



Departamento de Engenharia Elétrica

SEL-0339

Introdução à Visão Computacional

Aula 9

Extração de Características: Descritores

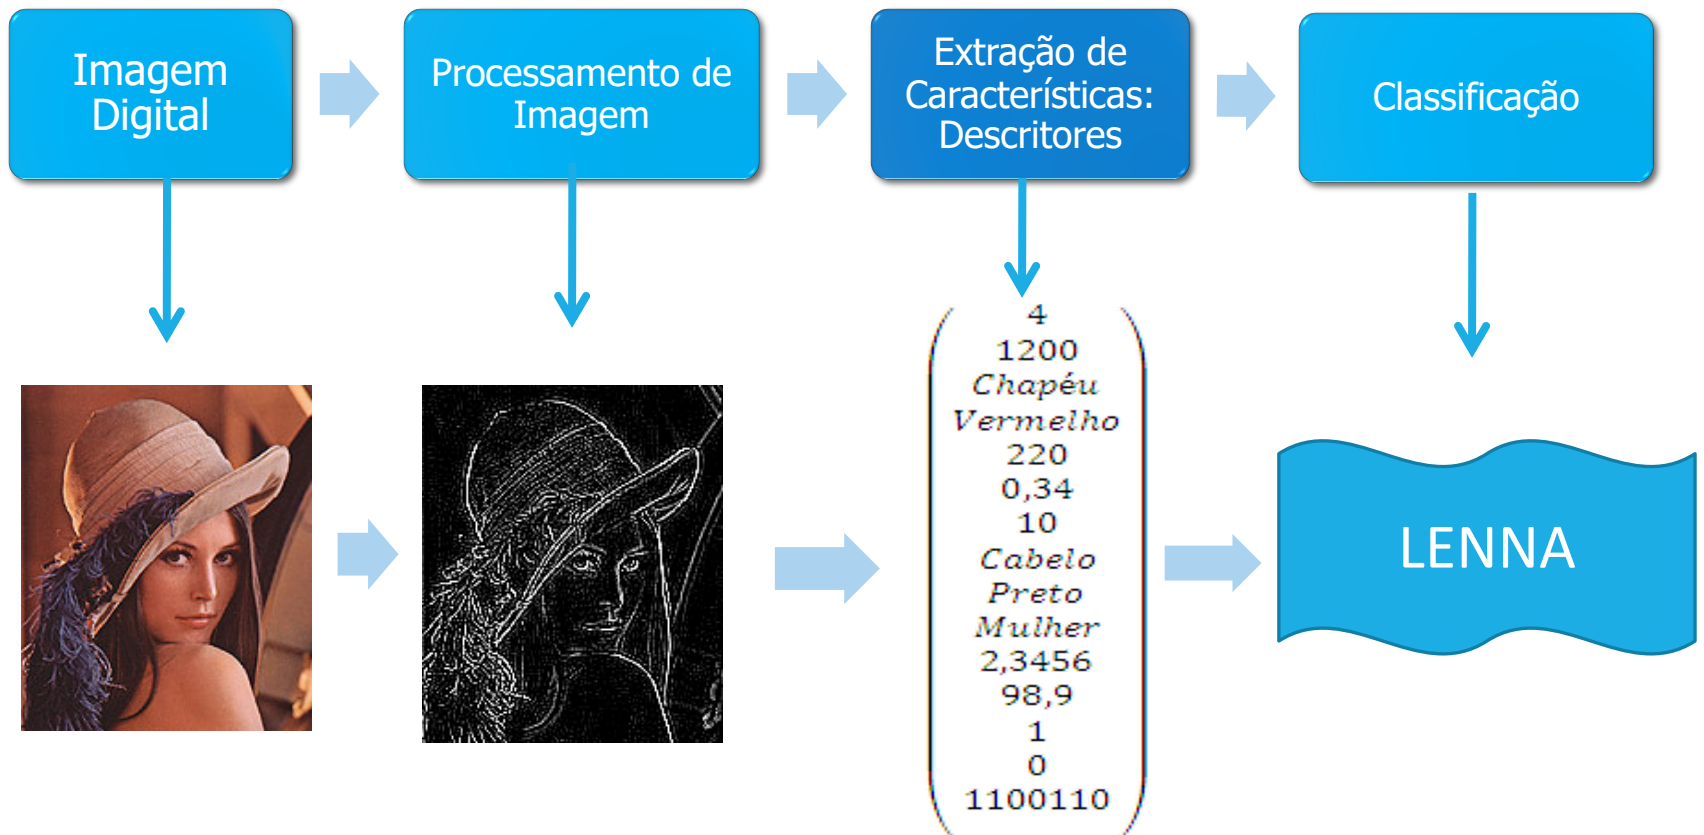
Prof. Dr. Marcelo Andrade da Costa Vieira

Arthur Chaves Costa

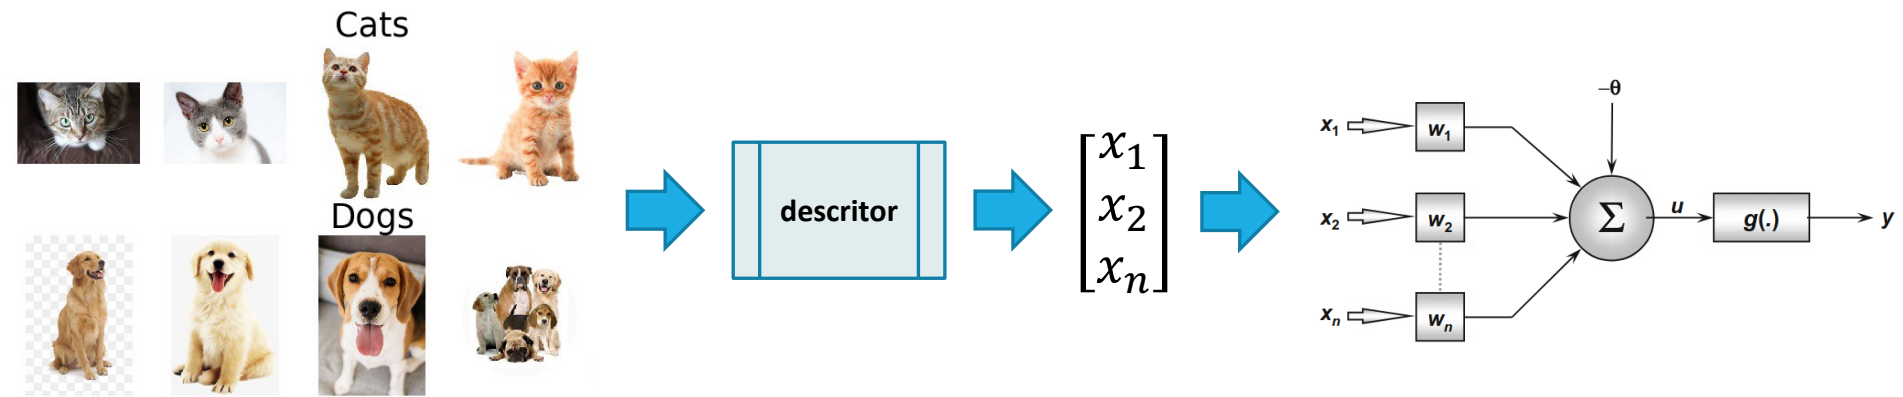
Renann de Faria Brandão

mvieira@sc.usp.br

Visão Computacional



Visão Computacional



Que características podemos utilizar para classificar as raças?



Bulldog



Whippet

Vetor com descritores de característica

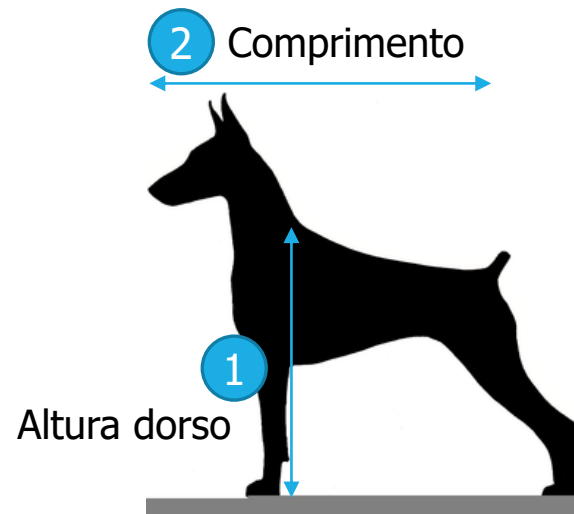


Bulldog




Whippet

Exemplo:



Vetor de características



Médias de medidas de cada raça



Bulldog

Altura dorso	35,5 cm
Comprimento	60 cm

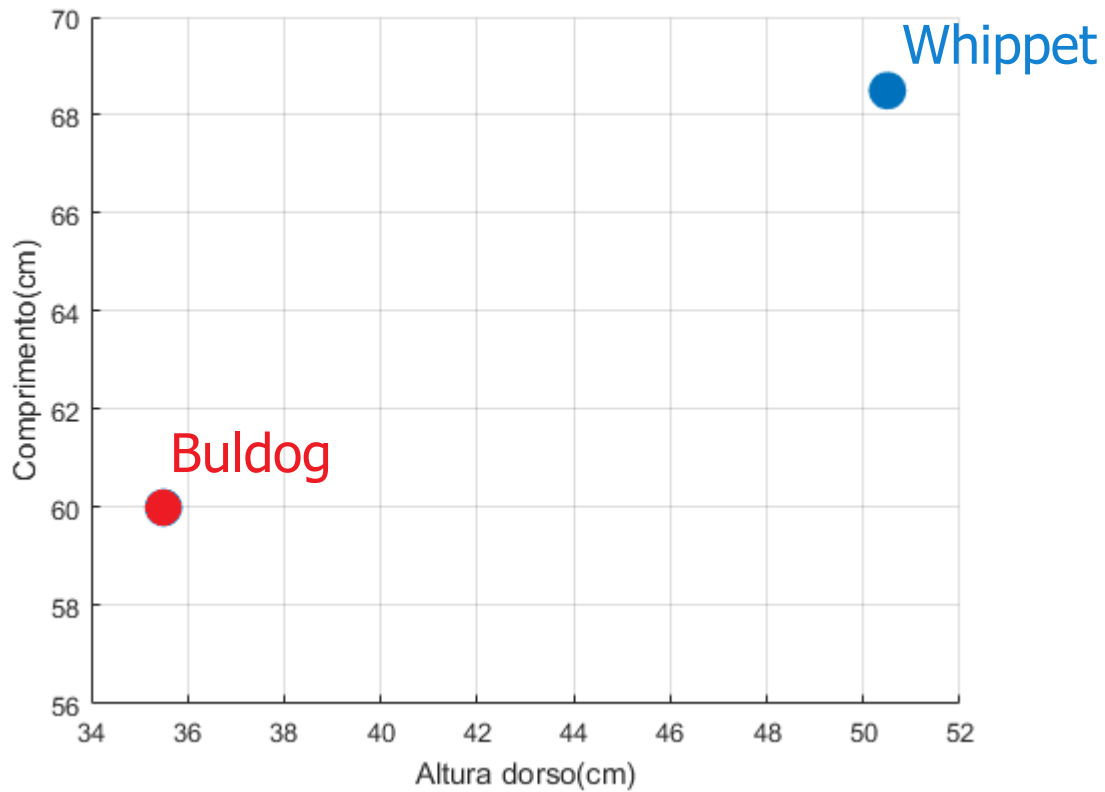


Whippet

Altura dorso	50,5 cm
Comprimento	68,5 cm

Vetor com descritores de característica

- No espaço de atributos do vetor de característica:



Médias de medidas de cada raça

- 1
- 2



Bulldog

Altura dorso	35,5 cm
Comprimento	60 cm



Beagle

Altura dorso	37 cm
Comprimento	57,5 cm

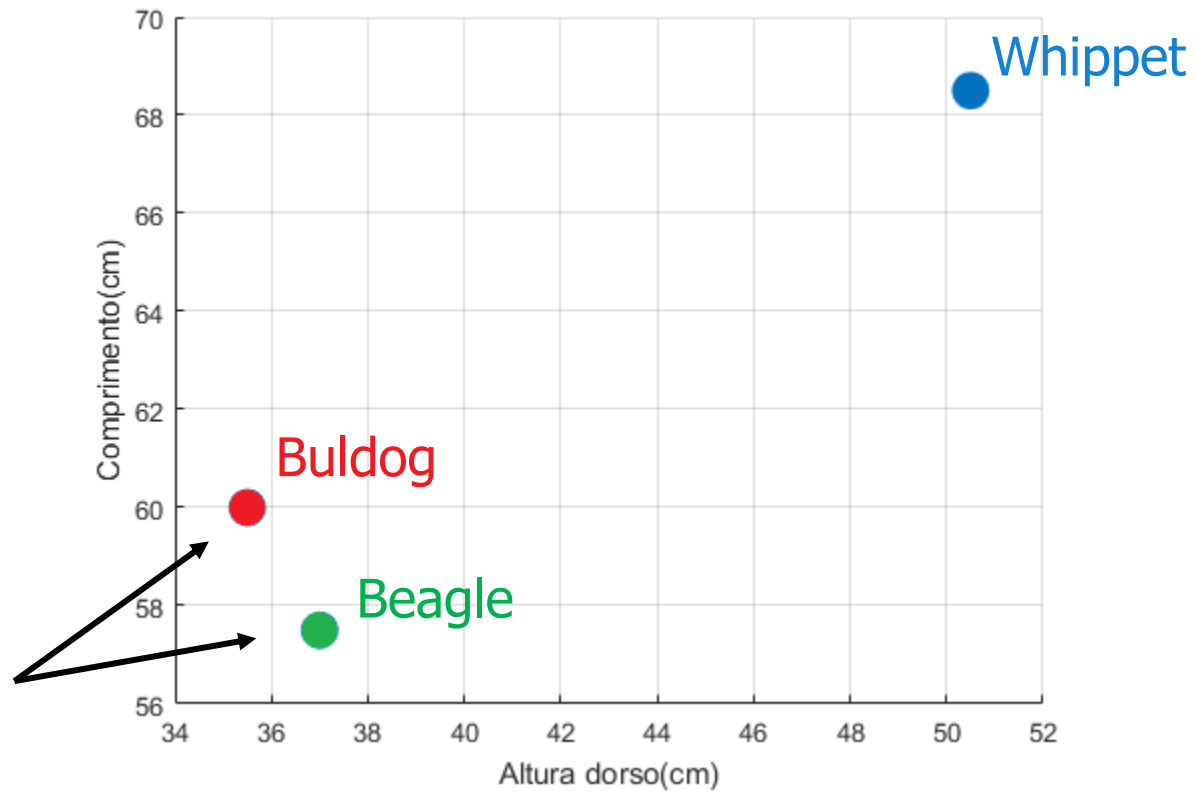


Whippet

Altura dorso	50,5 cm
Comprimento	68,5 cm

Os descritores são robustos para caracterizar uma nova raça?

- No espaço de atributos do vetor de característica:



Vetor de características com mais descritores



Bulldog




Beagle




Whippet

Exemplo:



Vetor de características



Médias de medidas de cada raça



Bulldog

Altura dorso	35,5 cm
Comprimento	60 cm
Peso	21,5 kg



Beagle

Altura dorso	37 cm
Comprimento	57,5 cm
Peso	10 kg

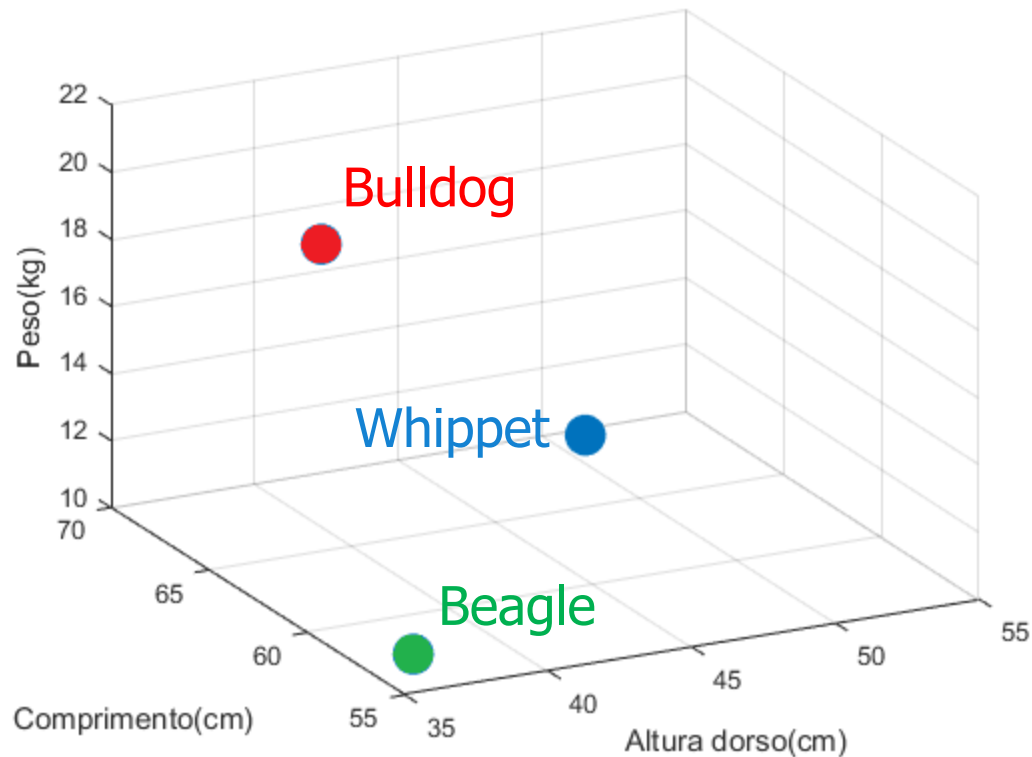


Whippet

Altura dorso	50,5 cm
Comprimento	68,5 cm
Peso	10,5 kg

Vetor de características com 3 descritores

- No espaço tridimensional de atributos do vetor de característica:



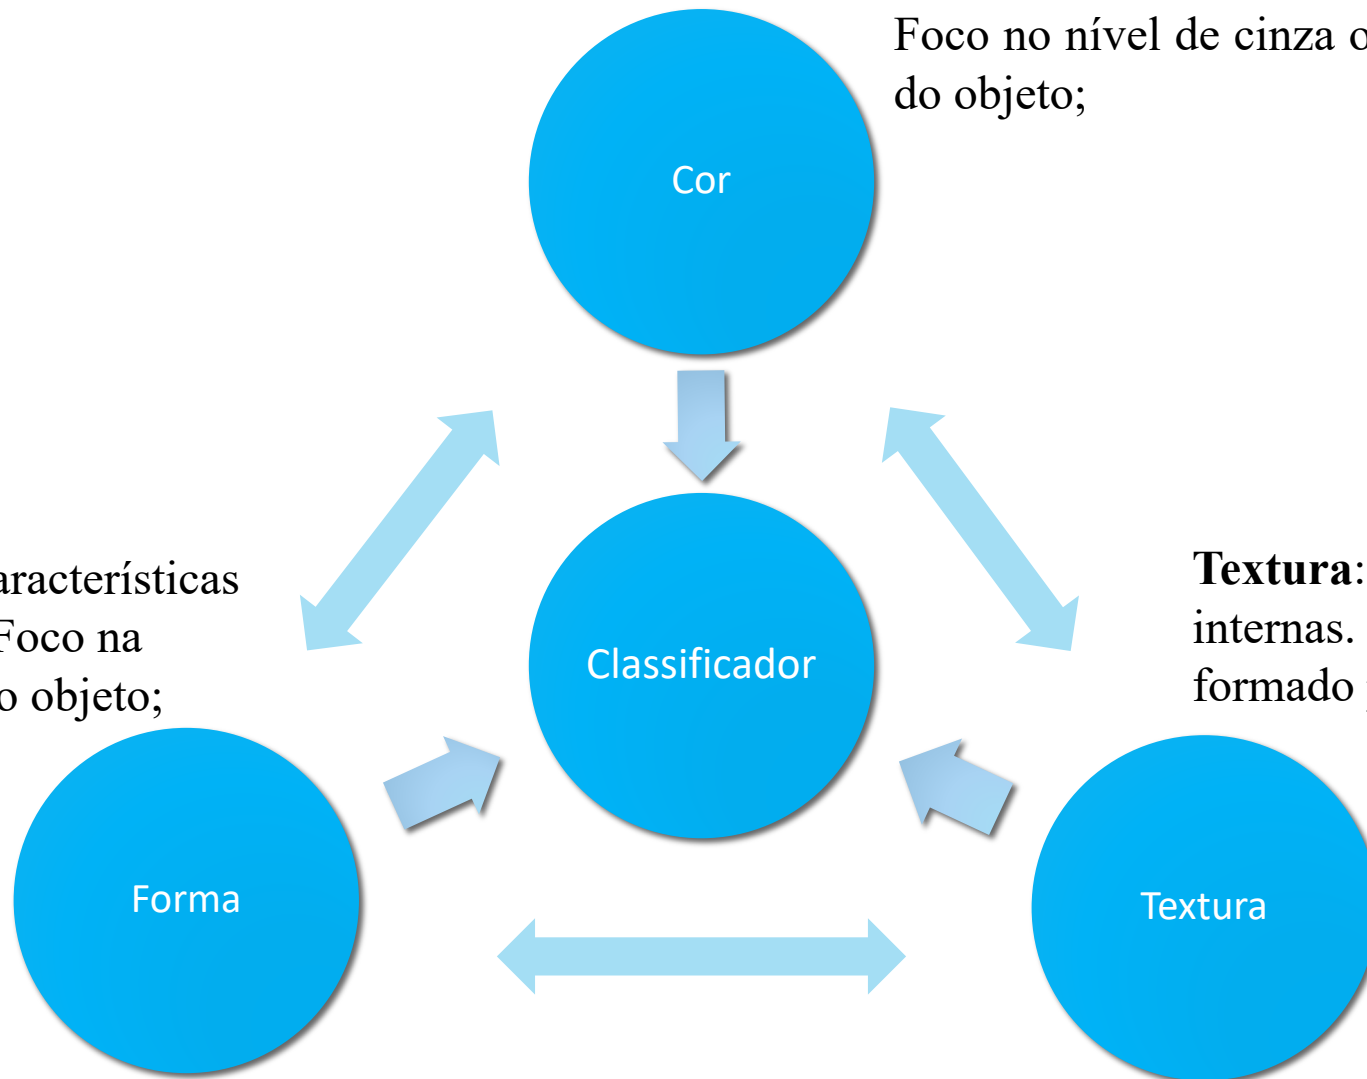
No espaço 3D as três raças são separadas em distintas regiões

Tipos de Descritores para Imagem

Cor: Características internas. Foco no nível de cinza ou cor do objeto;

Forma: Características externas. Foco na fronteira do objeto;

Textura: Características internas. Foco no padrão formado pela região.



Introdução

- ❑ Após a segmentação, os agrupamentos resultantes são usualmente **representados** por meio de dados em um formato apropriado chamado de **descritores**.
- ❑ A etapa de descrição é, em geral, mais importante do que a etapa de classificação:
 - ❑ Uso de descritores sofisticados em classificadores simples é preferível do que o oposto.
 - ❑ **Os descritores devem ser insensíveis à translação, rotação e mudança de escala**

Descritores



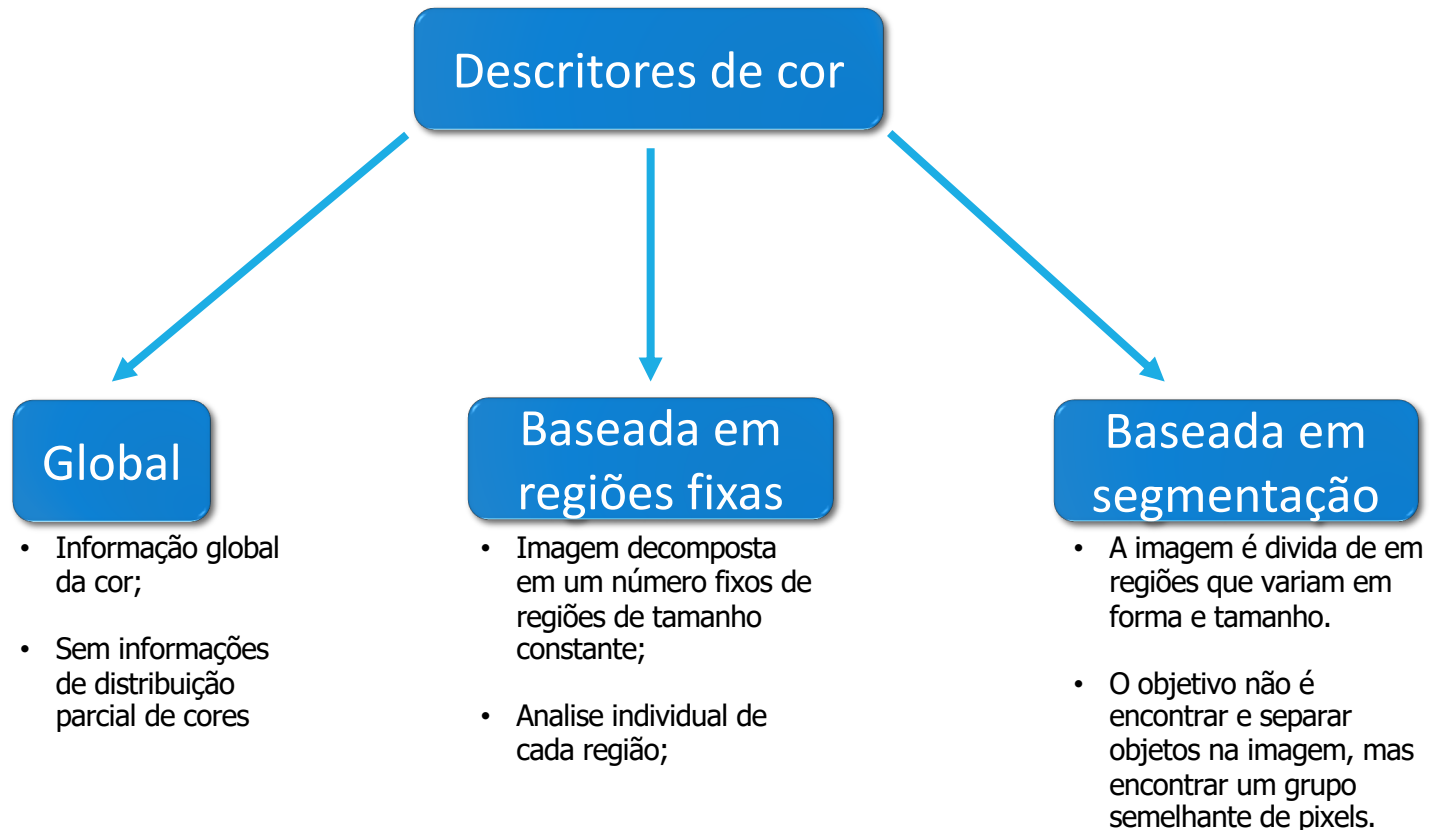
“Now! *That* should clear up a few things around here!”

Parte 1

Descritores de Cor

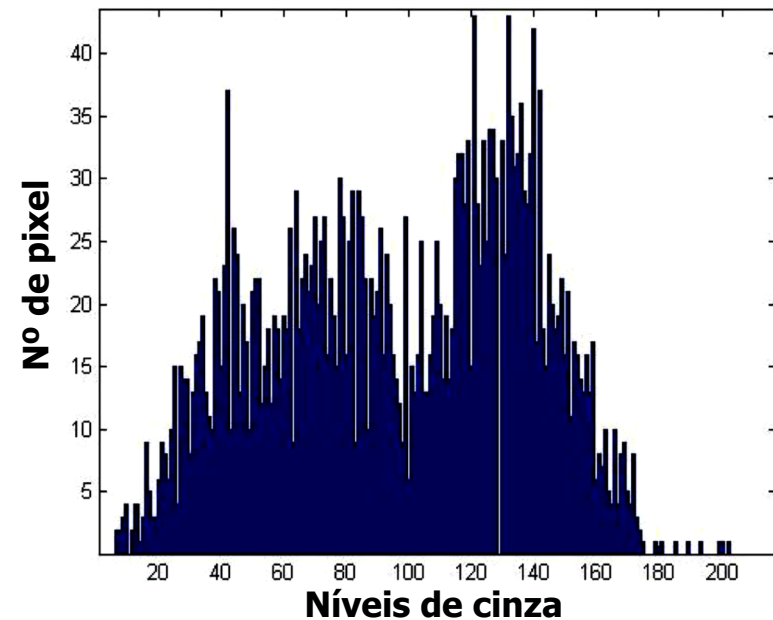
Descritores de cor

- Analisam as diversas cores presentes na imagem;
- Normalmente representam a distribuição de cor da imagem sem levar em conta informações espaciais:



Descritores de cor

- Distribuição de cor em uma imagem interpretada como uma distribuição de probabilidade (histograma):
- Tipos mais comum de descritor:
 - Coeficiente de variação
 - 1º momento (μ - média)
 - 2º momento (σ - Desvio padrão)
 - 3º momento (Obliquidade, ou *skewness*)
 - 4º momento (Curtose, ou *kurtosis*)



Momentos de cor

- Coeficiente de variação (CV)

$$CV = \frac{\sigma}{\mu}$$

- 1º momento (média)

$$\mu = \frac{1}{N} \sum_{j=1}^N f_{i,j}$$

Onde i é um canal de cor e j é um pixel da imagem f com N pixels.

- 2º momento (Desvio padrão)


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

Momentos de cor

A referência é a distribuição gaussiana (skewness = 0 e kurtosis = 0)


- 3º momento (Obliquidade, ou *skewness*)
 - Descritor da assimetria da distribuição de frequência

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



- 4º momento (Curtose, ou *kurtosis*)
 - Descritor da relação entre pico e achatamento da distribuição de frequência

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



Aplicação

- Identificação de ferrugem no café:



Folha de café saudável




Folha de café com ferrugem

Grande diferença em relação a cor amarela




Aplicação

- Identificação de ferrugem no café:
 - Analisando o sistema RGB e criação de **máscara binária para cada canal**
 - A ferrugem possui a coloração amarela
 - **Alta intensidade no canal R e G**
 - Alto valor de *Threshold* para os canais R e G
 - **Baixa intensidade no canal B**
 - Baixo valor de *Threshold* para o canal B



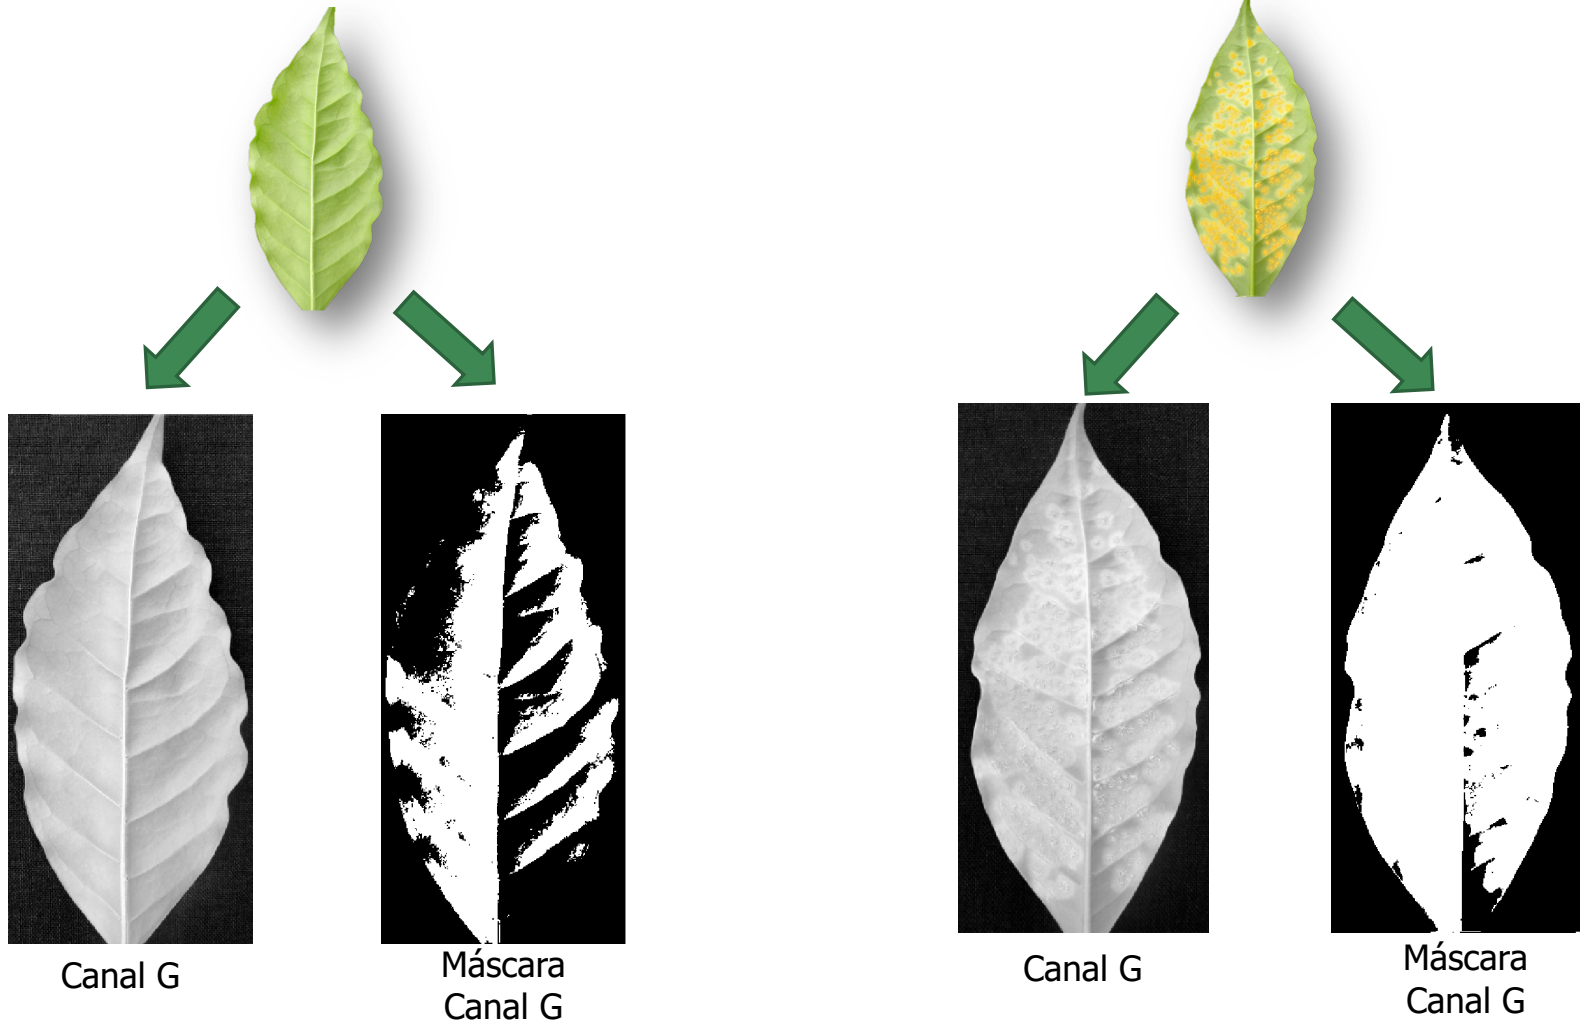
Aplicação

- Analisando cada canal RGB:




Aplicação

- Analisando cada canal RGB:



Aplicação

- Analisando cada canal RGB:



Aplicação

- Máscara final da folha saudável:



Máscara
Canal R

×




Máscara
Canal G

×



Complemento
Máscara Canal B


=



Máscara final

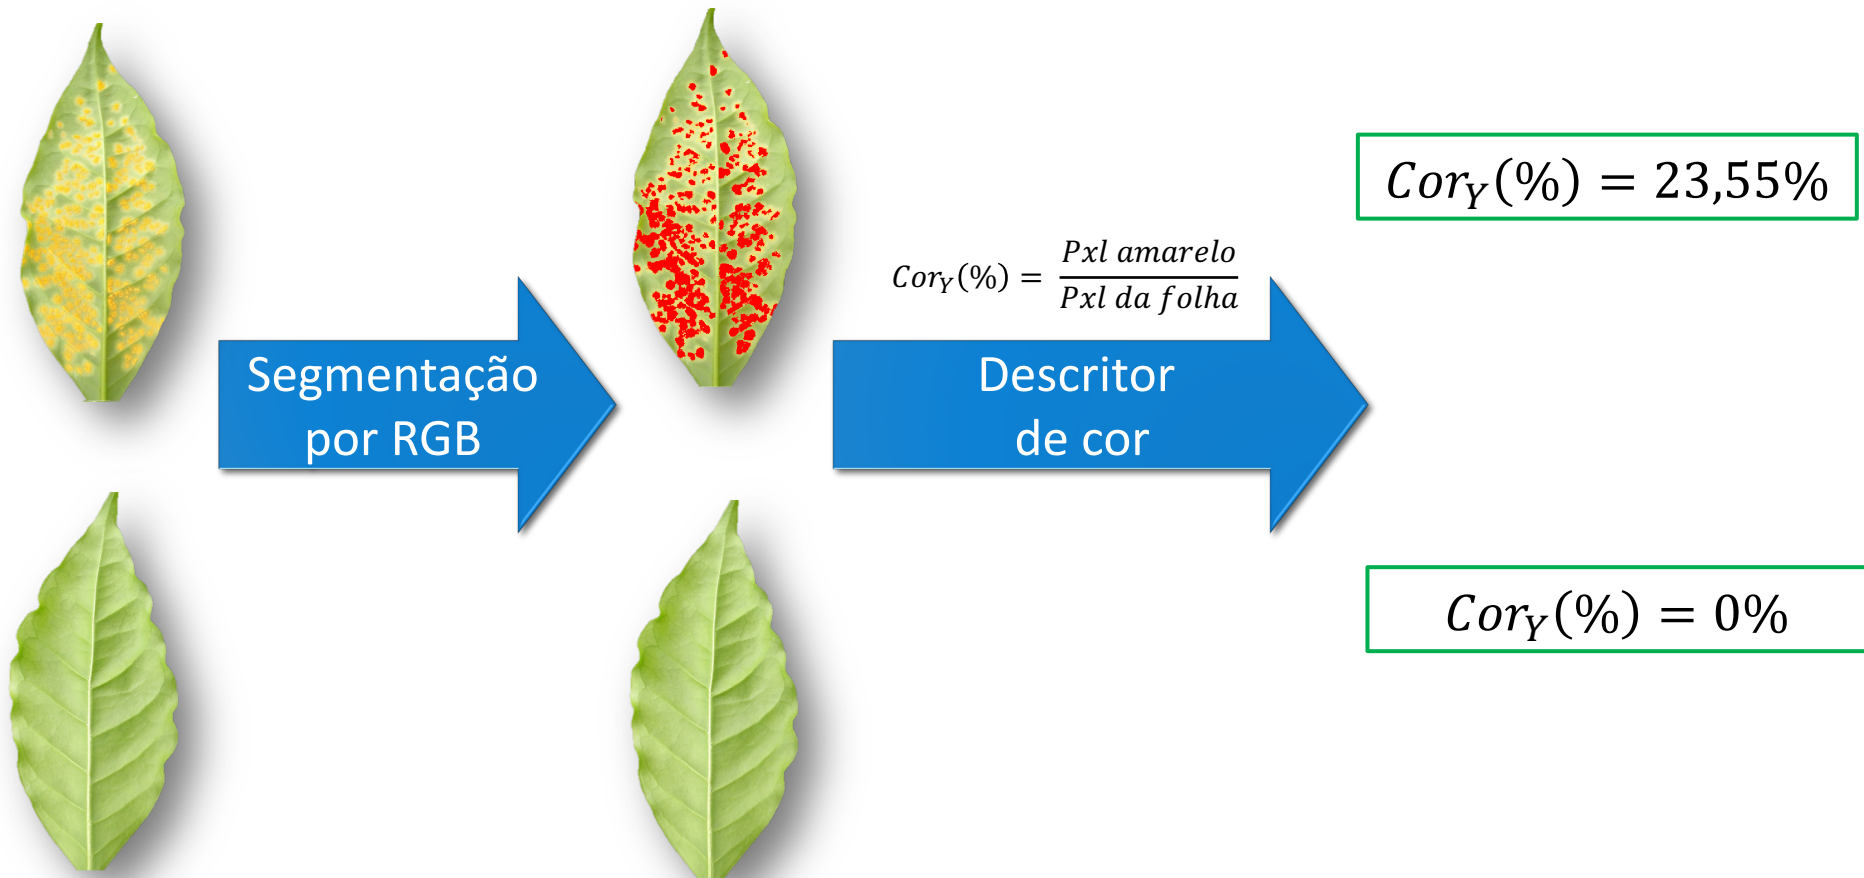
Aplicação

- Máscara final da folha com ferrugem:



Aplicação

- Identificação de ferrugem no café:
 - Aplicando o descritor de cor




Parte 2

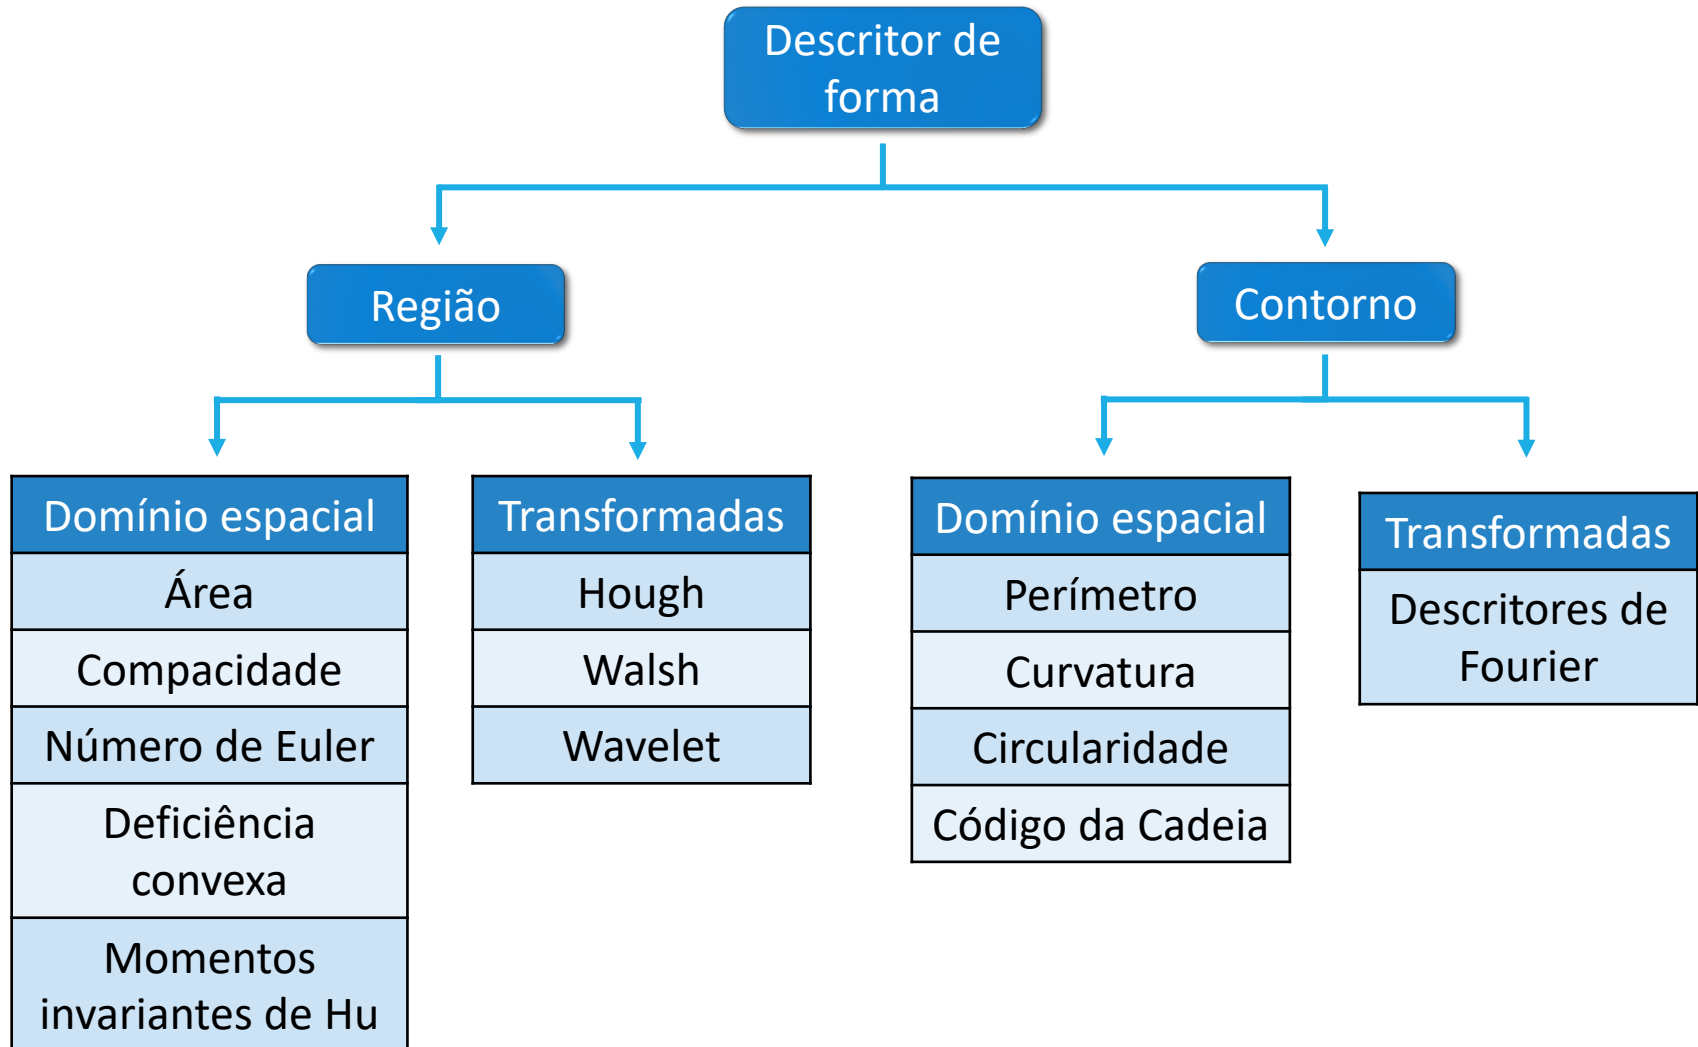
Descritores de Forma

Descritores de Forma

- Analisam as formas adquiridas na imagem;
 - Objetos em 3D representados em 2D.
- Alguns objetos possuem padrões de formas;
- Necessidade de noção de similaridade:



Descritores de Forma



Descritores de Forma

Região

Descritores de Forma: Região


- Área de uma região (A):

Corresponde ao número de pixels dentro da fronteira do objeto

- Compacidade (C):

Corresponde a razão entre o quadrado do perímetro com a área do objeto.


Exemplo:



$$A = 15$$

$$\text{Perímetro} = 20$$

$$C = \frac{\text{Perímetro}^2}{A} = 26,67$$



(a)



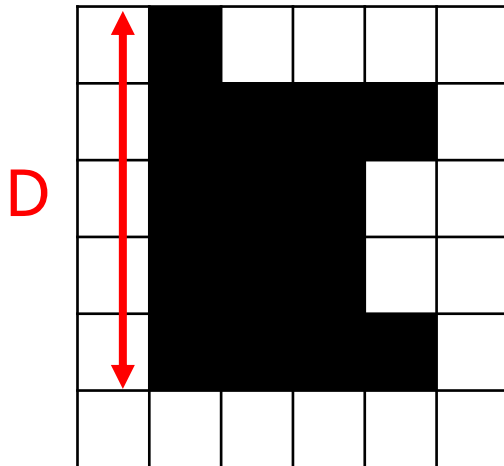
(b)

Compacidade. (a) objeto com baixa compacidade; (b) objeto com alta compacidade

Descritores de Forma

- Circularidade (Circ):
 - Corresponde o quão circular é a região
 - $Circ = \frac{100 \cdot \text{Área}}{\pi \cdot r^2}$, r corresponde a metade do maior eixo da imagem (D)

Exemplo:



$$\text{Área} = 15$$

$$D = 5$$

$$r = \frac{5}{2} = 2,5$$

$$Circ = \frac{100 \cdot \text{Área}}{\pi \cdot r^2} = \frac{100 \cdot 15}{\pi \cdot 2,5^2} = 76,39\%$$


Descritores de Forma

- Deficiência convexa (CD):

Corresponde a área que se precisa adicionar à imagem para que o objeto se torne convexo.

$$CD = \frac{RC - AO}{AO}$$

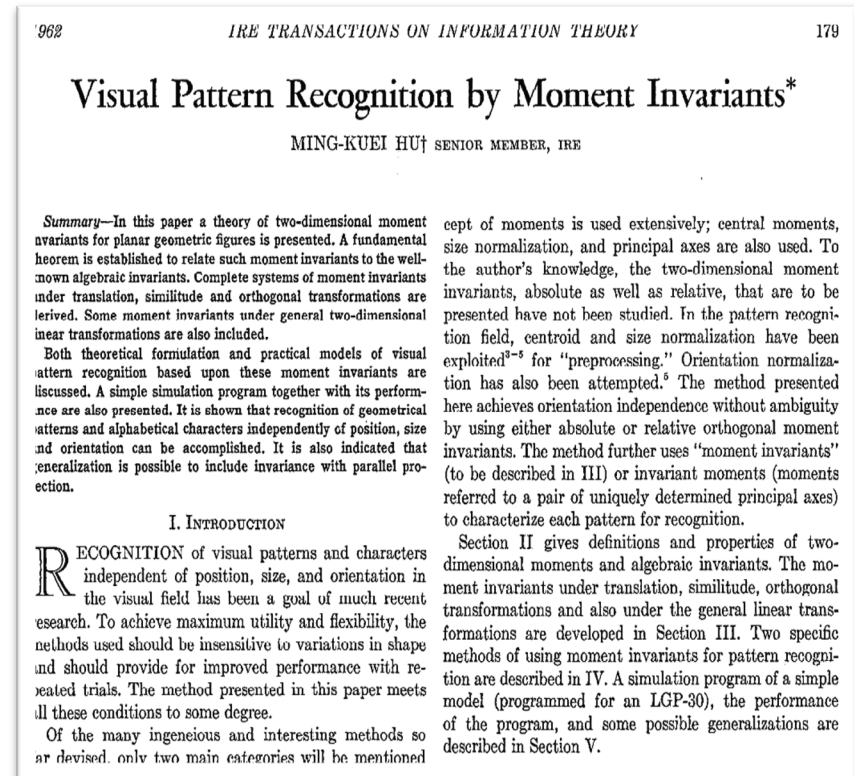
Região
convexa(RC)



Área do
objeto(AO)

Descritores de Forma

- Momentos invariantes de Hu:
 - Descrever a forma dos objetos na imagem;
 - Necessidade do descritor ser invariante à escala, rotação e translação;
 - Em 1962, o pesquisador Ming-Kuei Hu da Syracuse University propôs 7 momentos invariantes que servem como descritores;



Momentos

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

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

Momento 00 – Área da Região:

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

Momentos

Momentos 01 e 10: Coordenada por Área

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

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

Momentos Centrais Normalizados: Invariantes à escala!

São momentos centralizados em regiões e podem ser expressos como:

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

na qual:

$$\bar{x} = \frac{m_{10}}{m_{00}}$$

e

$$\bar{y} = \frac{m_{01}}{m_{00}}$$

são as coordenadas do **Centro de massa** da região

Versão discreta:

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

Momentos Centrais Até a Ordem 3

Ordem 0:

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

Ordem 1:

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

Ordem 2:

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

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

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

são
invariantes
com relação à
escala



Ordem 3:

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

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

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

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

Momentos Invariantes de Hu

Hu calculou 7 momentos*:

- invariantes à: translação, rotação e escala;

Momentos Centrais Normalizados pela área:

$$\eta_{pq} = \frac{\mu_{pq}}{\mu_{00}^\gamma} \quad \text{na qual,} \quad \gamma = \frac{p+q}{2} + 1 \quad \text{para } p+q = 2, 3, 4, \dots$$

Os 7 momentos de Hu são:

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

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

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

Momentos Invariantes de Hu


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

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

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

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

Exemplo



Momento invariante	Imagem original	Transladada	Redimensio- nada por 0,5	Espelhada	Rotacionada em 45°	Rotacionada em 90°
ϕ_1	2,8662	2,8662	2,8664	2,8662	2,8661	2,8662
ϕ_2	7,1265	7,1265	7,1257	7,1265	7,1266	7,1265
ϕ_3	10,4109	10,4109	10,4047	10,4109	10,4115	10,4109
ϕ_4	10,3742	10,3742	10,3719	10,3742	10,3742	10,3742
ϕ_5	21,3674	21,3674	21,3924	21,3674	21,3663	21,3674
ϕ_6	13,9417	13,9417	13,9383	13,9417	13,9417	13,9417
ϕ_7	-20,7809	-20,7809	-20,7724	20,7809	-20,7813	-20,7809

Descritores de Forma


Contorno

Representação de Fronteiras


Código da Cadeia (*Chain Code* ou Código de Freeman):

- Representam uma fronteira através de uma sequência conectada de segmentos, de direção e comprimento definidos.
- Deve-se inicialmente escolher a quantidade de direções a serem consideradas:

Código de 4 direções




Código de 8 direções




Exemplo: Código da Cadeia

Considerando 4 direções, temos o “gabarito”:



Verifica-se a **posição do próximo ponto em relação ao ponto atual**:

- Consultando o gabarito das direções, têm-se o código da transição.




- Código da cadeia: **0 3 0 3 2 2 1 1**.

Código da Cadeia: Limitações

Alto custo computacional:


- A verificação de todo um objeto ponto-a-ponto é muito lenta;

O algoritmo é suscetível a ruídos:




Solução:


- Re-amostrar a fronteira através de uma grade de amostragem de tamanho maior;
- Conforme a fronteira é percorrida, um ponto é atribuído a cada nó da grade em função da sua proximidade:




Código da Cadeia: Exemplo



Grade de reamostragem




4 direções:




ou

8 direções:




Código de 4 direções:



ou

Código de 8 direções:



0033333323221211101101

07666553321212

Código da Cadeia: Exemplo




Figura 11.5 (a) Imagem ruidosa. (b) Imagem suavizada com uma máscara de média 9×9 . (c) Imagem suavizada após a limiarização utilizando o método de Otsu. (d) Borda maior externa de (c). (e) Fronteira subamostrada (os pontos são mostrados ampliados para maior clareza). (f) Pontos conectados a partir de (e).

Normalização do Código da Cadeia

O Código da Cadeia de uma dada fronteira depende de uma origem e, portanto, não é invariante à rotação;

A solução é normalizar o código para que independa da origem:


Primeira Diferença ou Derivativo do Código da Cadeia

são
invariantes
com relação à
rotação




Primeira Diferença ou Derivativo do Código da Cadeia

1. Considerar o Código da Cadeia de forma “circular”, ou seja, fechado em suas extremidades.
2. Montar o **Código Derivativo** de acordo com a **distância** no **sentido anti-horário**:




4 direções



8 direções

Exemplo: 4 direções




Código da Cadeia:

0033333323221211101101


1 ⇒ 0 → 3

Código Derivativo

3 0 3 0 0 0 0 0 3 1 3 0 3 1 3 0 0 3 1 0 3 1



Exemplo: 8 direções




Código da Cadeia

076666553321212

$$2 \Rightarrow 0 = 6$$

Código Derivativo

6 7 7 0 0 0 7 0 6 0 7 7 1 7 1




Número do Formato (*Shape Numbers*)

O **Número do Formato da fronteira** é definido como:

- O menor número formado através da Rotação do Derivativo.

Ordem n do Número do Formato é definida como:

- O número de dígitos para representá-lo;
- n é par para fronteiras fechadas.



Ordem 4



Código da Cadeia:



0 3 2 1

Derivativo:


3 3 3 3

Número do Formato:


3 3 3 3



Código da Cadeia: 0 0 3 2 2 1
 Derivativo: 3 0 3 3 0 3
 Número do Formato: 0 3 3 0 3 3



Código da Cadeia: 0 0 3 3 2 2 1 1
 Derivativo: 3 0 3 0 3 0 3 0
 Número do Formato: 0 3 0 3 0 3 0 3



Código da Cadeia: 0 3 0 3 2 2 1 1
 Derivativo: 3 3 1 3 3 0 3 0
 Número do Formato: 0 3 0 3 3 1 3 3





Código da Cadeia: 0 0 0 3 2 2 2 1
 Derivativo: 3 0 0 3 3 0 0 3
 Número do Formato: 0 0 3 3 0 0 3 3

Assinaturas


Representação unidimensional de uma fronteira em coordenadas polares:

Exemplo:

- Gráfico da **Distância do centro de massa vs. ângulo**:



Assinaturas - Exemplos



Aplicação

- Deficiência nutricional das plantas em plantas de café:



Folha de café com
Deficiência de Boro





Folha de café com
deficiência de Cálcio

**Grande diferença em
relação a forma**



Aplicação

- Deficiência nutricional das plantas em plantas de café:



Deficiência	Boro	Cálcio
Perímetro	469,75	611,2
Área	15516	18412
Compacidade	14,22	20,29
Circularidade	83,15	58,84

Parte 3

Descritores de Textura


Descritores de Textura

- Definição [1] :

“Uma imagem com textura pode ser descrita pelo número e tipos de suas primitivas e pela organização espacial ou layout de suas primitivas. [...] Esta dependência pode ser estrutural, probabilística ou funcional.”

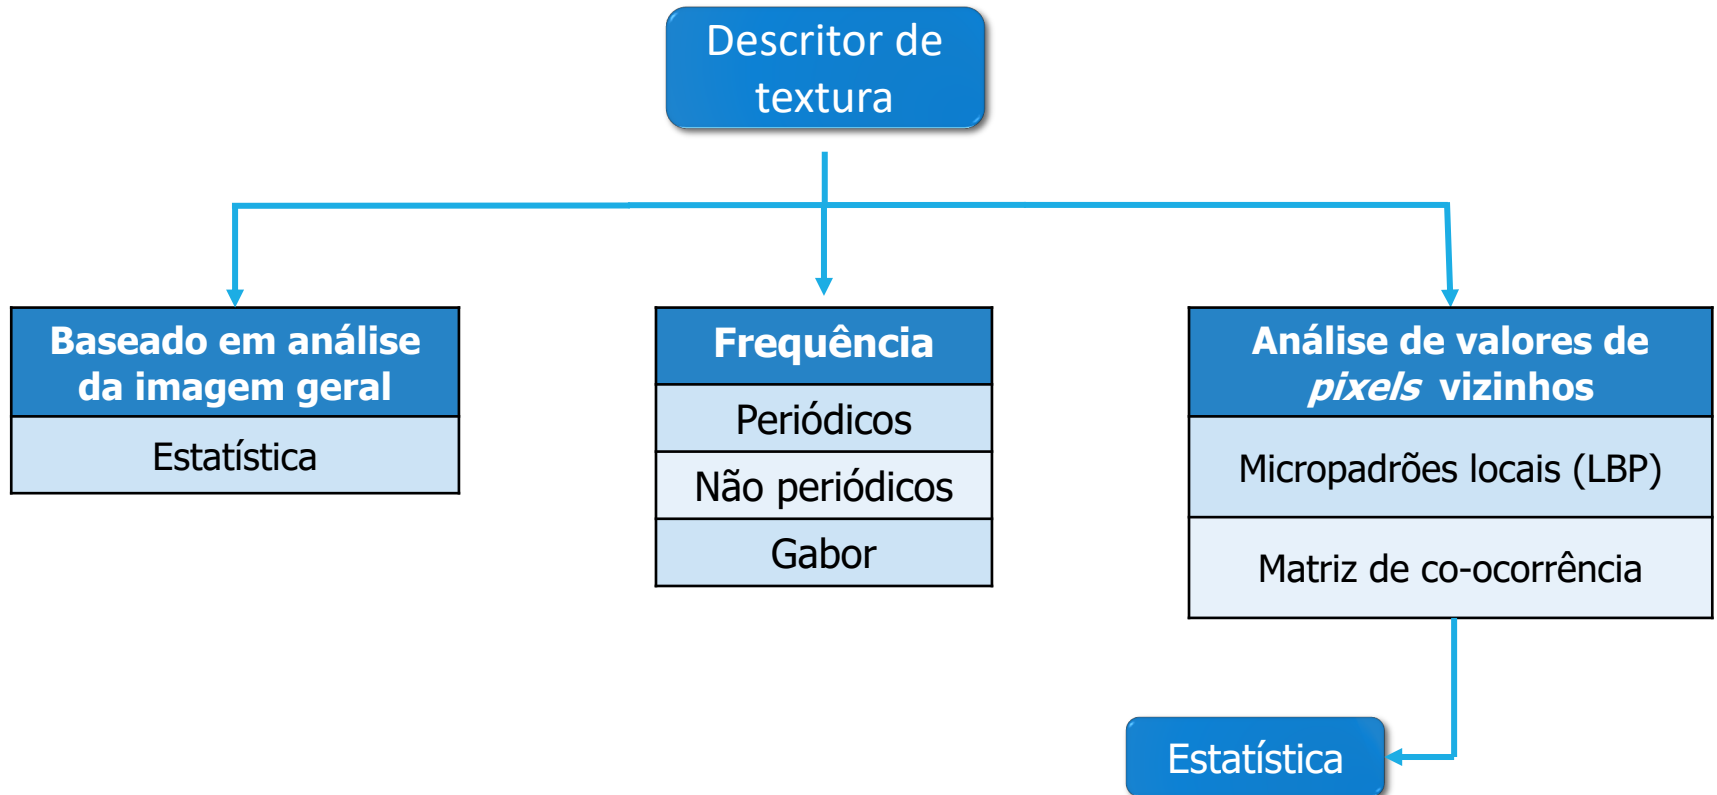
Características

- ✓ aspereza
- ✓ regularidade
- ✓ uniformidade
- ✓ densidade
- ✓ intensidade
- ✓ granulosidade
- ✓ suavidade



Algumas imagens da base de textura KTH-TIPS2

Descritores de Textura



Descritores de Textura – Estatística


- Medidas baseadas na distribuição do nível de cinza (avaliação de histograma):
 - Média;
 - Variância e desvio padrão (σ ou σ^2);
 - Terceiro momento (obliquidade - *skewness*):
 - Mede o grau de assimetria do histograma
 - Quarto momento (curtose):
 - Grau de achatamento da distribuição em relação a distribuição gaussiana (zero)
 - Uniformidade:
 - Indica o quanto a região possui um nível de intensidade constante
 - Entropia:
 - Avalia a aleatoriedade das intensidades da região.

Descritores de Textura – Estatística


Suave:



Rugosa:



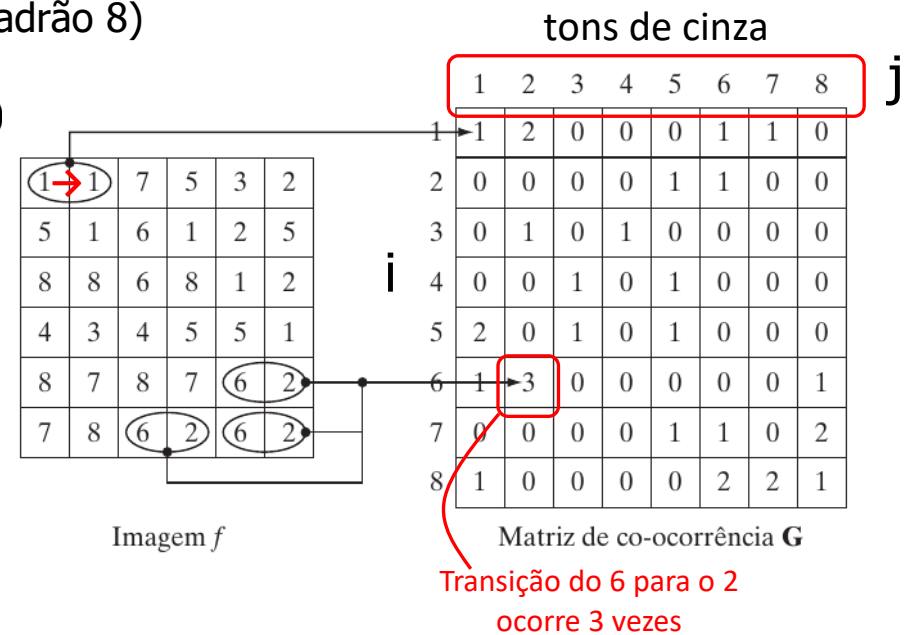

Regular:



Textura	Média	Desvio padrão	R (normalizado)	Terceiro momento	Uniformidade	Entropia
Suave	82,64	11,79	0,002	-0,105	0,026	5,434
Rugosa	143,56	74,63	0,079	-0,151	0,005	7,783
Regular	99,72	33,73	0,017	0,750	0,013	6,674

Descritores de Textura – Análise de vizinhos (GLCM)

- Matriz de co-ocorrência^[1]:
 - Referenciada como **GLCM**: Matriz de Co-Ocorrência de Tons de Cinza
 - Cada célula da matriz funciona como um contador de quantas vezes o nível de intensidade i e o nível j estão presentes na imagem separados por uma distância d
 - Parâmetros:
 - Quantos níveis de quantização (padrão 8)
 - Posição do vizinho
 - Raio da vizinhança (1 por padrão)



Exemplo de GLCM com raio 1 e posição do vizinho: →

Descritores de Textura – Estatísticas na GLCM

- Haralick *et al.* (1973), com o objetivo de descrever as propriedades contidas nas texturas, definiu um conjunto de 14 medidas estatísticas a serem calculadas a partir das matrizes de co-ocorrência.
- Baraldi e Parmiggiani^[2] mostraram que apenas **6** eram mais relevantes:

- Segundo momento angular (uniformidade) $f_1 = \sum_i \sum_j \{p(i,j)\}^2$

- Contraste $f_2 = \sum_{n=0}^{N_g-1} n^2 \left\{ \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p(i,j) \right\}$

- Correlação (dependência linear de *pixels* em relação à sua vizinhança) $f_3 = \frac{\sum_i \sum_j (ij)p(i,j) - \mu_x \mu_y}{\sigma_x \sigma_y}$

- Variância $f_4 = \sum_i \sum_j (i - \mu)^2 p(i,j)$

- Homogeneidade $f_5 = \sum_i \sum_j \frac{p(i,j)}{1 + (i-j)^2}$

- Entropia $f_6 = - \sum_i \sum_j p(i,j) \log\{p(i,j)\}$


[1] Haralick, et al., **IEEE Trans. on Systems, Man, and Cybernetics**, vol. SMC-3, no. 6, pp. 610-621, 1973. doi: 10.1109/TSMC.1973.4309314

[2] BARALDI, A.; PARMIGGIANI, F. An Investigation of the Textural Characteristics Associated with Gray Level Co-occurrence Matrix Statistical Parameters. *IEEE Transactions on Geoscience and Remote Sensing*, v. 33, n. 2, p.293-304, 1995.

Descritores de Textura - Estatísticas na GLCM




Contraste: 1,5975
Correlação: 0,5626
Energia: 0,0525
Homogeneidade: 0,6340



Contraste: 1,3413
Correlação: 0,8674
Energia: 0,1346
Homogeneidade : 0,7895

Contraste: 0,3045
Correlação: 0,9157
Energia: 0,4517
Homogeneidade : 0,8975







Descritores de Textura - Gabor

- Filtros de Gabor:

- Filtro passa banda: seleciona regiões que tem uma direção e tamanho preferencial
- Detecta padrões em diferentes frequências e orientações
- Multiplicação de uma superfície gaussiana por uma senóide


$$g(x, y) = \frac{1}{2\pi\sigma_x\sigma_y} \exp \left[-\frac{1}{2} \left(\frac{x^2}{\sigma_x^2} + \frac{y^2}{\sigma_y^2} \right) + 2\pi j W x \right]$$




Varia-se os parâmetros para alterar o tamanho do filtro, frequência e orientação

Descritores de Textura - Gabor



Imagem de mamografia



Magnitude após filtragem com diversos filtros de Gabor



Campo de orientações



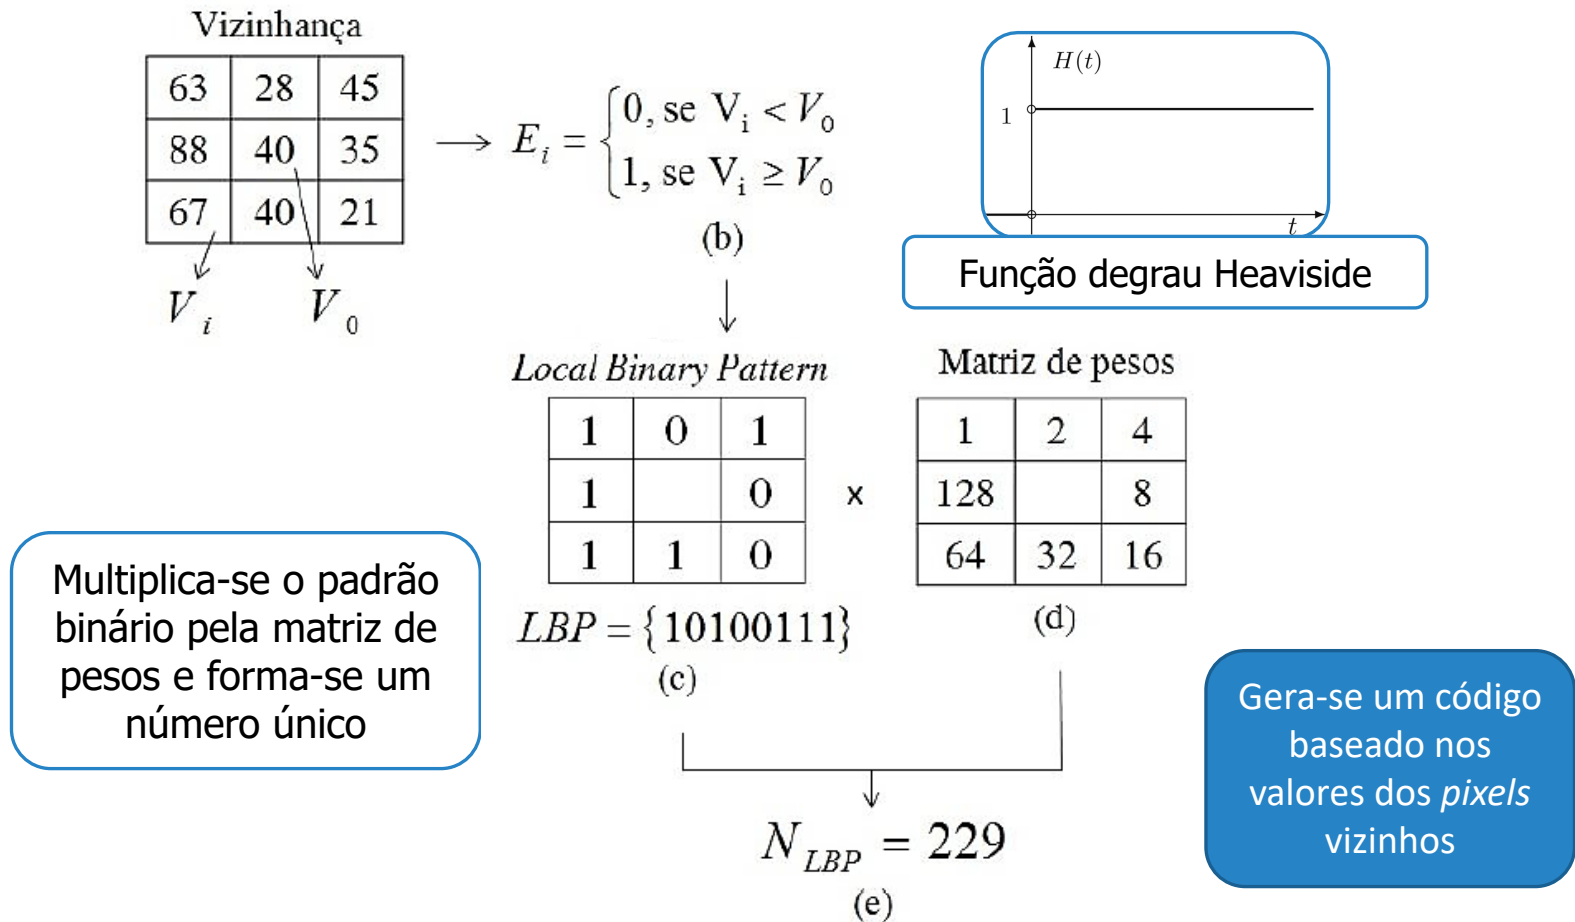
Utilização de filtros de Gabor para detectar orientação de linhas/estruturas

Descritores de Textura – Micropadrões Locais

- Baseiam-se na análise de pequenas vizinhanças de forma a representar padrões de textura
- Cada método possui diversas variantes
- Exemplos:
 - Unidades de Textura (*Texture Unit*)
 - *Local Binary Pattern* (LBP)
 - *Local Mapped Pattern* (LMP)

Descritores de Textura – Micropadrões Locais

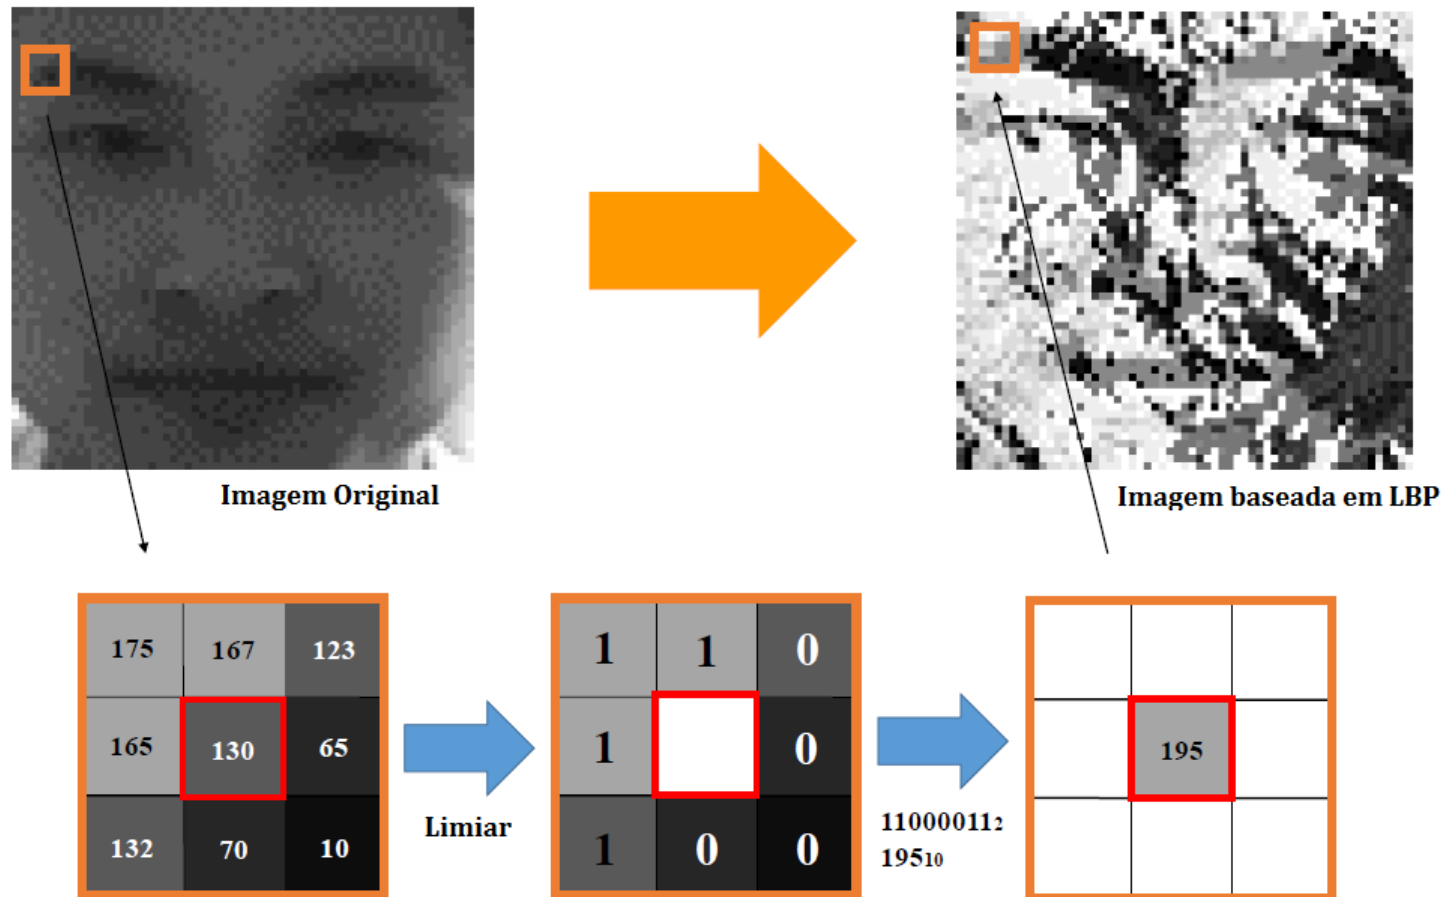
- *Local Binary Pattern* (LBP)^[1]
- Limiarização com 2 níveis ($2^8 = 256$ códigos de unidades de textura)



[1] OJALA, Timo; PIETIKÄINEN, Matti; HARWOOD, David. A comparative study of texture measures with classification based on featured distributions. **Pattern recognition**, v. 29, n. 1, p. 51-59, 1996.

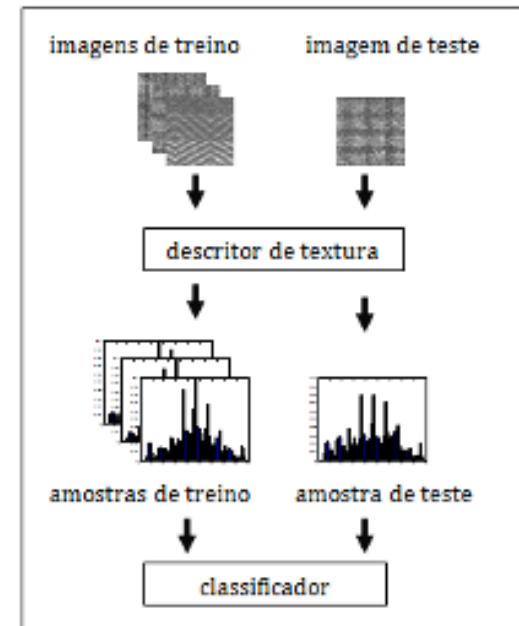

Descritores de Textura – Micropadrões Locais

- LBP











Descritores de Textura – Micropadrões Locais

- LBP
- A **descrição global** também é obtida por meio de um histograma de ocorrências de cada unidade
- A primeira versão não possui invariância à rotação, pois o mesmo padrão rotacionado gera diferentes códigos



Descritores de Textura – Micropadrões Locais

- LBP – O descritor é retirado dos valores do histograma de padrões




Imagens de entrada

Matriz de códigos LBP


Histograma LBP normalizado

Descritores de Textura – Micropadrões Locais

- Variantes do LBP:
 - LBP Circular



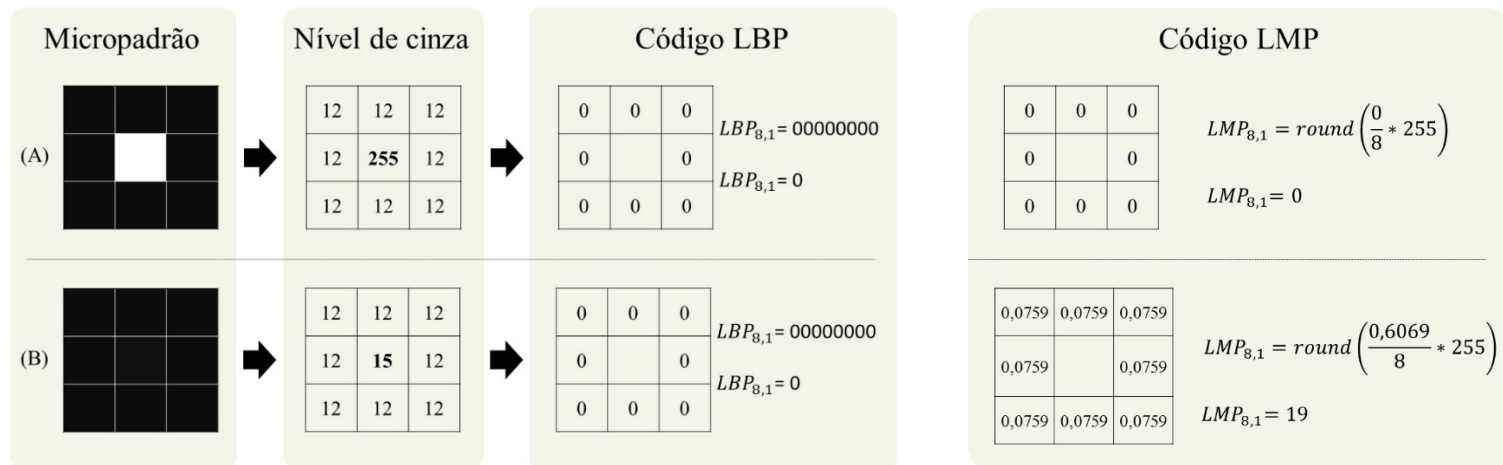
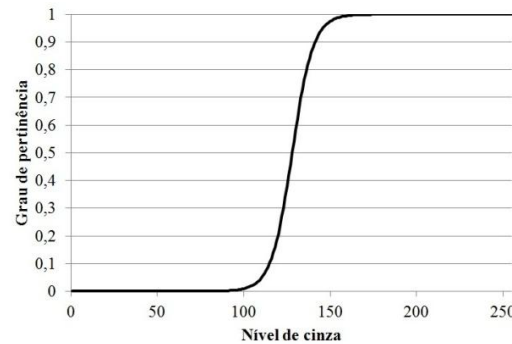
- RLBP (*Rotated* LBP): Pesos são associados de acordo com a direção dominante



[1] MEHTA, Rakesh; EGIAZARIAN, Karen O. Rotated Local Binary Pattern (RLBP)-Rotation Invariant Texture Descriptor. In: **ICPRAM**. 2013. p. 497-502.

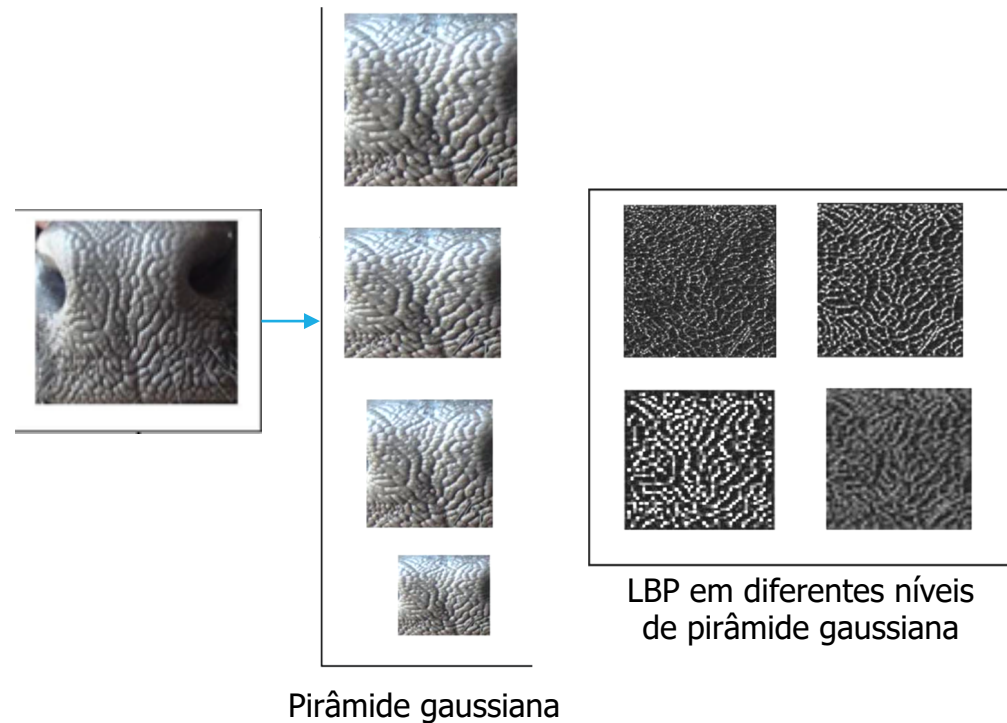

Descritores de Textura – Micropadrões Locais

- Variantes do LBP:
 - *Local Mapped Patterns* (LMP): Comparação entre *pixels* é modelada por uma função sigmoide que admite valores intermediários entre 0 e 1



Descritores de Textura – Micropadrões Locais

- Exemplo de aplicação:
 - Detecção de micro padrões em focinhos de gado para identificação do animal, como uma “impressão digital”^[1]




Exemplo de aplicação de descritores:

- Fratura de compressão vertebral (VCF)
 - VCF é o tipo mais comum de fratura osteoporótica;
 - Os idosos apresentam alta incidência de VCF's relacionadas ao câncer metastático que afeta os ossos;
 - A ressonância magnética é o método de imagem mais utilizado para doenças da coluna vertebral e detecção precoce de fraturas;
 - Existem 3 tipos de classificação para o exame de vértebra do paciente:
 1. Normal;
 2. VCF benigno;
 3. VCF maligno.

Situação problema

- Exemplos de 3 imagens de Ressonância Magnética de colunas diferentes:



Normal

VCF benigno

VCF maligno

1. Qual descritor é mais indicado para separar a coluna Normal e VCF?
2. Qual descritor é mais indicado para separar a VCF benigno e VCF maligno?



Situação problema

- Fratura de compressão vertebral (VCF):
 - Utilizou-se 27 descritores (cor, textura e forma).
- 1. Qual descritor é mais indicado para separar a coluna Normal e VCFs?**
 - Descritores de Forma:

Descritor
Compacidade
Deficiência convexa
Momento Hu (M1)
Momento Hu (M2)
Momento Hu (M3)
Momento Hu (M4)

Situação problema

- Fratura de compressão vertebral (VCF):
 - Utilizou-se 27 descritores (cor, textura e forma).
- 2. **Qual descritor é mais indicado para separar a VCF benigno e VCF maligno?**
 - **Descritores de Textura** e cor;

Descritor
<i>Skewness</i>
<i>Kurtosis</i>
Haralick (H4)
Haralick (H7)
Haralick (H10)
Haralick (H11)

FIM