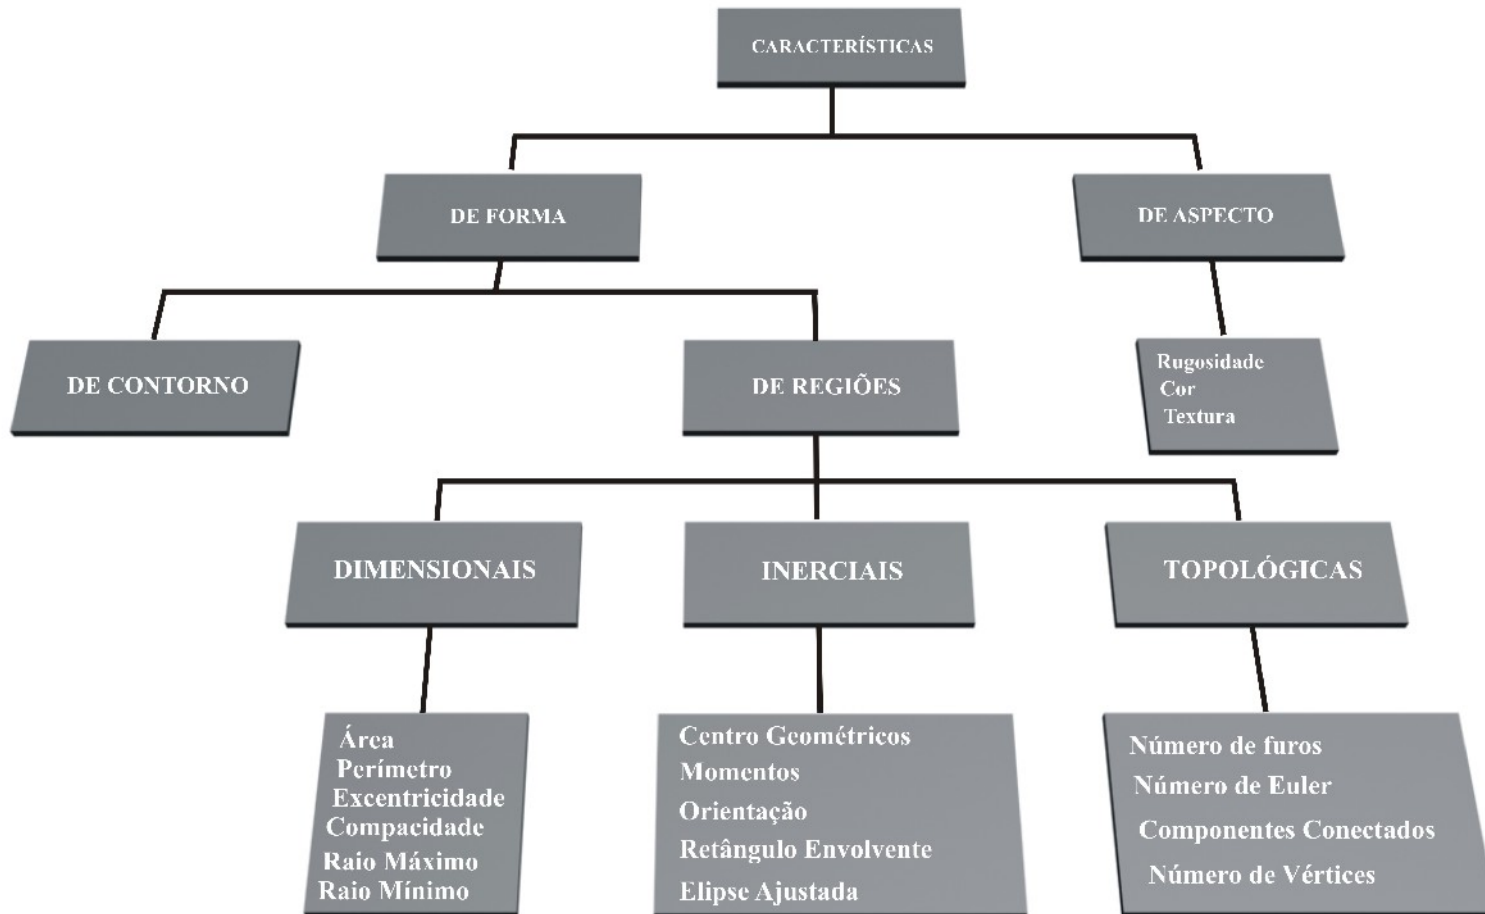


Figura 6.12 - Tipos de características.

6.2.1 - Análise de Componentes Principais (PCA)

- Também chamada de **Transformada Discreta de Karhunen-Loève** (KLT) ou ainda **Transformada Hotelling**.
- A **componente principal** é o arranjo que melhor representa a distribuição dos dados sendo que a **componente secundária** é perpendicular à componente principal.
- É útil quando os vetores de características têm muitas dimensões ou quando uma representação gráfica não é possível.

6.2.1.1. Matriz de covariância

A matriz de covariância para M amostras de vetores em um conjunto qualquer, com vetor médio m_x pode ser calculada de acordo com:

$$C_x = \frac{1}{M} \sum_{i=1}^M x_i x_i^T - m_x m_x^T \quad (6.6)$$

O vetor médio pode ser calculado:

$$m_x = \frac{1}{M} \sum_{i=1}^M x_i \quad (6.7)$$

6.2.1.2. Autoespaços , autovetores e autovalores

Um vetor v é um **autovetor** de uma matriz quadrada M se $M v$ (multiplicação da matriz M pelo vetor v) resulta num múltiplo de v , ou seja, em λv (ou na multiplicação de um escalar pelo vetor).

Nesse caso, λ é o chamado **autovalor** de M associado ao autovetor v .

- Se uma matriz $n \times n$ tem n autovalores linearmente independentes então ela é **diagonalizável**.

Se uma matriz é diagonalizável então ela tem n autovalores linearmente independentes que serão os seus elementos da diagonal principal.

Para diagonalizar uma matriz M :

- 1- Encontrar seus autovetores linearmente independente: v_1, v_2, \dots, v_n .
- 2- Formar uma Matriz P com estes vetores como colunas.
- 3- O produto $P^{-1} M P$ será uma matriz diagonal, com elementos iguais aos autovalores na diagonal principal.

6.2.1.3. Transformada de Hotelling

Transformada de Hotelling:

$$y = A (x - m_x) \quad (6.26)$$

Estabelece um novo sistema de coordenadas cuja origem será o centróide do conjunto de pontos e cujos eixos estarão na direção dos autovetores de C_x .

6.2.1.4. Análise de Componentes Principais para Imagens Coloridas

(1) Gera-se a matriz Σ :

$$\Sigma = cov ([R \ G \ B]) \quad (6.29)$$

(2) Com a matriz de covariância Σ , pode-se, então, calcular seus autovalores e autovetores:

$$[T, aut] = eig (\Sigma) \quad (6.30)$$

(3) Gera-se um novo espaço chamado de $[P1, P2, P3]$.

$$\begin{bmatrix} P_1(i) \\ P_2(i) \\ P_3(i) \end{bmatrix} = \begin{bmatrix} t_{1,1} & t_{1,2} & t_{1,3} \\ t_{2,1} & t_{2,2} & t_{2,3} \\ t_{3,1} & t_{3,2} & t_{3,3} \end{bmatrix} \cdot \begin{bmatrix} R(i) \\ G(i) \\ B(i) \end{bmatrix} \quad (6.31)$$

6.2.1.5. PCA em Reconhecimento de Padrões

Pode-se dizer que uma imagem é um padrão de $h \times w$ características ou um vetor no espaço (hxw) dimensional, o qual é chamado de “espaço de imagens”, representado por I .

Dada uma imagem, pode-se construir sua representação como um vetor através de uma leitura coluna a coluna da imagem, colocando o valor de cada *pixel* da imagem em um vetor coluna x .

6.2.1.6. Transformada de Hotelling e PCA na reconstrução

Outra aplicação importante se relaciona à reconstrução de x , dado y , por: _

$$y = A (x - m_x) \quad (6.32)$$

A PCA é um método estatístico linear que encontra os autovalores e autovetores da matriz de covariância dos dados, e, com esse resultado pode-se realizar a redução dimensional dos dados e analisar os padrões principais de variabilidade presentes.

6.3. Descritores de forma

6.3.1 - Características Dimensionais

6.3.2 - Características Inerciais

6.3.3. Características de Contorno

6.3.4. Características Topológicas

6.3.5. Características de Aspecto

6.3.6. Outras características

6.3.1 - Características Dimensionais

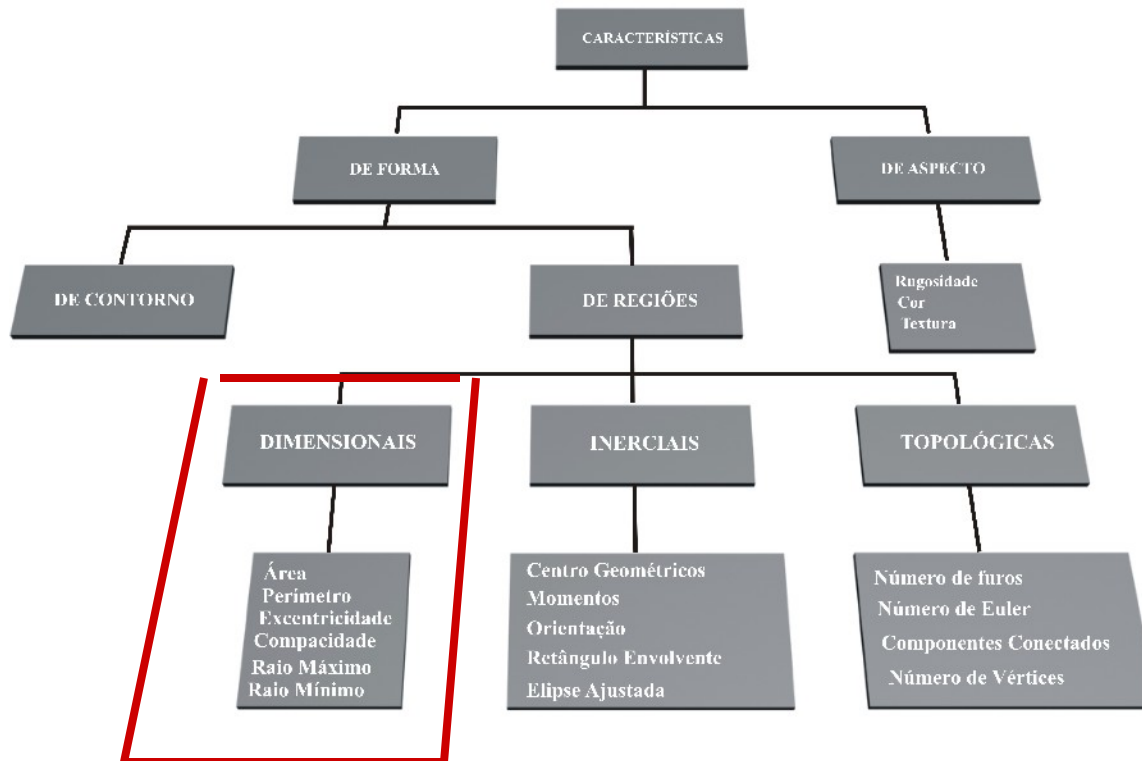


Figura 6.12 - Tipos de características.

6.3.1.1 Área e Retângulos envolventes

Exemplos: área, área do menor retângulo que envolve o objeto, área no menor retângulo que envolve o objeto na mesma direção do sistema de eixos da imagem, área da menor corpo convexo que envolva o objeto, e, a deficiência convexa.

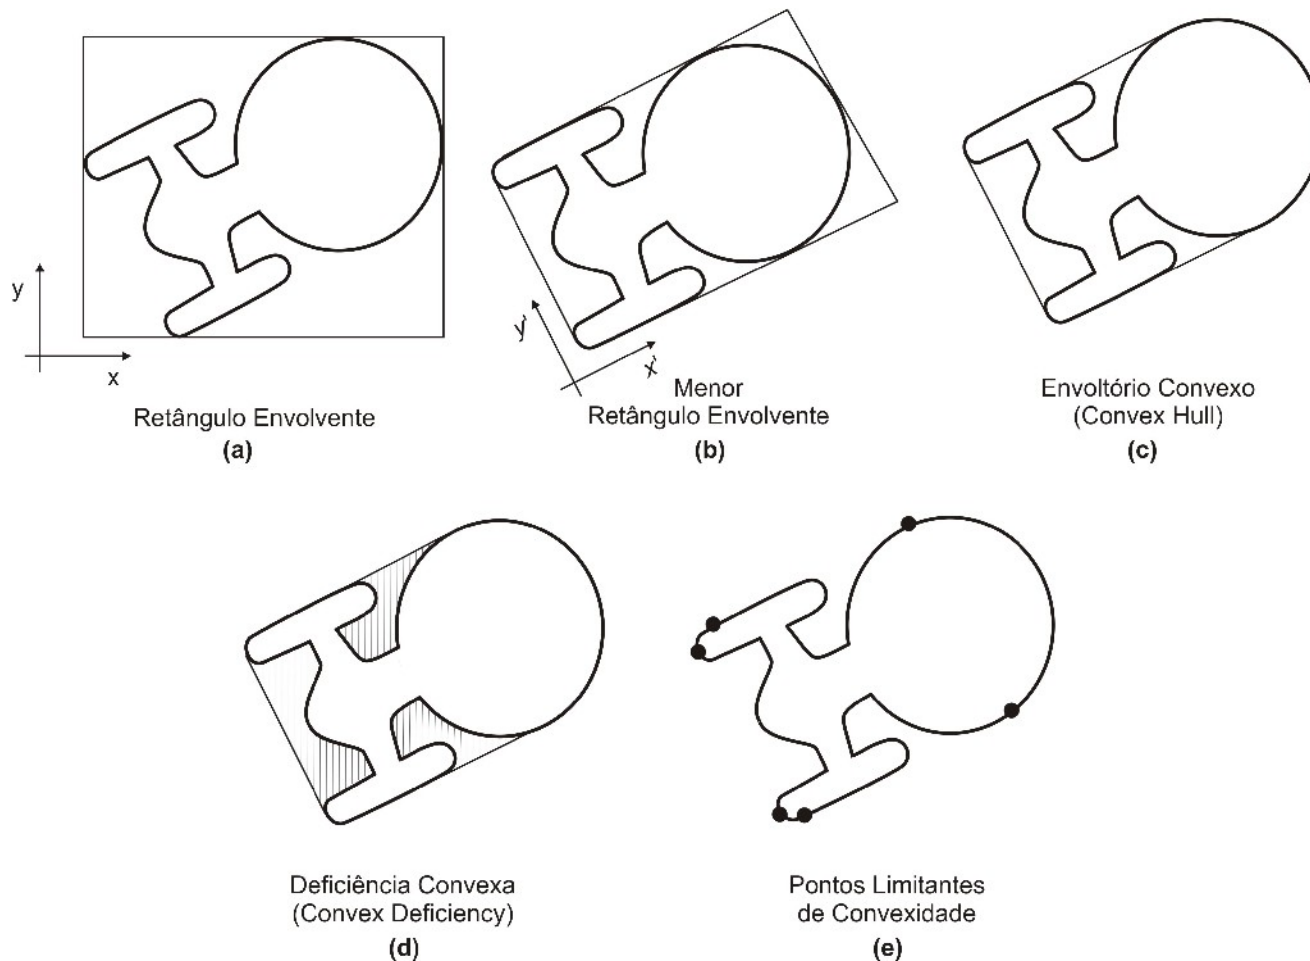


Figura 6.13 - Menor retângulo envolvente (BB), menor retângulo que envolve o objeto na mesma direção do sistema de eixos da imagem (AABB), menor corpo convexo envolvente, e a deficiência convexa.

6.3.1.2 Perímetro, Alongamento e Retangularidade

Perímetro - número de *pixels* conexos que constituem o contorno da região.

Alongamento - relação de lados do menor retângulo que envolve o objeto.

Retangularidade - relação entre a área do objeto e área do menor retângulo que o envolve.

6.3.1.3 Excentricidade, diâmetro, raio máximo e mínimo do objeto

Diâmetro de um objeto - maior distância entre 2 pontos deste objeto.

Excentricidade - relação entre dois pontos extremos do objeto que passem pelo **eixo maior** e **eixo ortogonal**.

Raio máximo e mínimo do objeto - distâncias máxima e mínima, respectivamente, da borda ao centro geométrico.

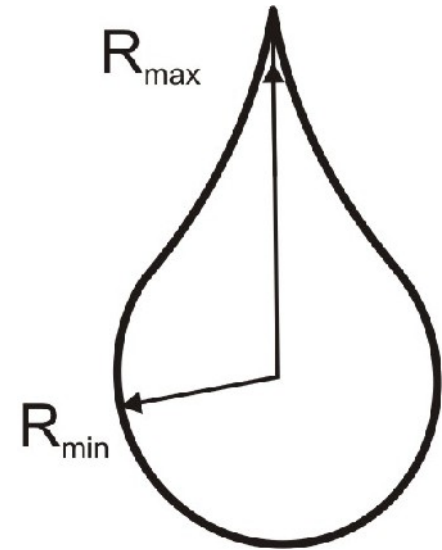


Figura 6.14 - Raios máximo e mínimo de uma imagem representada pelo seu contorno.

6.3.1.4-Coeficiente de compacidade e fator de forma

$$\gamma = \frac{P^r}{\varepsilon \pi A} \quad (6.34)$$

6.3.1.5 - *Bit quads*

$$A = \frac{1}{\varepsilon} nQ_1 + \frac{1}{\Upsilon} nQ_r + \frac{V}{\Lambda} nQ_r + nQ_\varepsilon + \frac{\Upsilon}{\varepsilon} nQ_D \quad (6.35)$$

$$P = nQ_r + \frac{1}{\sqrt{\Upsilon}} [nQ_1 + nQ_r + \Upsilon nQ_D] \quad (6.36)$$

$$\varepsilon = \frac{1}{\varepsilon} [nQ_1 - nQ_r + \Upsilon nQ_D] \quad (6.37)$$




Figura 6.15 - Forma visual dos *Bitquads*.

6.3.2 - Características Inerciais

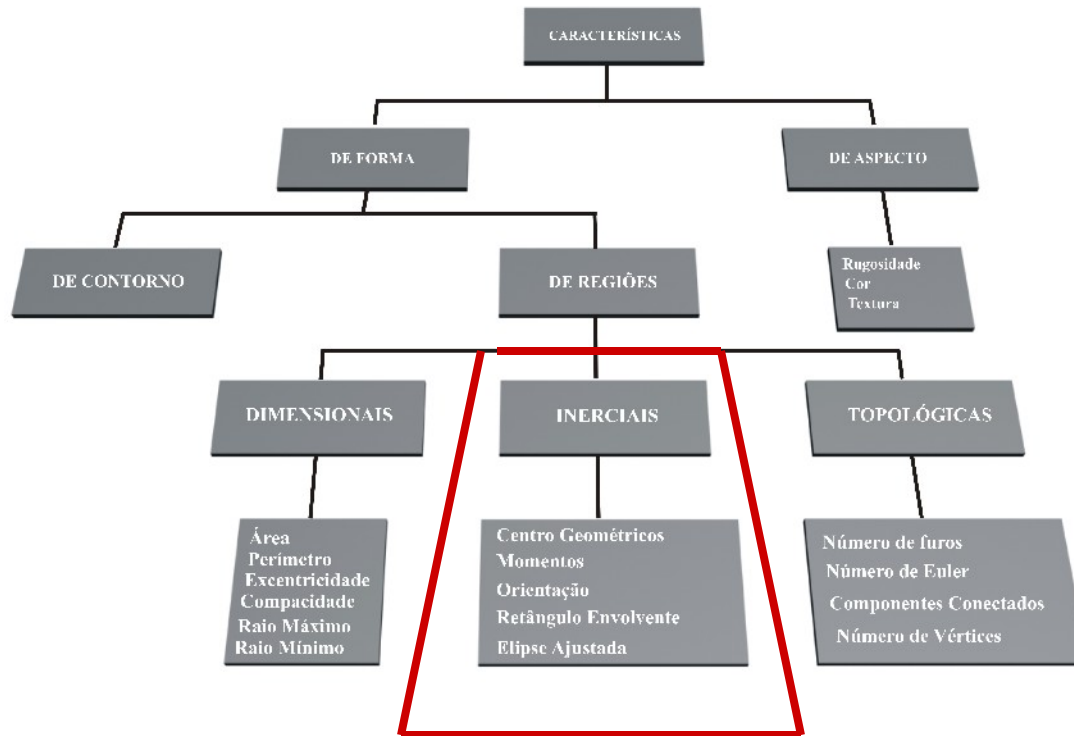


Figura 6.12 - Tipos de características.

6.3.2.1 Momentos Geométricos

Momentos invariantes de ordem $(p + q)$ de objetos contínuos em uma imagem binarizada:

$$m_{pq} = \sum_{k=1}^n B(i_k, j_k) (i_k)^p (j_k)^q \quad p, q = 0, 1, 2, \dots \quad (6.39)$$

Área:

$$m_{00} = \sum_m \sum_n B(m, n) \quad (6.41)$$

Centróide:

$$i_0 = \sum_{k=1}^n B(i_k, j_k) i_k / \sum_{k=1}^n B(i_k, j_k) = m_{10} / m_{00} \quad (6.42)$$

$$j_0 = \sum_{k=1}^n B(i_k, j_k) j_k / \sum_{k=1}^n B(i_k, j_k) = m_{01} / m_{00}$$

Momentos centrais :

$$\mu_{pq} = \sum_{k=1}^n B(i_k, j_k) (i_k - i_0)^p (j_k - j_0)^q B(i_k, j_k) \quad (6.43)$$

$$\mu_{0,0} = m_{0,0} \quad (\text{área})$$

$$\mu_{0,1} = \mu_{1,0} = 0 \quad (\text{momentos estáticos})$$

$$\mu_{0,2} = m_{0,2} - i_0 m_{0,1} \quad (\text{momentos de inércia})$$

$$\mu_{2,0} = m_{2,0} - i_0 m_{1,0} \quad (\text{momentos de inércia})$$

$$\mu_{1,1} = m_{1,1} - j_0 m_{1,0} \quad (\text{produto de inércia})$$

Momentos geométricos invariantes de Hu (1962):

$$\phi_1 = \eta_{2,0} + \eta_{0,2} \quad (6.45)$$

$$\phi_2 = (\eta_{2,0} - \eta_{0,2})^2 + 4\eta_{1,1}^2 \quad (6.46)$$

$$\phi_3 = (\eta_{3,0} - 3\eta_{1,2})^2 + (3\eta_{2,1} - \eta_{0,3})^2 \quad (6.47)$$

$$\phi_4 = (\eta_{3,0} + \eta_{1,2})^2 + (\eta_{2,1} + \eta_{0,3})^2 \quad (6.48)$$

$$\begin{aligned} \phi_5 = & (\eta_{3,0} - 3\eta_{1,2})(\eta_{3,0} + \eta_{1,2})[(\eta_{3,0} + \eta_{1,2})^2 - 3(\eta_{2,1} + \eta_{0,3})^2] + \\ & (3\eta_{2,1} - \eta_{0,3})(\eta_{2,1} + \eta_{0,3}) [3(\eta_{3,0} + \eta_{1,2})^2 - (\eta_{2,1} + \eta_{0,3})^2] \end{aligned} \quad (6.49)$$

Momentos geométricos invariantes de Hu (1962):

$$\phi_6 = (\eta_{2,0} - \eta_{0,2})[(\eta_{3,0} + \eta_{1,2})^2 - (\eta_{2,1} + \eta_{0,3})^2] + 4\eta_{1,1}(\eta_{3,0} + \eta_{1,2})(\eta_{2,1} + \eta_{0,3}) \quad (6.50)$$

$$\phi_7 = (3\eta_{2,1} - \eta_{0,3})(\eta_{3,0} + \eta_{1,2})[(\eta_{3,0} + \eta_{1,2})^2 - 3(\eta_{2,1} + \eta_{0,3})^2] - (\eta_{3,0} - 3\eta_{1,2})(\eta_{2,1} + \eta_{0,3})[3(\eta_{3,0} + \eta_{1,2})^2 - (\eta_{2,1} + \eta_{0,3})^2] \quad (6.51)$$

θ - orientação dos eixos principais:

$$\tan 2\theta = 2\mu_{1,1} / (\mu_{2,0} - \mu_{0,2}) \quad (6.52)$$

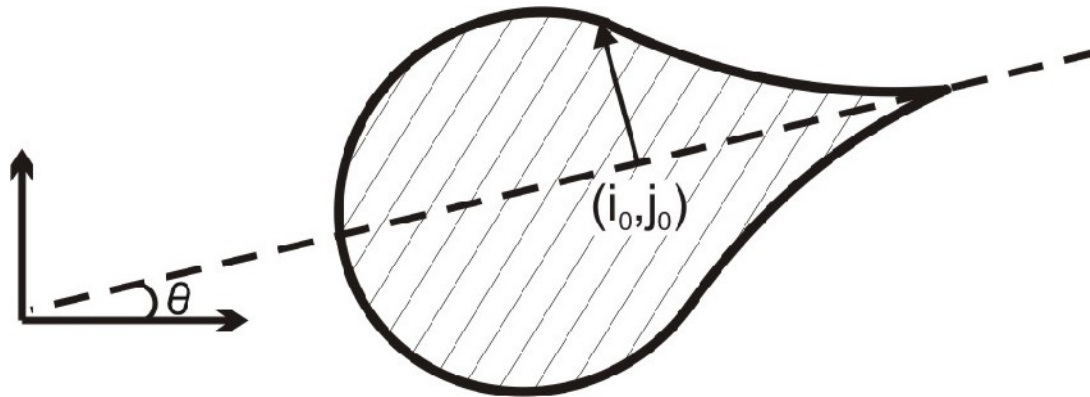


Figura 6.17 – Orientação.

6.3.2.2 Retângulos e Elipses ajustados




Figura 6.18 - Retângulo ajustado.




Figura 6.19 - Elipse ajustada.

6.3.3. Características de Contorno

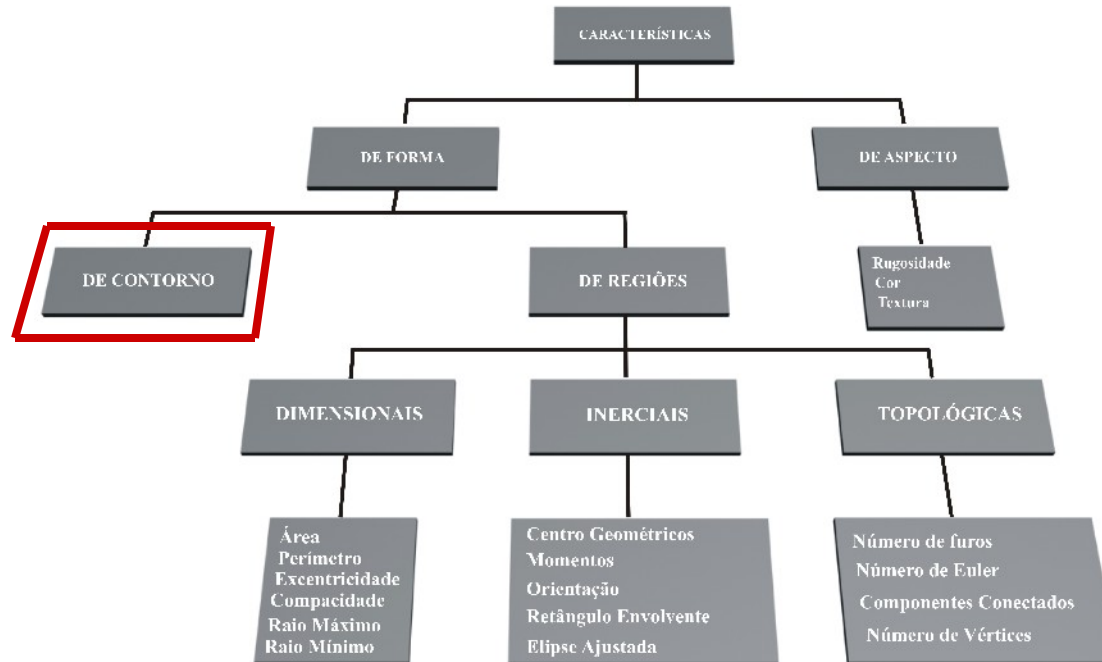



Figura 6.12 - Tipos de características.



(a)

(b)

Figura 6.20. Exemplo de aplicação do filtro de gradiente (b) para acentuar o contorno em uma imagem de tomografia (a). Neste exemplo foram realizados procedimentos para ligação de bordas.

6.3.3.1. Código da Cadeia




Figura 6.21. – Codificação vizinhança-4 de p , $N_4(p)$ (a) e vizinhança-8 de p , $N_8(p)$ o (b) para o código da cadeia.

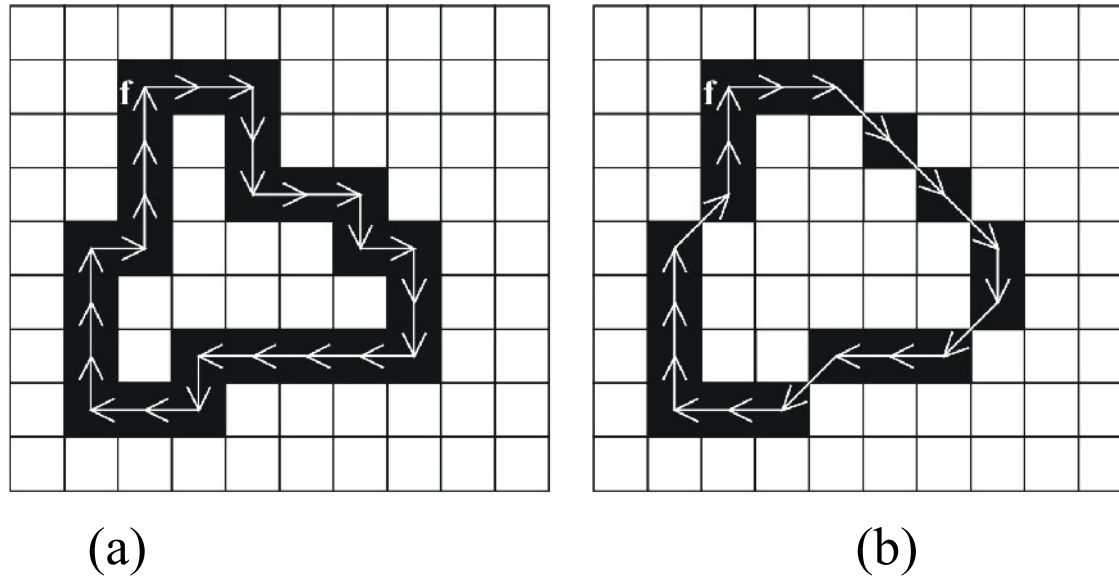


Figura 6.22 . Segmentaões para o código da Cadeia: (a) código para vizinhança-4; (b) código para vizinhança-8 de p .

$$N_4(p) \text{ é CC} = (1,1,0,0,1,1,0,1,0,0,3,3,3,3,0,3,3,2,2,2,1,2,2,2).$$

$$N_8(p) \text{ é CC} = (2,2,1,1,1,0,7,6,6,7,6,6,4,4,4,3,4,4).$$

6.3.3.2. Assinaturas ou Gráficos $r(\theta)$




Figura 6.24 – Quatro objetos e suas assinaturas, ou gráficos $r(\theta)$.

6.3.3.3. Transformada de Hough

Transformar a imagem do espaço digital (x,y) para uma representação na forma dos parâmetros descritos pela curva que se deseja encontrar na imagem




Figura 6.25. Etapas da aplicação da transformada de Hough para qualquer forma geométrica.

Retas:

$$y = mx + g \quad (6.58)$$

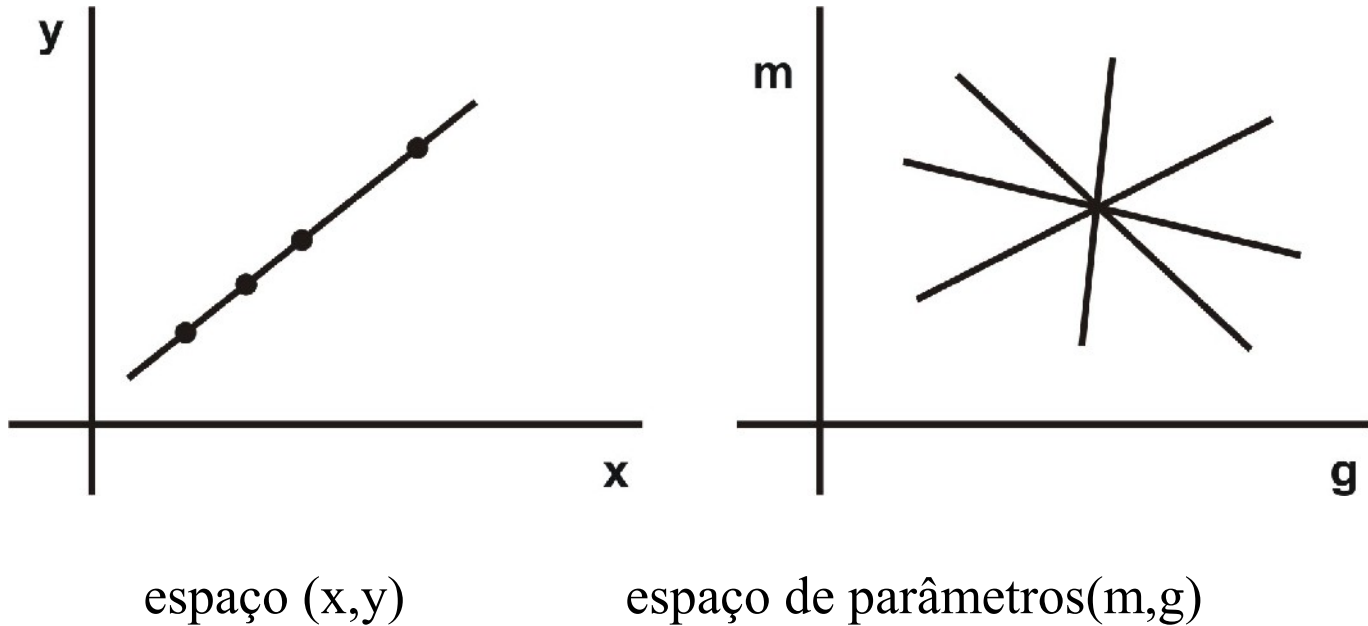


Figura 6.26 – Cada ponto no espaço da imagem transforma-se em uma reta no espaço de parâmetro: $g = -mx + y$.

Retas – forma polar:

$$\rho = x \cos \theta + y \sin \theta \quad (6.59)$$




Figura 6.28 - Cada ponto $P(x,y)$ no espaço da imagem, corresponde a uma senóide $S(\rho,\theta)$ no espaço de parâmetros.

6.3.3.3.1. Discretização da matriz acumuladora

- Para determinar o tamanho e os limites da matriz acumuladora, devem-se observar todos os parâmetros que compõem o espaço dos parâmetros.
- No caso das retas, é necessário ter a informação dos limites angulares de θ e dos valores limite de ρ .
- Para uma imagem descrita entre os limites $(0,0)$ e (N_1, N_2) , o parâmetro ρ se apresenta em um intervalo de $-\sqrt{N_1^2 + N_2^2}$ a $\sqrt{N_1^2 + N_2^2}$.

6.3.3.3.2. Detecção de formas cônicas

As cônicas (Figura 3.3 do Volume 1) são curvas obtidas pela interseção de um plano com um cone circular.

6.3.3.3.3. Transformada de Hough para formas circulares

Formas circulares:

$$x = x_0 + \rho \cos \theta$$

$$y = y_0 + \rho \sin \theta$$

(6.67)




Figura 6.32 – Representação gráfica da transformada de Hough para círculos.

6.3.3.3.4. Transformada de Hough para elipses

Elipses:

$$\rho^2 = \frac{s^2 t^2}{s^2 \sin^2 \tau + t^2 \cos^2 \tau}$$

(6.70)




Figura 6.34 - Elipse inclinada com seus cinco parâmetros e coordenadas inicial e final de seu maior eixo.

6.3.3.3.5. Transformada de Hough para parábolas

Parábolas:

$$\rho = \frac{2d}{1 - \cos \beta}$$

(6.84)




Figura 6.38 - Parábola rotacionada.

6.3.3.4. Aproximação poligonal

O objetivo é capturar a essência da forma com o menor número possível de segmentos poligonais.

A fronteira digital pode ser aproximada com mais ou menos precisão por poligonais




Figura 6.40- Borda original e 3 etapas do algoritmo 2 que a aproxima com linhas retas. O ponto mais distante passa a ser o limite de cada subdivisão da poligonal.

6.3.4. Características

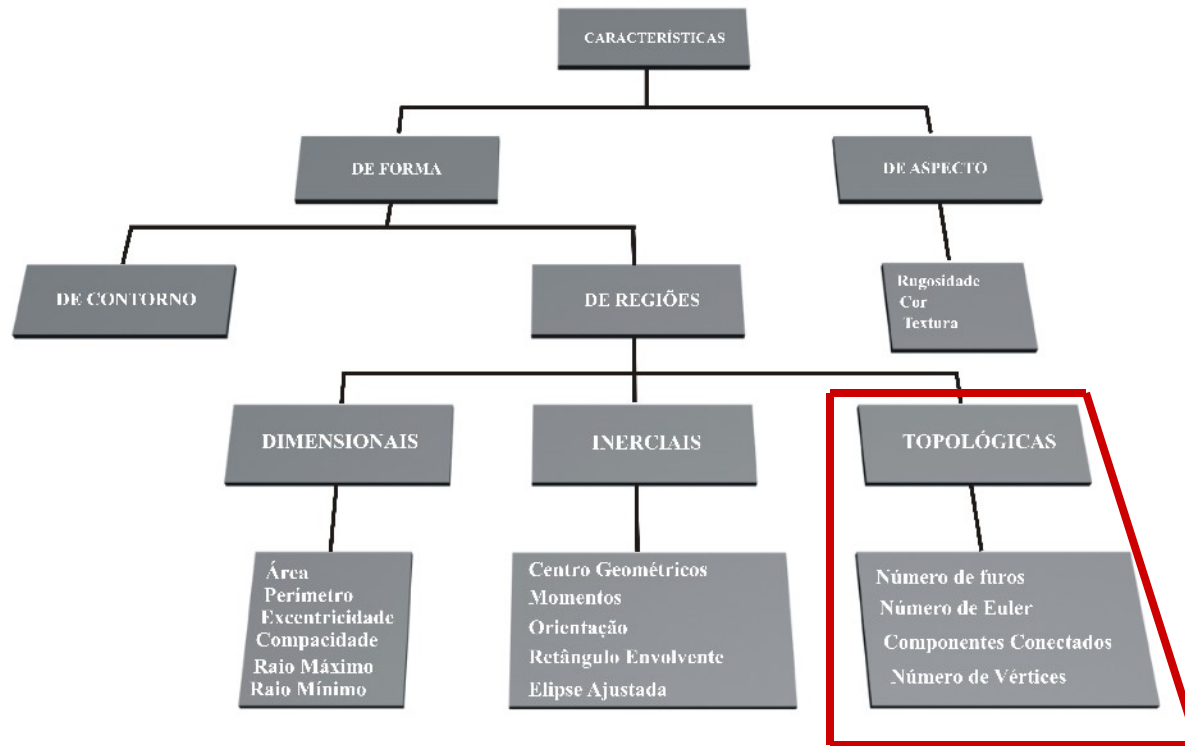


Figura 6.12 - Tipos de características.

Principais descritores topológicos:

- (1) Número de componentes conectados.
- (2) Número de furos.
- (3) Número de Euler.



Figura 6.41 - Distorção “folha de borracha”.




Figura 6.42 – Regiões com número de Euler igual a 0 a -1, respectivamente.

6.3.5. Características de Aspecto

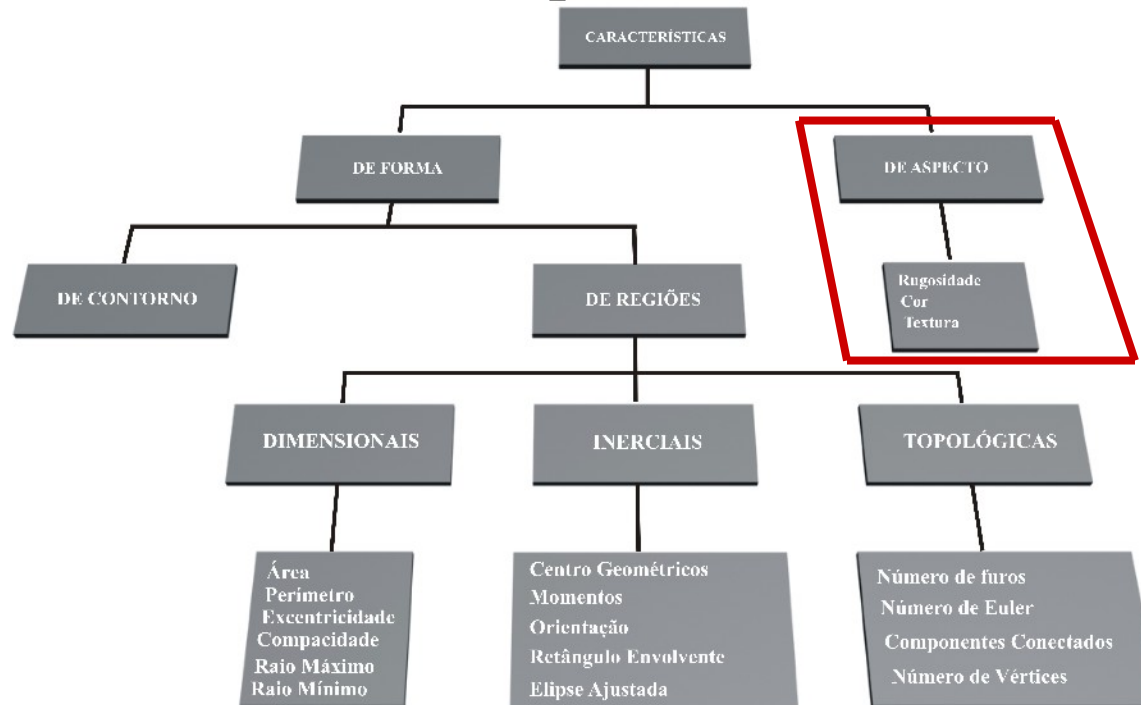



Figura 6.12 - Tipos de características.

6.3.6. Outras características

6.3.6.1. Codificação de Corrida

6.3.6.2. Histograma de Projeção

6.3.6.1. Codificação de Corrida



12(0), 4(1), 6(0), 2(1), 8(0), 1(1), 1(0), 5(1),
2(0), 2(1), 1(0), 1(1), 1(0), 2(1), 3(0), 1(1),
4(0), 2(1), 3(0), 1(1), 1(1), 1(0), 6(1),
2(0), 3(1), 3(0), 1(1), 9(0), 1(1), 2(0)

Figura 6.43 – Codificação de Corrida.

6.3.6.2. Histograma de Projeção




Figura 6.44 - Imagem binária e suas projeções horizontais e verticais.




Figura 6.45 - Imagem binária e sua projeção diagonal.

6.4. Reconhecimento de Padrões em Imagens

6.4.1. Reconhecimento de Padrões

6.4.2. Classificação Supervisionada

6.4.3. Classificação Não Supervisionada

6.4.4. Redes Neurais Artificiais

6.4.5. Lógica Fuzzy

6.4.1. Reconhecimento de Padrões

- **Abordagem estatística**
- **Abordagem sintática**
- **Abordagem neuronal**
- **Abordagem nebulosa**

6.4.2. Classificação Supervisionada

Etapas:

- Escolha de um conjunto de treinamento.
- Escolha dos parâmetros relevantes a serem medidos.
- Obtenção da função discriminante, que pode ser obtida por método não estatístico (distribuição livre) ou por método estatístico.
- Eliminação dos parâmetros não relevantes.
- Testes com objetos fora do conjunto de treinamento.

6.4.2.1. Classificação por Distribuição Livre

Exemplos:

- funções discriminantes;
- vizinhança mais próxima;
- árvore de decisão.

Funções discriminantes:




Figura 6.46 (a) - Divisão do espaço de características (problema de três classes) (Duda e Hart, 1973).

Vizinhança mais próxima:

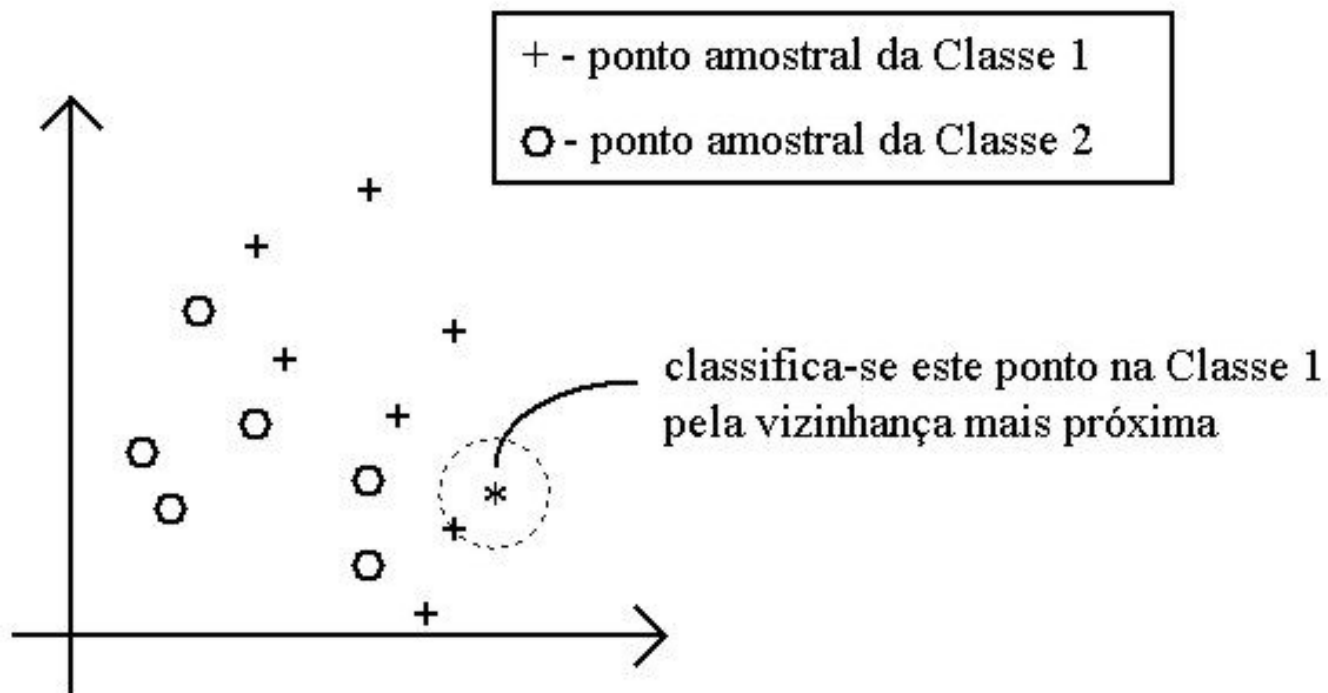


Figura 6.47 - Uma CVMP para duas classes em um espaço amostral [CHEN73].

Árvore de decisão:

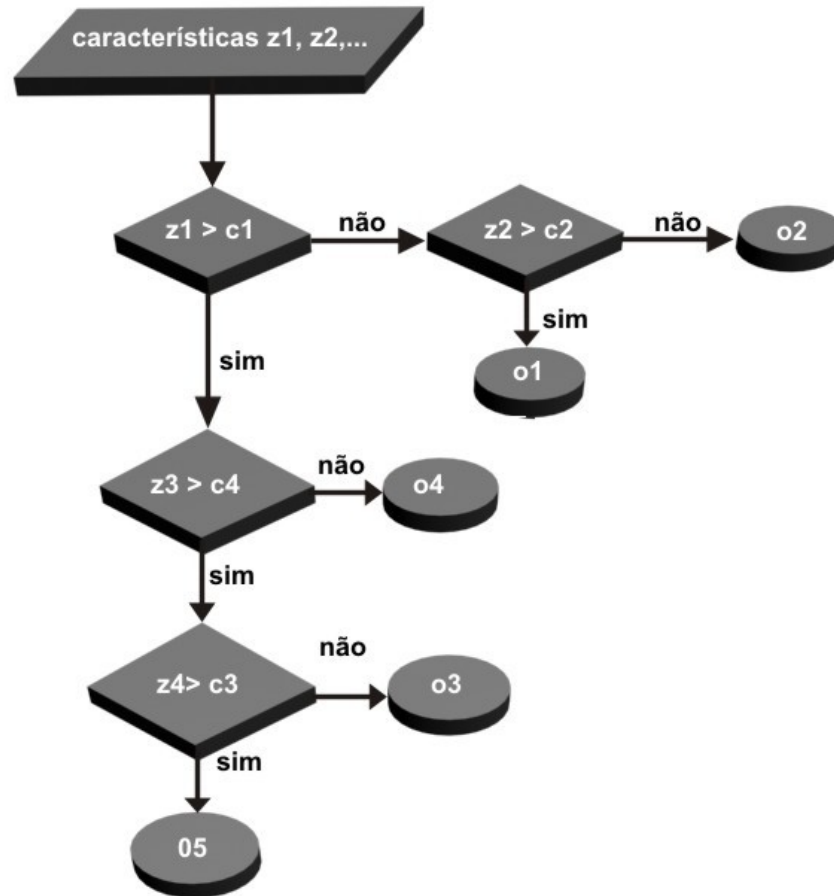


Figura 6.48 - Árvore de decisão.

6.4.2.2. Por Distribuição Estatística

Classificador de Risco Mínimo de Bayes (CRMB):

$$\mathfrak{R} \cong \sum_{k=1}^K \int_{R_k} c(x/S_k) p(x) dx \quad (6.92)$$

A regra de decisão que minimiza \mathfrak{R} é dada por:


$$\sum_{i=1}^K c_{i,k} P(S_i) p(x/S_i) < \sum_{i=1}^K c_{i,j} P(S_i) p(x/S_i) \quad , \\ \forall \quad j \neq k \Rightarrow \mathbf{x} \in S_k \quad (6.94)$$

6.4.3. Classificação Não Supervisionada

Estabelecem-se *clusters* ou agrupamentos naturais no espaço de características, a partir da medida de diferentes parâmetros dos objetos.

Um *cluster* é um conjunto de pontos no espaço de características, que possuem densidade local máxima se comparada à densidade dos pontos ao redor.

6.4.4. Redes Neurais Artificiais



6.4.5. Lógica Fuzzy

Função de pertinência:

$$\mu_I(f(x,y)) = \begin{cases} \frac{1}{1 + |f(x,y) - m_1(T)|/D} & \text{se } f(x,y) \leq T, \\ \frac{1}{1 + |f(x,y) - m_2(T)|/D} & \text{se } f(x,y) > T, \end{cases} \quad (6.97)$$

