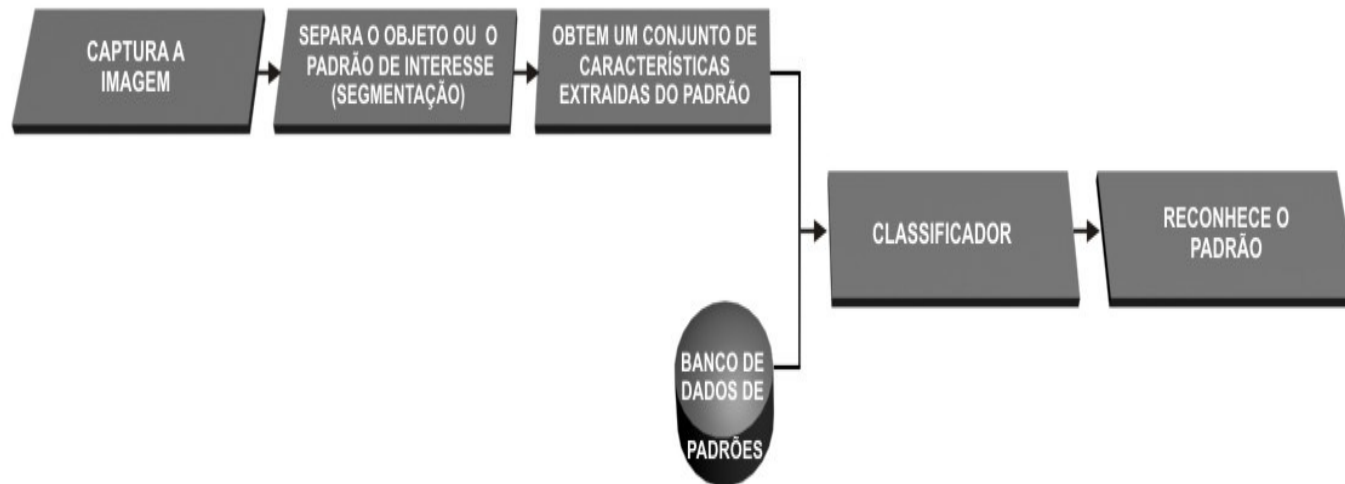




Aula 8 – Reconhecimento de Padroes : parte 2.

Análise de Imagens - 2015

Aura Conci



Etapas de um sistema de reconhecimento de padrões.

Padrão como generalização de um *Pixel, Voxel ou Região*

Vizinhança do padrão

Vizinhança-4


Vizinhança-8

Medidas de Distância


Métricas

Conectividade (Propriedade de um padrão como região
conectada)


Vizinhança do padrão (Vizinhança-4 e Vizinhança-8)



vizinhança-4 de p ,




vizinhança-8 de p ,



vizinhança-8 de p .

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



Vizinhança Hexagonal

Vizinhança de um padrão numa grade hexagonal.

Métricas

Distância *city-block*, *Manhatan* ou *quarteirão* : $r=1$ na *formula generica*

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

A *distância Euclidiana*, D_2 para $r = 2$ na *fórmula genérica*

$$= D_2(p, q)$$

Ex. $r=n=2$, entre p e q :

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

$\sqrt{8}$	$\sqrt{5}$	2	$\sqrt{5}$	$\sqrt{8}$
$\sqrt{5}$	$\sqrt{2}$	1	$\sqrt{2}$	$\sqrt{5}$
2	1	0	1	2
$\sqrt{5}$	$\sqrt{2}$	1	$\sqrt{2}$	$\sqrt{5}$
$\sqrt{8}$	$\sqrt{5}$	2	$\sqrt{5}$	$\sqrt{8}$

Distância Euclidiana $D_2 \leq 2$ do *pixel* central .

4	3	2	3	4
3	2	1	2	3
2	1	0	1	2
3	2	1	2	3
4	3	2	3	4

Distância $D_1 \leq 2$ do *pixel* central .

Fazer esses até vizinhança 7x7

Trab 7: Mostre como fica a métrica **sup** , ou **infinito**, $D_{\infty}(p,q)$ ou $D_{sup}(p,q)$, para uma vizinhança de 7x7 de um pixel.

Use a formula apresentada no slide anterior.

Apresente essas distancias em cores distintas seguindo os modelos acima, para os 4 primeiros níveis de vizinhança use as mesmas cores daqui.

Conectividade

(Propriedade de um padrão ser
uma região conectada)

Regiões conectas 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

$$N_4(p) \cap N_4(q) = \text{vazio!}$$

Tipos de características padrão

Características Estatísticas: mediana, moda e média, (momentos de ordem zero)

Amplitude/Range, variância (momento de ordem dois em torno da média), momentos de ordem superior em torno ou não da média

$$\text{variância} = \frac{\sum_{i=1}^N (m - x_i)^2}{N - 1}$$

**Mas pode-se ter muito mais que isso formando um vetor em \mathbb{R}^n
= $(x^1, x^2, \dots, x^i, \dots, x^n)$**

Análise de Componentes Principais (PCA)

Análise de Componentes Independentes (ICA)

Análise de Componentes Principais (PCA)

- Também chamada de **Transformada Discreta de Karhunen-Loève** (KLT) ou ainda **Transformada Hotelling**.
- *Descobre o grau de correlação entre as características usadas*
- A **componente principal** é o arranjo que melhor representa a distribuição dos dados.
- 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.

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:

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

O **vetor médio** pode ser calculado:

$$m_x = \frac{1}{M} \sum_{i=1}^M x_i$$

onde $(x_1, x_2, \dots, x_i, \dots, x_M)$

Auto espaços , auto vetores e auto valores

Um vetor v é um **autovetor** de uma matriz M , se M é um 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.

Transformada de Hotelling

Transformada de Hotelling:

$$y = A (x - m_x)$$

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 .

Análise de Componentes Principais para Imagens Coloridas

(1) Gera-se a matriz Σ :

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

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

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

(3) Gera-se um novo espaço chamado de $[P_1, P_2, P_3]$.

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

PCA em Reconhecimento de Padrões

Pode-se dizer que uma **imagem é um padrão de $h \times w$ características** ou um vetor no espaço $(h \times w)$ dimensional.

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 .

Transformada de Hotelling e PCA na reconstrução

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

$$y = A (x - m_x)$$

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.

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

Utilizam-se **descritores** para caracterizar o objeto/padrão.


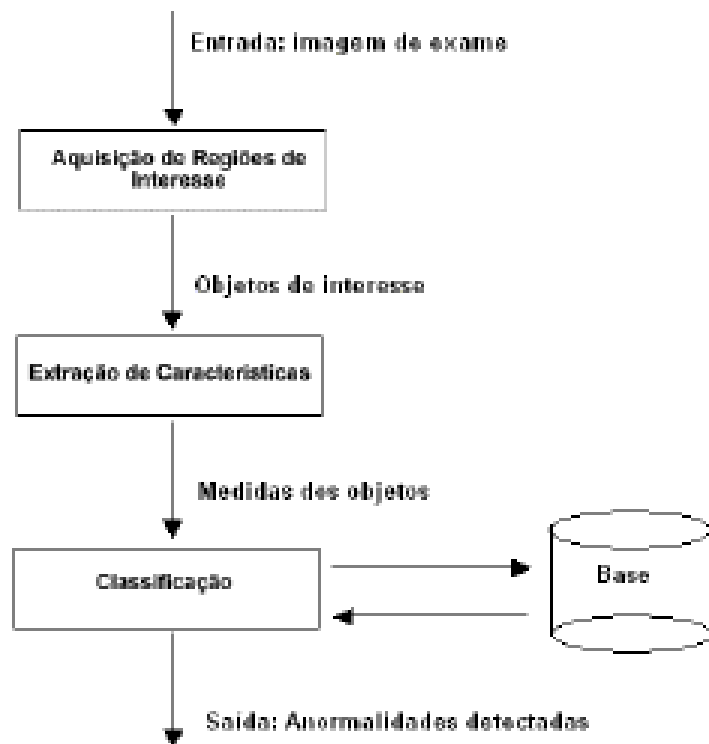
Cada tipo de descritor será **mais adequado** a **determinado aspecto** como:

- **forma,**
- **dimensões,**
- **cor,**
- **textura,**
- **etc.**

Exemplo de aplicação de descritor de forma: detecção de tumores malignos ou benignos

Métodos Computacionais de
Auxílio à Detecção e Diagnóstico


(CAD/CADx - Computer-Aided Detection and Diagnosis)



Exemplo de aplicação de descritor de forma: detecção de tumores malignos ou benignos



- Mamogramas:
- incidência médio-lateral e craniocaudal
- (ambas da mesma pessoa).



Exemplo de uma mamografia com seus principais elementos.



CAD e CADx

(CAD/CADx: *Computer-Aided
Detection / Diagnosis*)

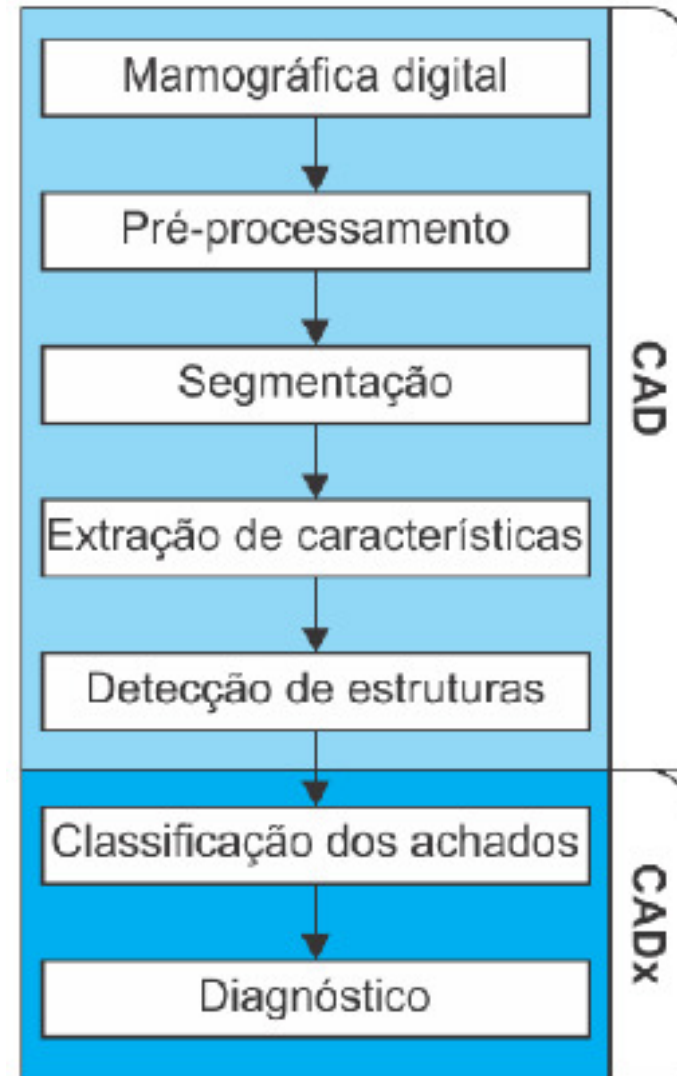


Figura 1: Anormalidades do tecido mamário. (a) Massa; (b) Microcalcificações; (c) Distorção de arquitetura.





Figura 2: Classificação das massas de acordo com o aspecto de suas bordas.



Figura 3: Classificação das massas de acordo com sua forma.



Oval



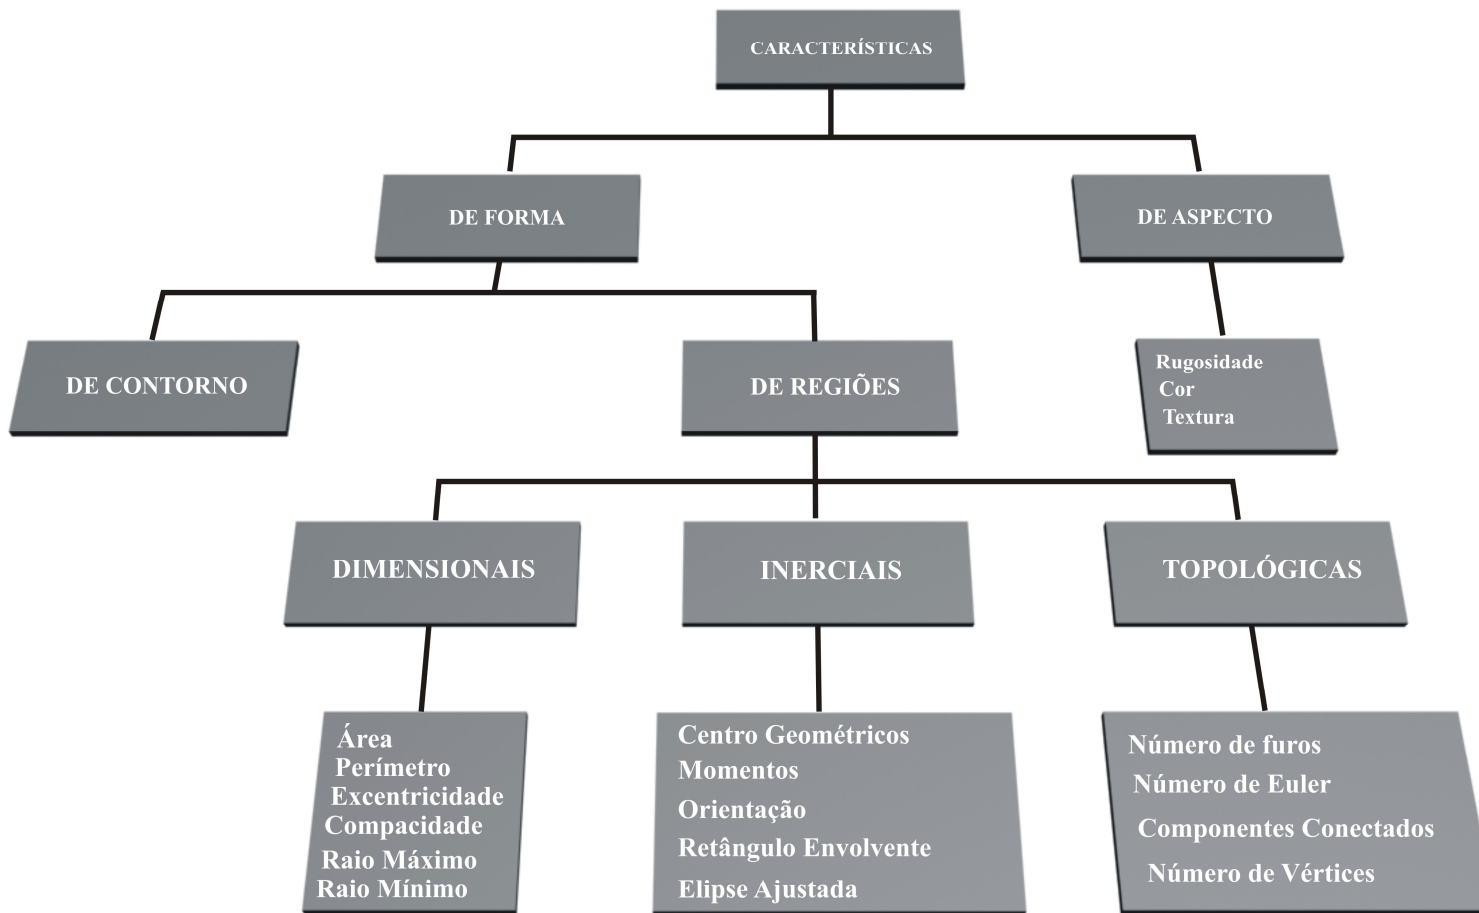
Circular



Lobulada



Irregular



Tipos de características.

Descritores de forma

Características Dimensionais

Características Inerciais

Características de Contorno

Características Topológicas

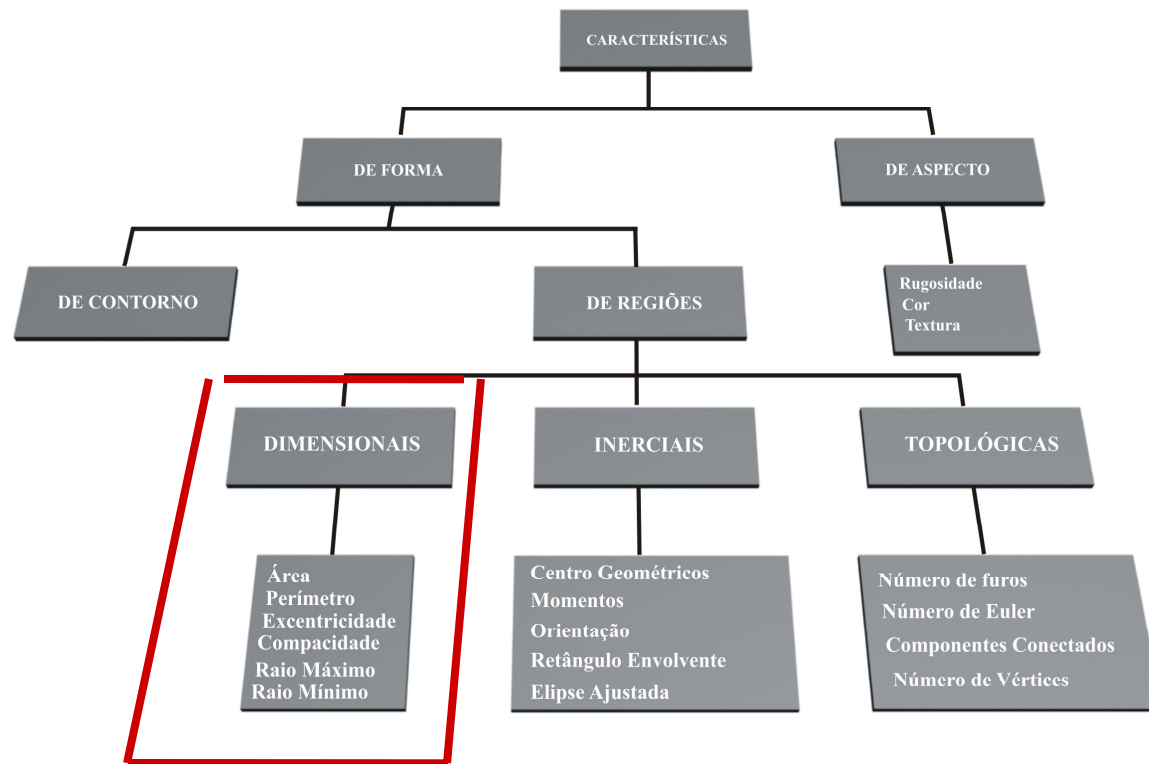
Características de Aspecto

Outras características

A forma pode conter informações importantes.

- A literatura de processamento de imagens apresenta vários descritores ou medidas geométricas. Entre eles, destacam-se a compacidade, excentricidade, circularidade, descritores Fourier, desproporção circular, densidade circular e descritores de Feret, descritores baseados em momentos e curvatura.
- Para o cálculo de tais medidas não são levados em conta os níveis de cinza presentes nos objetos, ou seja, o objeto é binarizado.
- Somente suas propriedades geométricas, tais como área e perímetro são utilizados nos cálculos.

Características Dimensionais

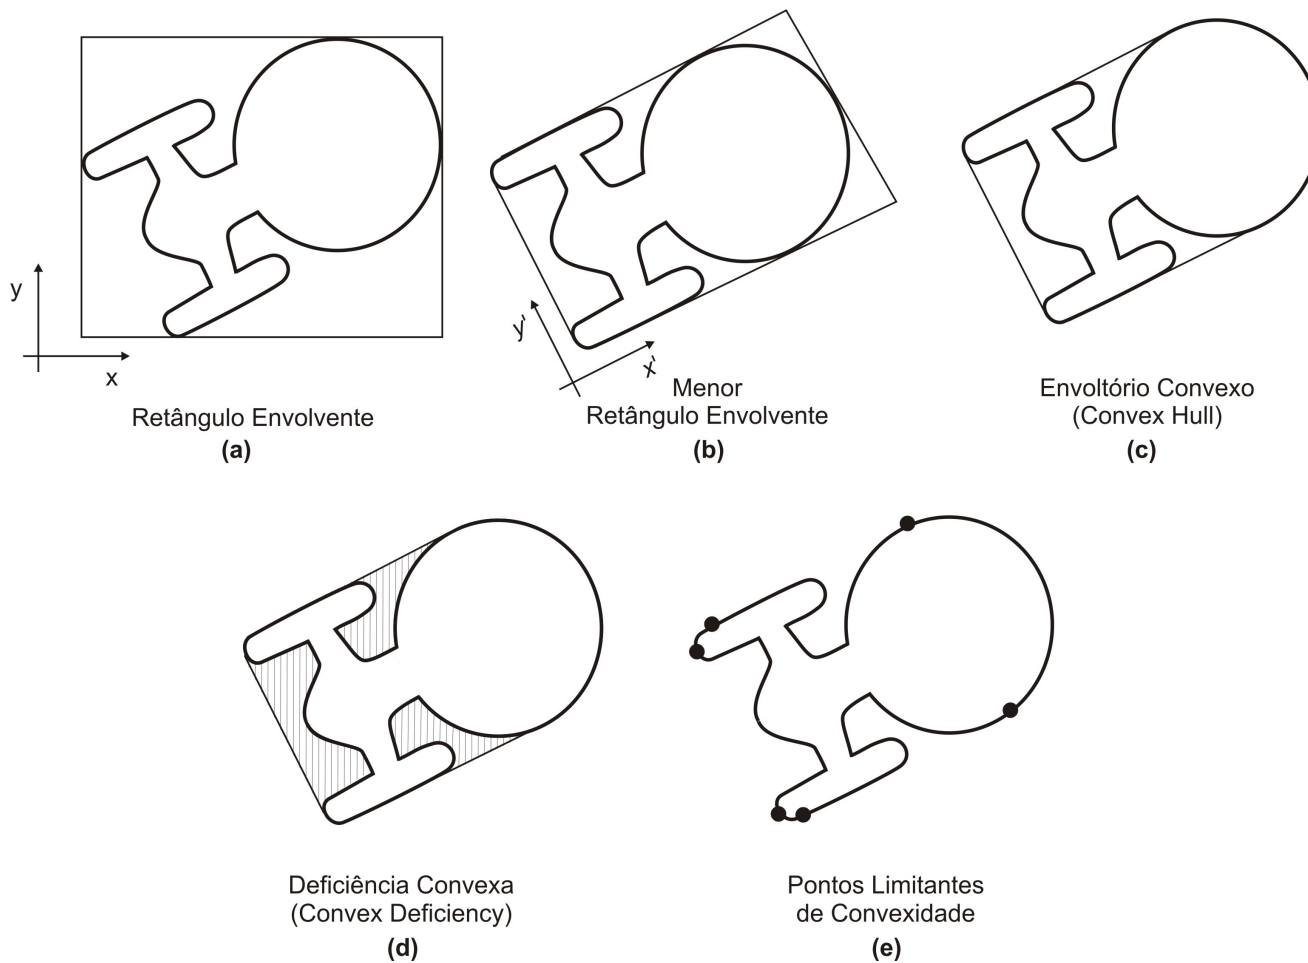


Tipos de características.

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.



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.

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.

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.




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


Coeficiente de compacidade e fator de forma

$$\gamma = \frac{P^2}{4\pi A}$$

(repare que para um círculo a compacidade é 1)



(A)




(B)

Comparação de objetos através da compacidade: (a) compacto; (b) não-compacto.

Comparação de objetos através da excentricidade



excentricidade alta



excentricidade baixa

- convexidade



(a)

(a) Objeto com picos e defeitos.



(b)

superfície convexa.

A circularidade é definida por:

$$C = \frac{4\pi A}{(P_{convexo})^2}$$

sendo A a área do objeto em estudo e $p_{convexo}$ é o perímetro convexo. .




Circularidade = 0.584



Circularidade = 0.447

Esqueleto


- A definição de esqueleto diz que, um ponto pertence ao esqueleto se, ele é o centro de um círculo máximo, que toca a borda do objeto em pelo menos dois pontos distintos.
- A Figura contém um exemplo do esqueleto (em preto) de um retângulo.



Esqueleto

A Figura contém um exemplo do esqueleto (em preto) de um retângulo.

Os pontos A , B e C (verdes) correspondem aos centros dos círculos que tocam as bordas da imagem. Porém, apenas A e B tocam as bordas da imagem pelo menos em dois pontos distintos, logo, pertencem ao esqueleto.




Esq. Cont.

- Os esqueletos possuem várias aplicações em processamento de imagens, tais como:
 - agrupamento,
 - segmentação,
 - vetorização,
 - descrição de formas,
 - reconhecimento de caracteres.
- Podem ainda ser utilizados em conjunto com outras medidas de forma

Bit quads

É possível extrair características usando conjuntos de 2x2 pixels que descrevem o conteúdo de um objeto binarizado

Os bit quads descrevem as 16 combinações possíveis de ocorrer P&B (ou 0 e 1) nestes pixels




Forma visual dos *Bitquads*: Q_0
 $, Q_1, Q_2, Q_3, Q_4$ e Q_D

Bit quads

$$A = \frac{1}{4}nQ_1 + \frac{1}{2}nQ_2 + \frac{7}{8}nQ_3 + nQ_4 + \frac{3}{4}nQ_D \quad (\text{area})$$

$$P = nQ_2 + \frac{1}{\sqrt{2}}[nQ_1 + nQ_3 + 2nQ_D] \quad (\text{perimetro})$$

$$\varepsilon = \frac{1}{4}[nQ_1 - nQ_3 + 2nQ_D] \quad (\text{número de Euler})$$




Forma visual dos *Bitquads*:

Q_0, Q_1, Q_2, Q_3, Q_4 e Q_D

NÚMERO DE EULER (pronuncia-se "Óiler")

- O grande matemático Leonhard Euler foi, para todos os efeitos, quem inaugurou um ramo da matemática chamado **topologia**.
- **Nasceu na suíça em abril de 1707**, produziu suas maiores obras quando já estava velho e cego.
- Em um objeto tridimensional vamos chamar o número de faces de F , o número de arestas de A e o número de vértices de V .
- Euler provou que por mais que o objeto se transforme é sempre constante o que hoje chamamos de **número de Euler (E)**: definido assim:
- **$E = F - A + V$.**







NÚMERO DE EULER

$$E = F - A + V$$

- Imagine que o cubo é feito de massa de moldar. Com jeito, é possível transformá-lo em uma esfera, uma pirâmide ou uma batata doida sem rasgar nem cortar nada.
- Isso só é possível com objetos topologicamente iguais.
- O cubo tem 6 faces, 12 arestas e 8 vértices.
- Portanto, o número de Euler do cubo é:
 $E(\text{cubo}) = 6 - 12 + 8 = 2.$





O teorema de Euler diz que:
o número de Euler é **constante**
para uma superfície qualquer.

- Isso quer dizer o seguinte: suponha que você divida cada face do cubo em 4 partes, traçando 2 segmentos de reta perpendiculares entre si
- Agora, pontos como (A) ou (B) serão considerados novos vértices, linhas como (AB) serão novas arestas e áreas como (ABCD), novas faces.
- Pois conte os novos números de faces, arestas e vértice.
- Você obterá: $F' = 24$, $A' = 48$ e $V' = 26$.
- E, terá:
- **$E' = F' - A' + V' = 24 - 48 + 26 = 2 = E$.**



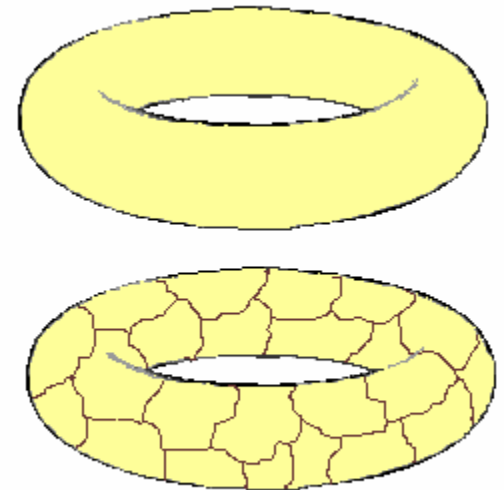
O resultado é o mesmo de antes.

- Pois acredite: mesmo se você desenhar linhas malucas sobre o cubo, criando uma porção de novas arestas, vértices e faces, obterá sempre o mesmo número de Euler: 2.
- Acho que ninguém vai se admirar, a essa altura, ao constatar que o número de Euler continuará o mesmo até quando o cubo for deformado como mostra a figura.
- E a deformação pode ser tal que o cubo acabe virando uma jeitosa esfera (mudança de sexo) ou mesmo uma batata toda cheia de “calombos”.
- Tecnicamente, diz-se que o cubo, a esfera e a batata são todas superfícies topologicamente idênticas. Todas têm o mesmo número de Euler: 2.




Imagine que o cubo é feito de massa de moldar, dessa que as crianças adoram. Com jeito, é possível transformá-lo em uma esfera, uma pirâmide ou uma batata doida sem rasgar nem cortar nada. Isso só é possível com objetos topologicamente iguais.

- A coisa muda se o objeto tiver um furo.
- O objeto furado mais amado pelos matemáticos é o **toro**, essa coisa com forma de rosquinha.
- Se a gente fizer sobre a superfície do toro o mesmo que fizemos sobre a superfície do cubo (traçando linhas que formam faces, arestas e vértices) e depois fizermos as contas, acharemos um número de Euler nulo!
- **$E(\text{toro}) = 0$**



O toro, e qualquer superfície com um furo, é topologicamente diferente do cubo e da esfera.

- Isto é: Não dá para transformar uma esfera de massa em um toro sem cortar ou rasgar alguma coisa.
- Talvez você tenha estranhado que o toro tenha curvatura zero, quando ele nos parece bem encurvadinho. É óbvio que a curvatura local do toro não é zero em todos os pontos. O que é zero é a *curvatura total* do toro.
- Considere um corte no toro resultando no círculo ABCD.
- Os pontos que ficam no lado de fora (ABC), menos os extremos A e C, têm curvatura positiva. Os pontos que ficam no lado de dentro (ADC) têm curvatura negativa. E os pontos A e C têm curvatura nula. Computando tudo, achamos a curvatura total zero.



Quando a superfície tem buracos a expressão para o número de Euler fica sendo:

$$\mathbf{E = F - A + V = 2 - 2 \times B},$$

sendo **B** o número de buracos ou furos na superfície.

- Essa formula é chamada de Euler/Poincaré
- Para uma esfera ou um cubo, $B = 0$, logo, $E = 2$. Para o toro, $B = 1$, logo, $E = 0$.
- Com mais de um buraco, o número de Euler fica negativo.

Vazios

- O vazio interno mede a relação entre a área vazia (marcada com 0) e a área não vazia (marcada com 1) da Figura

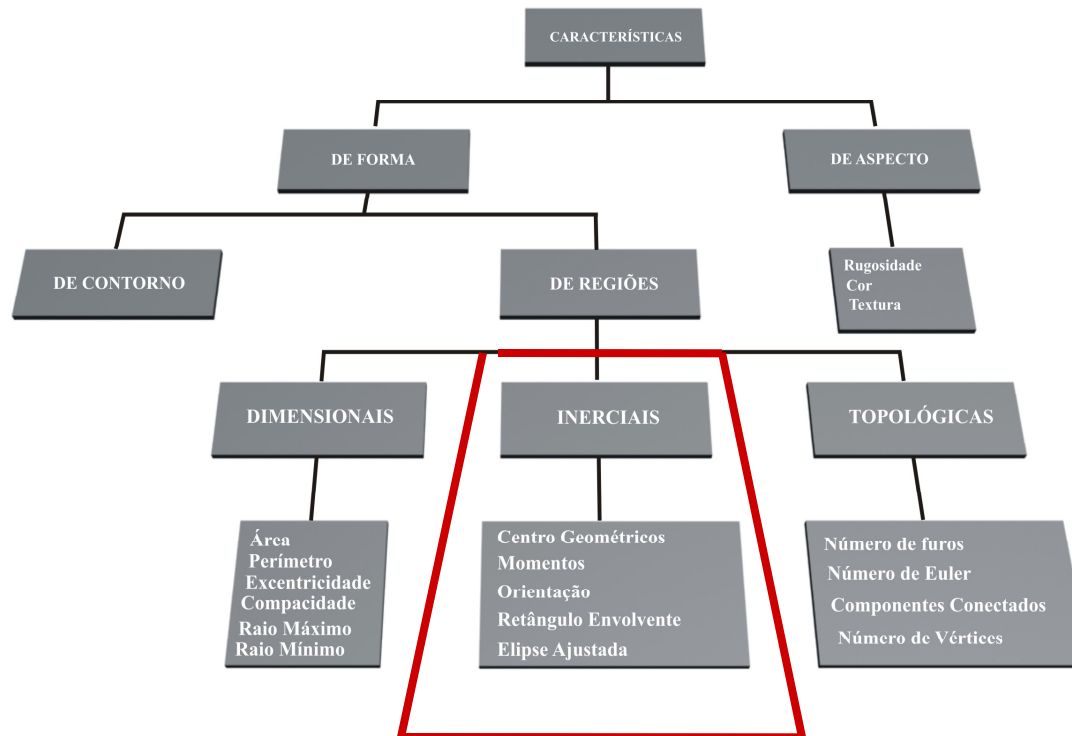
$$V_i = \frac{A_0}{A_1}$$

O vazio mede a relação entre a área vazia e a área total da imagem (preenchida ou não):

$$V_i = \frac{A_0}{A_0 + A_1}$$



Características Inerciais



Tipos de características.

Momentos Geométricos

A moment of order p of a continuous signal $f(x)$ of length N is defined as follows:

$$M_p = \int_0^N f(x)x^p dx. \quad (1)$$

Similarly, for a 2-D signal $f(x, y)$, the moment of order p, q is defined as

$$M_{p,q} = \int_0^N \int_0^N x^p y^q f(x, y) dx dy. \quad (2)$$

However, for discrete signals, the above expressions are approximated by sums

$$M_p = \sum_{x=0}^{N-1} f(x)x^p \quad (3)$$

and

$$M_{p,q} = \sum_{x=0}^{N-1} \sum_{y=0}^{N-1} f(x, y)x^p y^q, \quad (4)$$

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

$$m_{pq} = \sum_{k=1}^n B(i_k, j_k) (i_k)^p (j_k)^q \quad p, q = 0, 1, 2, \dots \quad (3)$$

Área:

$$m_{00} = \sum_m \sum_n B(m, n) \quad (4)$$

Centróide:

$$i_0 = \sum_{k=1}^n B(i_k, j_k) i_k / \sum_{k=1}^n B(i_k, j_k) = m_{10} / m_{00} \quad (6)$$

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

Momentos centrais :

$$\mu_{pq} = \sum_{k=1}^n B(i_k, j_k) (i_k - i_0)^p (j_k - j_0)^q B(i_k, j_k) \quad (6)$$

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

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

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

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

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

Momentos geométricos invariantes de [Hu](#) (1962):

$$\phi_1 = \eta_{2,0} + \eta_{0,2} \quad (5)$$

$$\phi_2 = (\eta_{2,0} - \eta_{0,2})^2 + 4\eta_{1,1}^2 \quad (6)$$

$$\phi_3 = (\eta_{3,0} - 3\eta_{1,2})^2 + (3\eta_{2,1} - \eta_{0,3})^2 \quad (7)$$

$$\phi_4 = (\eta_{3,0} + \eta_{1,2})^2 + (\eta_{2,1} + \eta_{0,3})^2 \quad (8)$$

$$\begin{aligned} \phi_5 = & (\eta_{3,0} - 3\eta_{1,2})(\eta_{3,0} + \eta_{1,2}) [(\eta_{3,0} + \eta_{1,2})^2 - 3(\eta_{2,1} + \eta_{0,3})^2] + \\ & (3\eta_{2,1} - \eta_{0,3})(\eta_{2,1} + \eta_{0,3}) [3(\eta_{3,0} + \eta_{1,2})^2 - (\eta_{2,1} + \eta_{0,3})^2] \end{aligned} \quad (9)$$

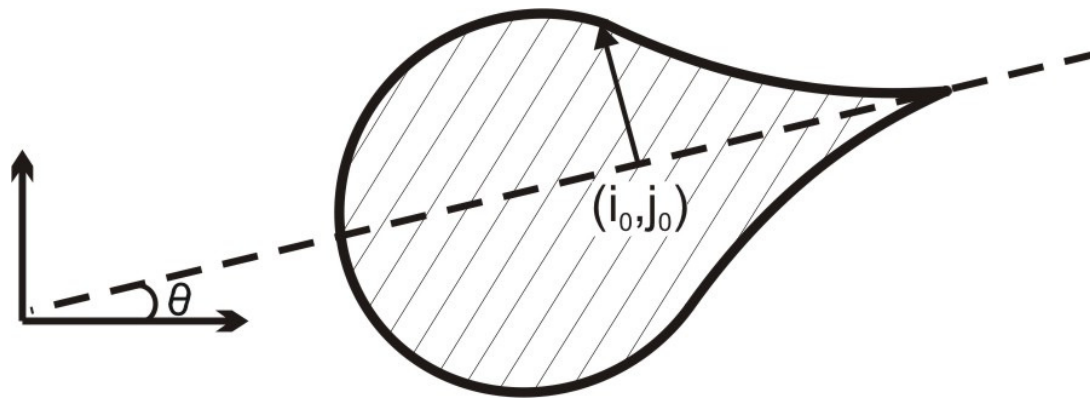
Momentos geométricos invariantes de **Hu** (1962):

$$\phi_6 = (\eta_{2,0} - \eta_{0,2})[(\eta_{3,0} + \eta_{1,2})^2 - (\eta_{2,1} + \eta_{0,3})^2] + 4\eta_{1,1}(\eta_{3,0} + \eta_{1,2})(\eta_{2,1} + \eta_{0,3}) \quad (10)$$

$$\phi_7 = (3\eta_{2,1} - \eta_{0,3})(\eta_{3,0} + \eta_{1,2})[(\eta_{3,0} + \eta_{1,2})^2 - 3(\eta_{2,1} + \eta_{0,3})^2] - (\eta_{3,0} - 3\eta_{1,2})(\eta_{2,1} + \eta_{0,3})[3(\eta_{3,0} + \eta_{1,2})^2 - (\eta_{2,1} + \eta_{0,3})^2] \quad (11)$$


θ - orientação dos eixos principais:

$$\tan 2\theta = 2\mu_{1,1} / (\mu_{2,0} - \mu_{0,2}) \quad (12)$$




Orientação.

Retângulos e Elipses ajustados




Retângulo ajustado.



Elipse ajustada.

Distância radial ponderada

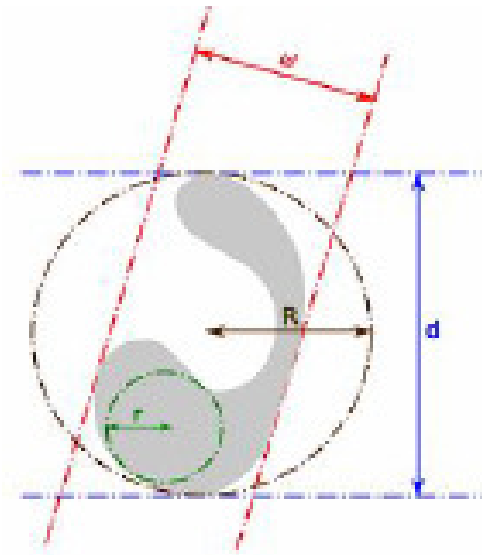
A distância radial ponderada calcula a relação entre o raio médio da figura e o seu raio estimado.



- Ilustração da distância radial ponderada. Em azul o raio médio (R_m) e em laranja o raio estimado (R_e).

O diâmetro de Feret

- é uma medida de um tamanho do objeto ao longo de uma direção específica.
- Em geral, pode ser definido como a distância entre os dois planos paralelos que
- limitam o objeto perpendicular a essa direção.
- Dada uma forma em 2D, é possível extrair as informações de área (A), perímetro (P), r (raio da maior circunferência interna da forma), R (raio da menor circunferência externa da forma), ω (diâmetro mínimo de Feret), d (diâmetro máximo de Feret).



O diâmetro de Feret- cont

- Com essas informações é possível criar um conjunto de descritores de forma, como mostrado na Tabela

Equação	Equação
r/R	$2\pi r/P$
$w/(2R)$	$\pi w/P$
$A/2\pi R^2$	$4\pi A/P^2$
$2r/d$	$2\delta/P$
w/d	$4R/P$
$4A/\pi d^2$	$\pi r^2/A$
$R^2\sqrt{3}/d$	$2r/w$

Descritores geométricos, capazes de extrair medidas invariantes à rotação, translação e escala. Exemplos listados na tabela, onde A , P , r , R , w e d são a área, perímetro, raio da maior circunferência interna, raio da menor circunferência externa, diâmetro mínimo de Feret, diâmetro máximo de Feret respectivamente.

$$f_1 = \frac{a}{\tan(\text{azul} \leq \theta)}$$

$$f_3 = \frac{\text{dist}(\text{CentroMassa}, \text{CentroMin})}{\text{dist}(\text{CentroMassa}, \text{CentroMax})}$$

$$f_5 = \frac{\text{distMinMédia}(\text{azul} \leq \theta, \text{forma})}{\tan(\text{azul} \leq \theta) \cdot R}$$

$$f_7 = \frac{\text{distMinMédia}(\text{azul} \leq \theta, \text{forma})}{P \cdot r}$$

$$f_9 = \frac{\text{distMinMédia}(\text{forma}, \text{fecho})}{P \cdot R}$$

$$f_{11} = \frac{\text{distMinMédia}(\text{azul} \leq \theta, \text{fecho})}{P \cdot R}$$

$$f_{13} = \frac{\text{distMinMédia}(\text{forma}, \text{CentroMin})}{P \cdot R}$$

$$f_{15} = \frac{\text{distMinMédia}(\text{forma}, \text{CentroMassa})}{P \cdot R}$$

$$f_{17} = \frac{\text{distMinMédia}(\text{fecho}, \text{CentroMax})}{\tan(\text{fecho}) \cdot r}$$

$$f_{19} = \frac{\text{área}(\text{CentroMassa}, \text{CentroMin}, \text{CentroMax})}{A}$$

$$f_{21} = \frac{A}{\text{área}(\text{fecho})}$$

$$f_2 = \frac{w}{\tan(\text{azul} \leq \theta)}$$

$$f_4 = \frac{\text{DyDistMin}(\text{azul} \leq \theta, \text{forma})}{R}$$

$$f_6 = \frac{\text{distMinMédia}(\text{azul} \leq \theta, \text{forma})}{P \cdot R}$$

$$f_8 = \frac{\text{distMinMédia}(\text{forma}, \text{fecho})}{P \cdot R}$$

$$f_{10} = \frac{\text{distMinMédia}(\text{forma}, \text{fecho})}{P \cdot r}$$

$$f_{12} = \frac{\text{distMinMédia}(\text{azul} \leq \theta, \text{fecho})}{P \cdot r}$$

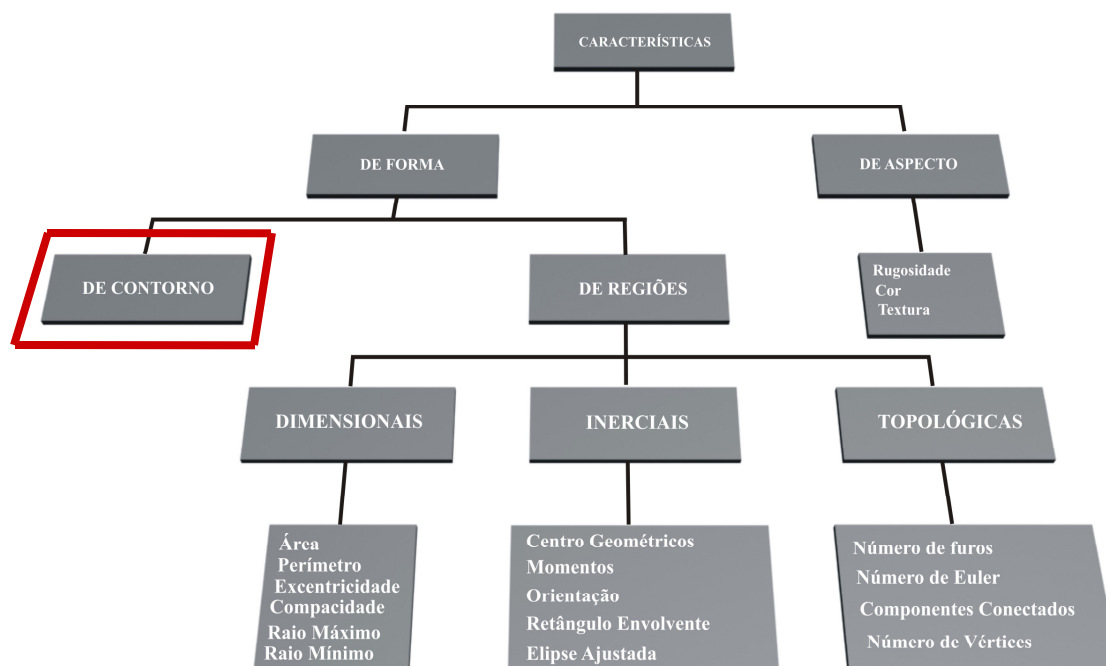
$$f_{14} = \frac{\text{distMinMédia}(\text{forma}, \text{CentroMax})}{P \cdot R}$$

$$f_{16} = \frac{\text{distMinMédia}(\text{forma}, \text{CentroMin})}{P \cdot r}$$


$$f_{18} = \frac{\text{distMinMédia}(\text{fecho}, \text{CentroMassa})}{\tan(\text{fecho}) \cdot r}$$

$$f_{20} = \frac{\text{área}(\text{CentroMassa}, \text{CentroMin}, \text{CentroMax})}{\text{área}(\text{fecho})}$$

Características de Contorno



Tipos de características.




(a)


(b)

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.

Código da Cadeia




Codificação vizinhança-4 de p $N_4(p)$




e vizinhança-8 de p ,
 $N_8(p)$

para o código da cadeia.



(a)



(b)

Segmentos para o código da Cadeia:

(a) código para vizinhança-4; (b) código para vizinhança-8 de p


.

$N_4(p)$ 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).

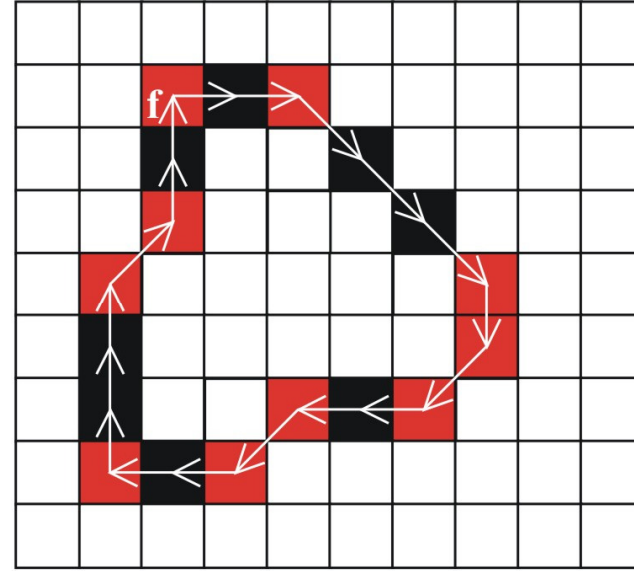
$N_8(p)$ é CC = (2,2,1,1,1,0,7,6,6,7,6,6,4,4,4,3,4,4).

Uso:

- É possível obter diversas características , como altura, largura, área ou perímetro, direto do código de cadeia de um objeto.
- Ele também ajuda na vetorização de objetos.
- Na forma de código de primeira diferença é ainda invariante a escala!



(a)



(b)

Pontos onde o código se diferencia do vizinho.

A base DDSM, registra os nódulos pela regra da cadeira.

- Possui 2620 casos adquiridos através das seguintes instituições americanas: **Massachusetts General Hospital**, **Wake Forest University**, e **Washington University in St. Louis School of Medicine**.
- Os dados são constituídos de estudos de pacientes de diferentes origens étnicas e raciais.
- Cada caso contém duas imagens de cada mama, nas projeções médio-lateral oblíqua e craniocaudal,
- consistindo assim em quatro imagens radiográficas. Além disso, são disponibilizadas informações sobre a paciente, tal como a idade e a densidade da mama.
- O contorno da lesão está codificado em **chain code**

Assinaturas ou Gráficos $r(\theta)$




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

Referencias:

ESTER, M.; KRIEGEL, H.; SANDER, J.; XU, X. **A density-based algorithm for discovering clusters in large spatial databases with noise**, 2nd International Conference on Knowledge Discovery and Data Mining, pp. 226-231, 1996.

PAL, N.; PAL, S. **A Review on image segmentation techniques**, Pattern Recognition, vol. 26, pp. 1277-1294, 1993.

VAPNIK, V. **Statistical learning theory**, New York: Wiley, 1998.

A. Conci, E. Azevedo e F.R. Leta - **[Computação Gráfica](#): volume 2 ,
Processamento e Análise de Imagens Digitais, Campus/Elsevier. 2008 –
ISBN 85-352-1253-3.**