

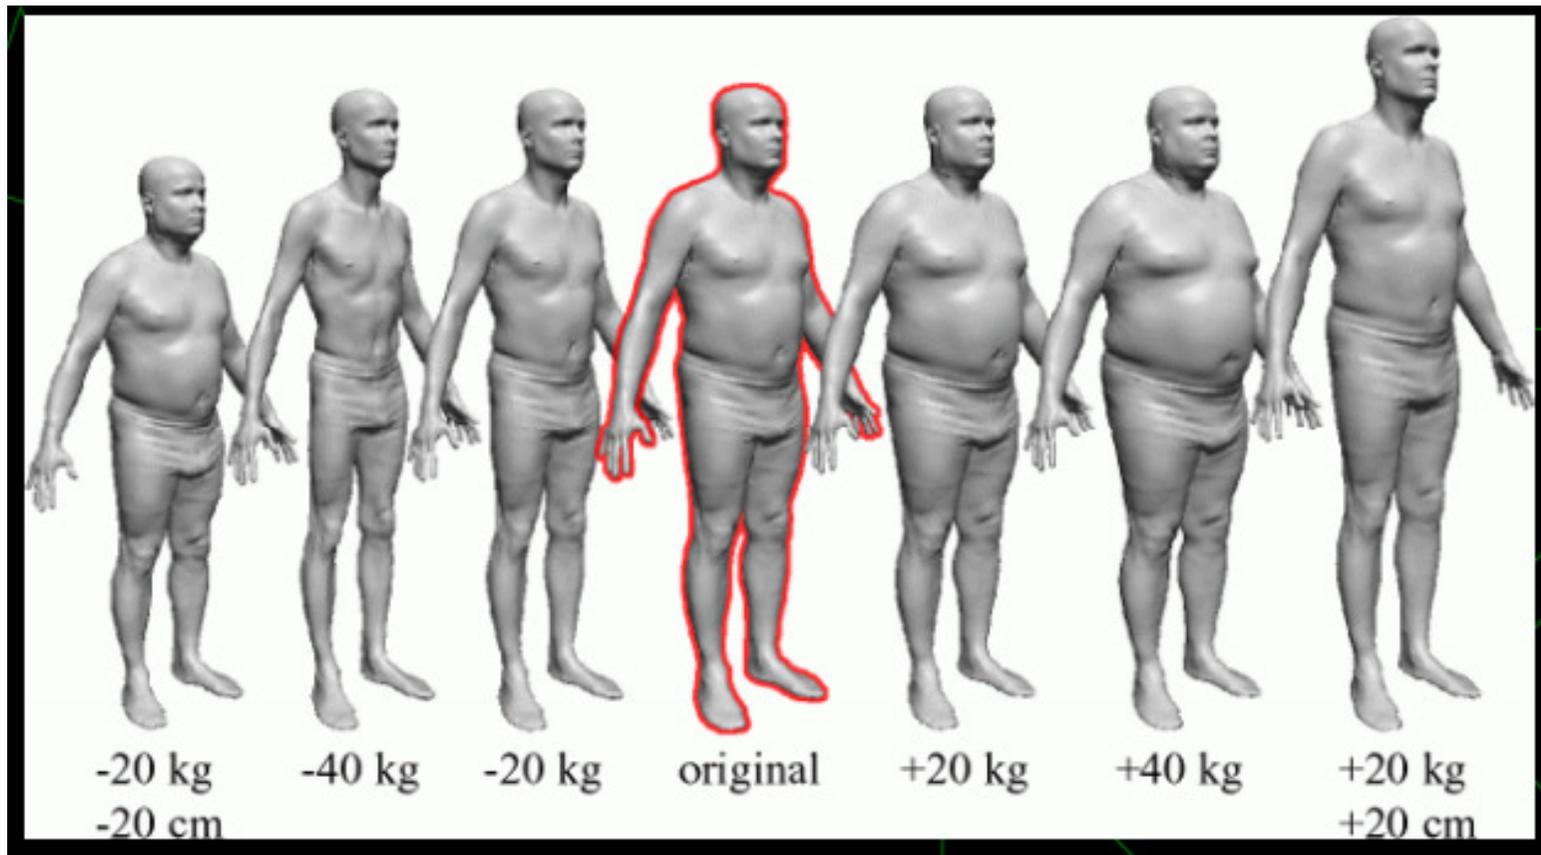


Tema 2 – Texturas e como caracteriza-las nas Imagens

Análise de Imagens - 2020

UFF

O que caracteriza uma coisa?



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

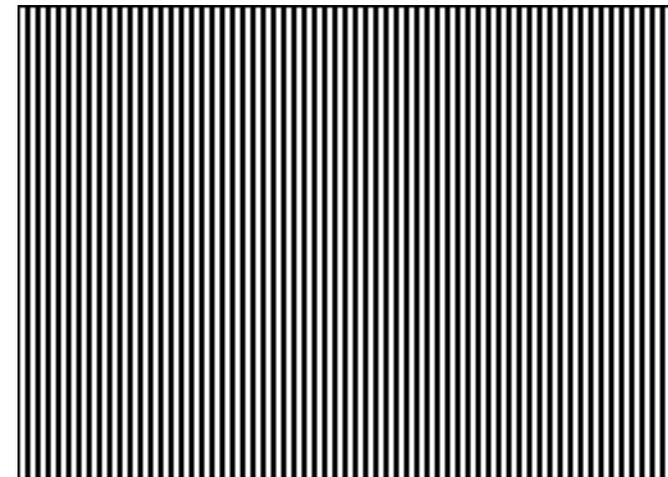
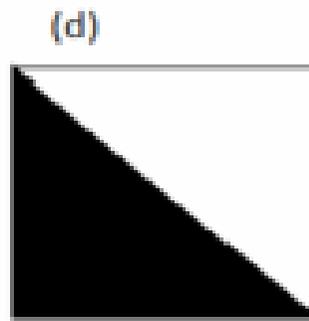
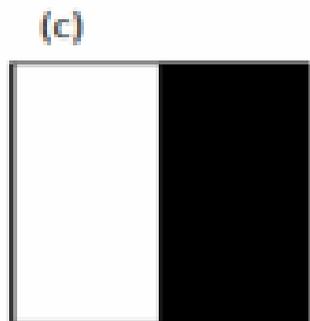
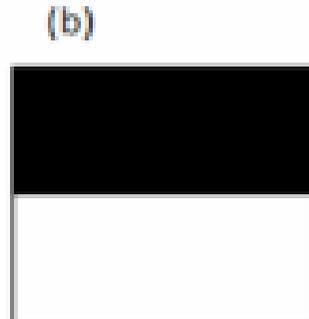
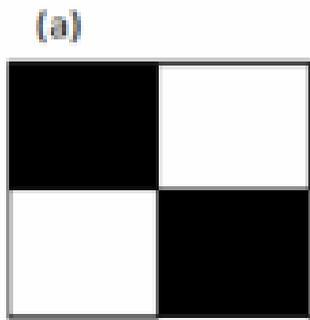
$$\text{variância} = \frac{\sum_{i=1}^N (m - x_i)^2}{N - 1}$$

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

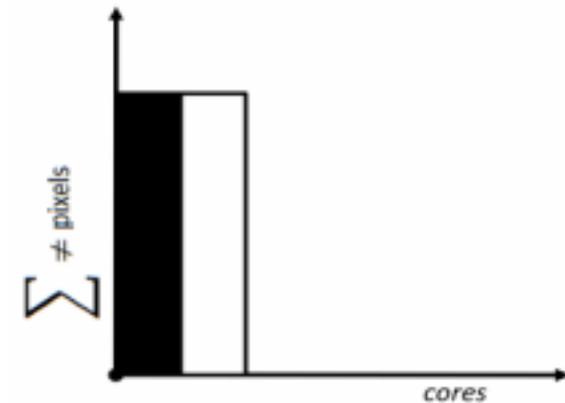


5 imagens com mesmo histograma

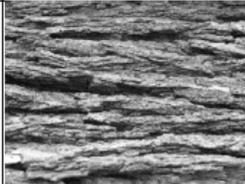
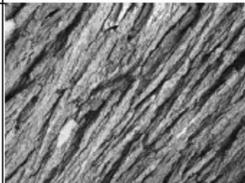
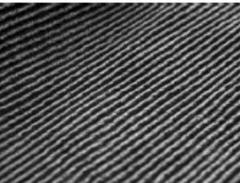
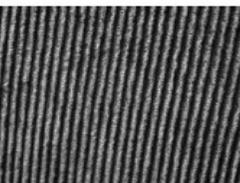
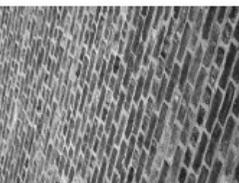
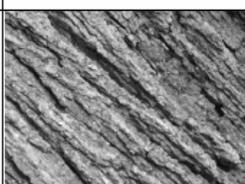
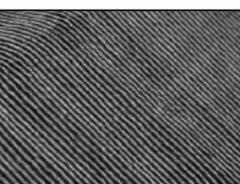
Coisas baseados no histograma são boas mas não identificam unicamente uma imagem!



(e)



Diversas
imagens com
mesmo número
de tons podem
ter o mesmo
histograma
como essas
Texturas de
Lazebnik

Âng.	Texturas		
	<i>Casca de Árvore</i>	<i>Veludo</i>	<i>Tijolos</i>
0°	 Textura 40	 Textura 44	 Textura 48
45°	 Textura 41	 Textura 45	 Textura 49
90°	 Textura 42	 Textura 46	 Textura 50
135°	 Textura 43	 Textura 47	 Textura 51

DEFINIÇÕES DE TEXTURA

Padrão visual :

- que possui algumas propriedades de **homogeneidade** que não resultam simplesmente de uma cor ou intensidade.
- constituído de **elementos mutuamente relacionados** (**pode ou não** depender de escala) .
- composto de um grande número de **elementos similares** mais ou menos ordenados.
- relacionada com **uniformidade, densidade, aspereza, regularidade, intensidade**, dentre outros, oriundos de ocorrência de variações tonais.

TEXTURAS PODEM SER:

- Descritas por medidas que quantificam suas propriedades de suavidade, rugosidade e regularidade.
- Identificadas por **características estatísticas** ou propriedades estruturais locais **constantes**, com **pouca variação** ou aproximadamente **periódicas**.
- Relacionadas à **variação de intensidade luminosa** em partes das imagens.

APLICAÇÕES das TEXTURAS

- **Segmentação** ou divisão de uma imagem em regiões.
- **Descrição** de regiões.
- **Classificação e rotulação** de uma região.
- **Análise de forma.**
- **Réplica** para caracterizar superfícies (síntese de imagens) .



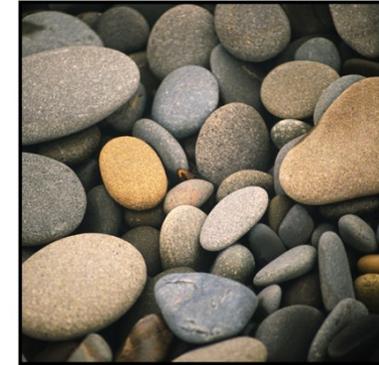
a) Água



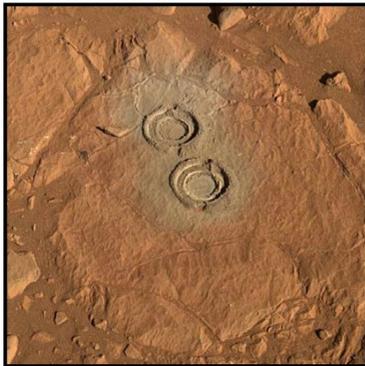
b) Folhas



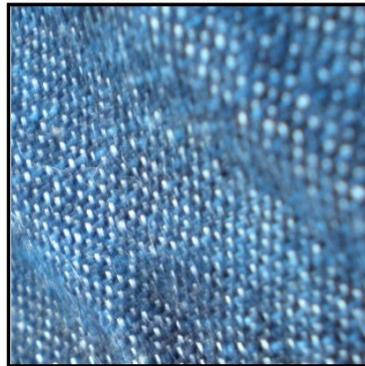
c) Madeira



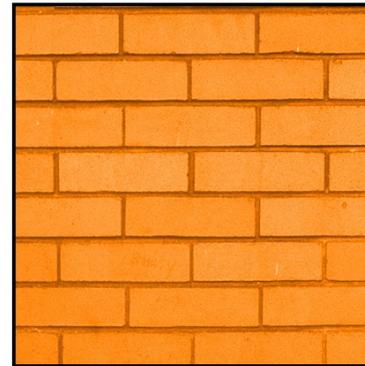
d) Pedra



e) Solo



f) Tecido



g) Tijolos



h) Vegetação

Exemplos de texturas naturais (a,b,c,d,h) e artificiais (e,f,g).

Textura

- Além de classificação, características de textura são bastante utilizadas na recuperação de informação.
 - Imagens médicas;
 - Imagens de satélite;
 - Navegação em um ambiente;
 - E diversas outras aplicações

Objetivo das Features de Texturas

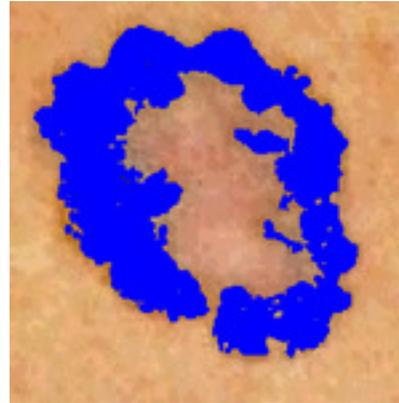
Encontrar numeros para com eles identificar (quantizar) os padrões de homogeneidade (ou outras características qualitativas) que não estão presentes em uma simples cor ou intensidade.

Os tipos de feaures dependem dos métodos usados.

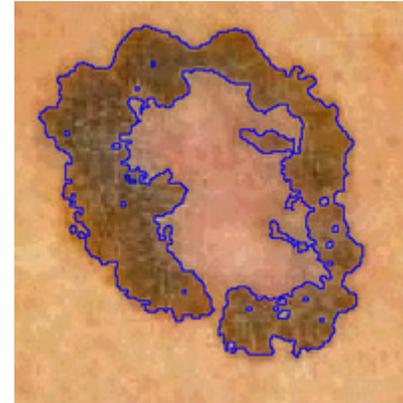
Exemplos de aplicações reais



(a)



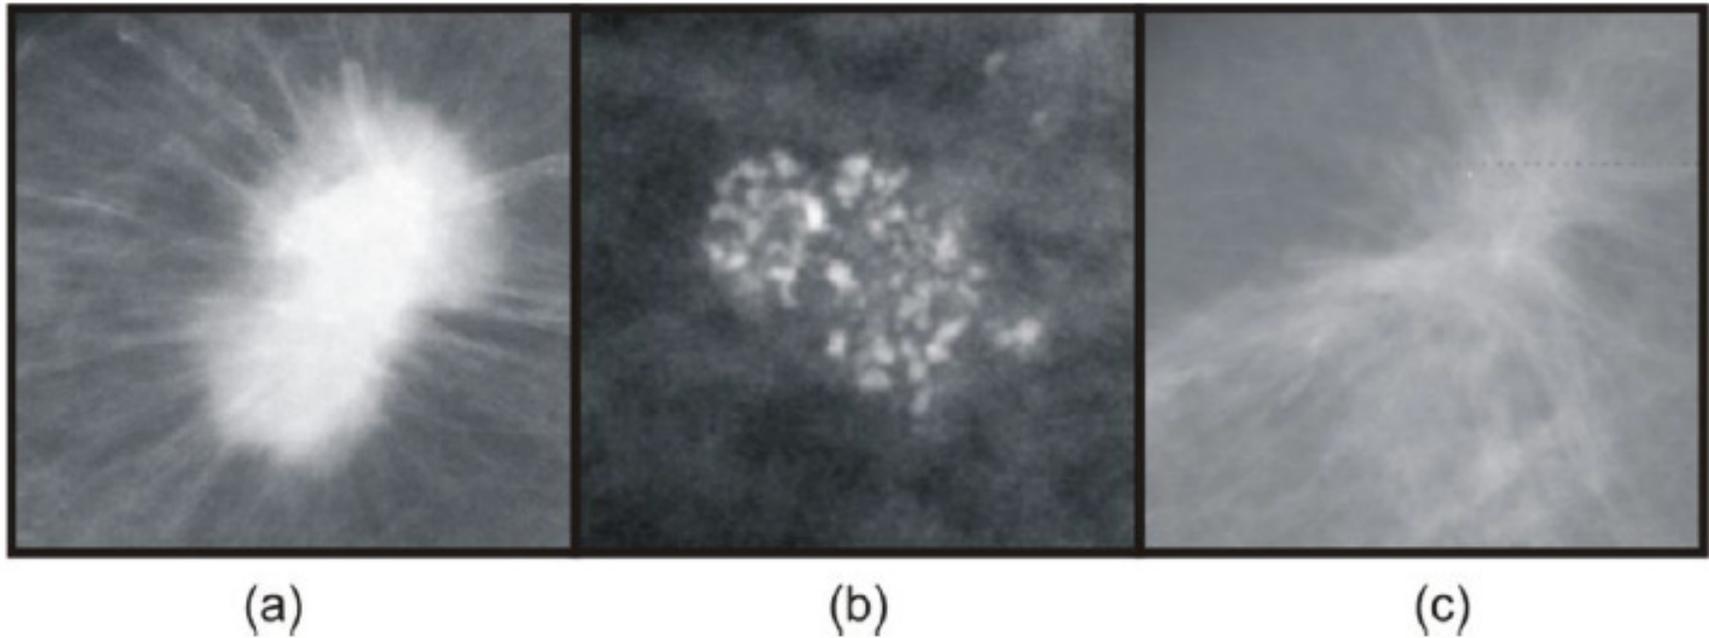
(b)



(c)

(a) Melanoma; (b) Segmentação considerando a área interior e (c) Localização do contorno ampliada.

Area de uma mamografia amplificada



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

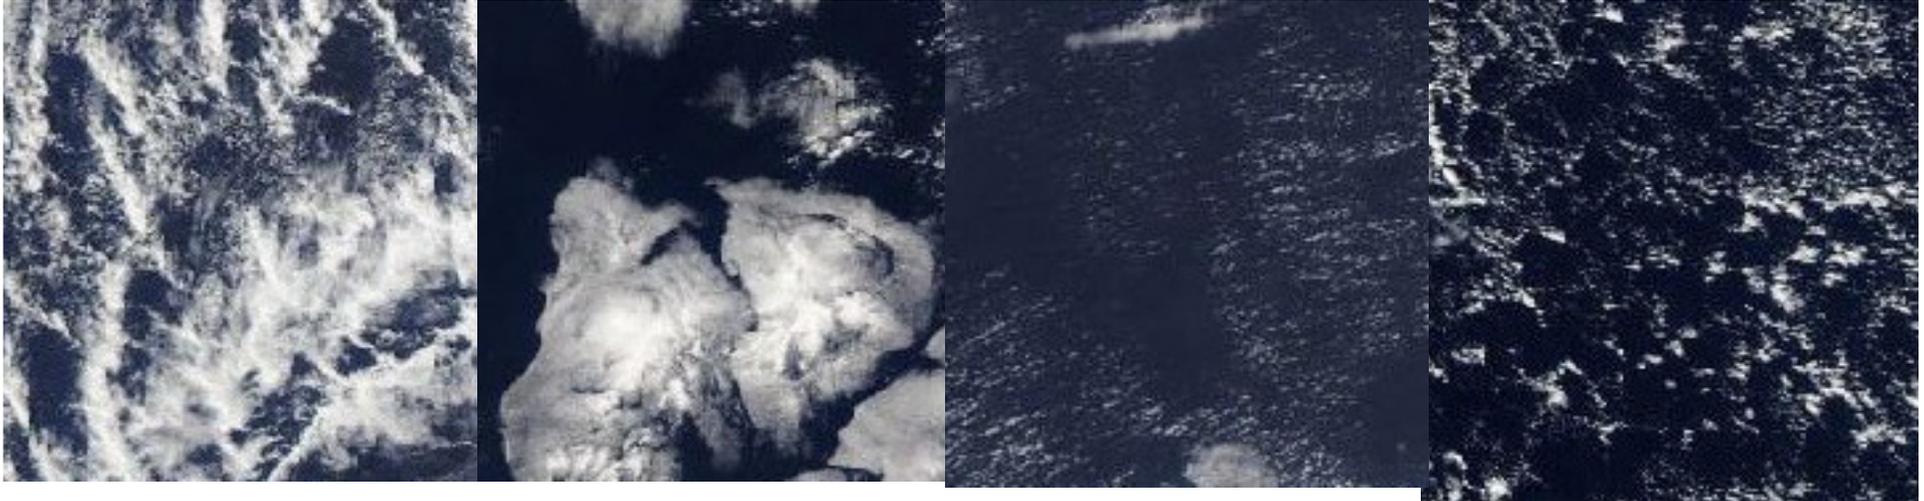
Competição

Max Planck Institute launch a competition in Kaggle: *Understanding clouds from satellite images using deep learning techniques*

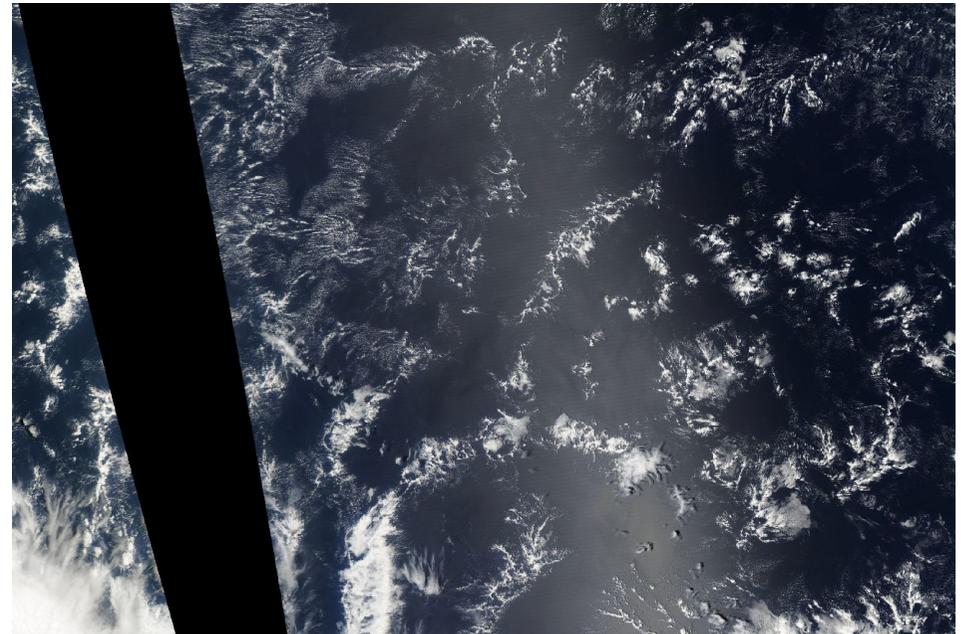
Based on visual inspection, four subjective patterns or organizations were defined: Sugar, Flower, Fish and Gravel

From a dataset of images captured by two satellites TERRA and AQUA

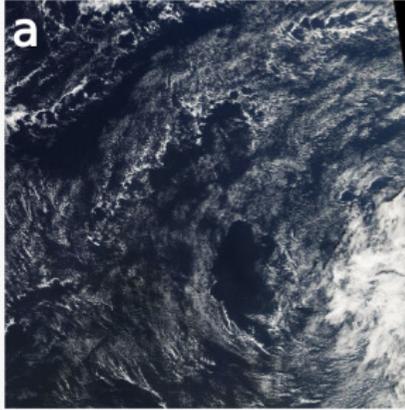
Sugar, Flower, Fish and Gravel



There area parts with nothing
and ilumination problems

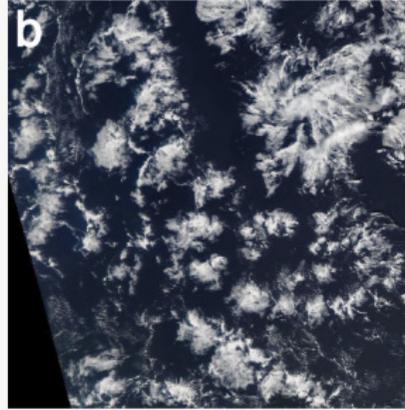


explicando



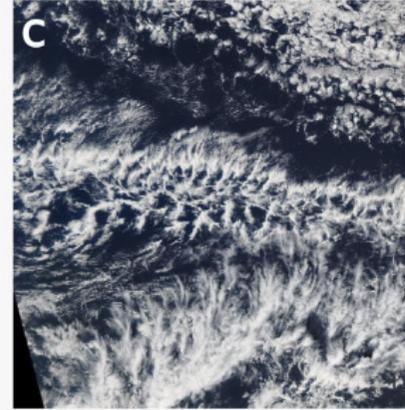
Sugar

Dusting of very fine clouds, little evidence of self-organization



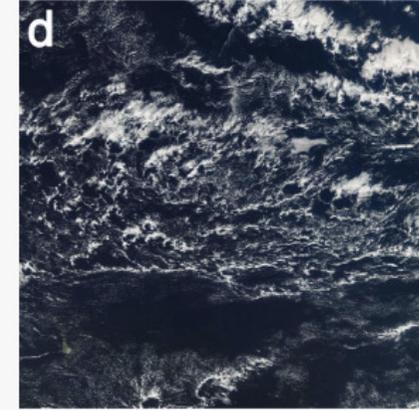
Flower

Large-scale stratiform cloud features appearing in bouquets, well separated from each other.



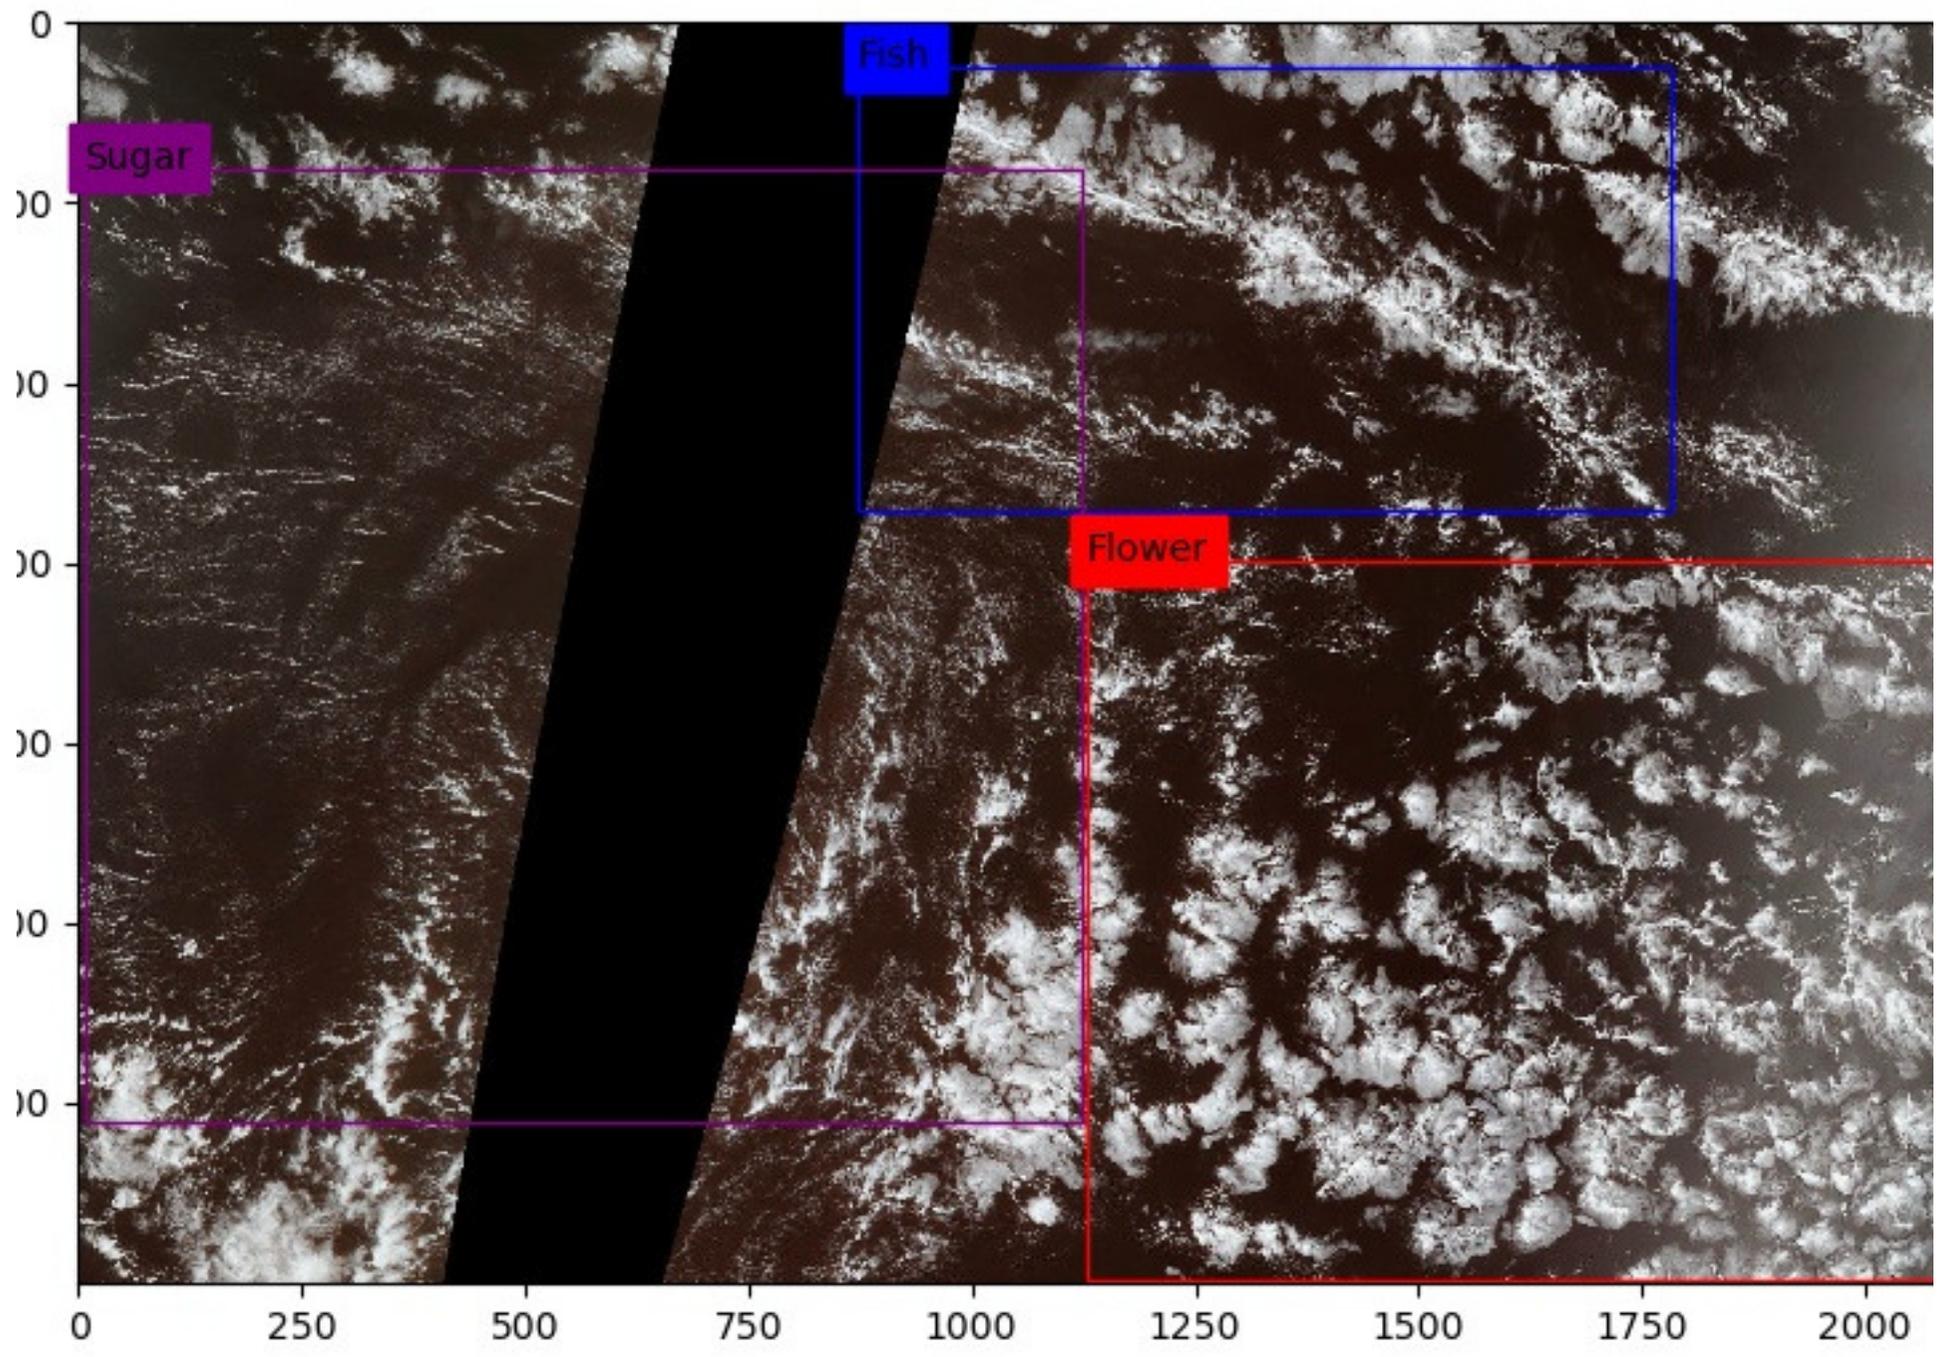
Fish

Large-scale skeletal networks of clouds separated from other cloud forms.



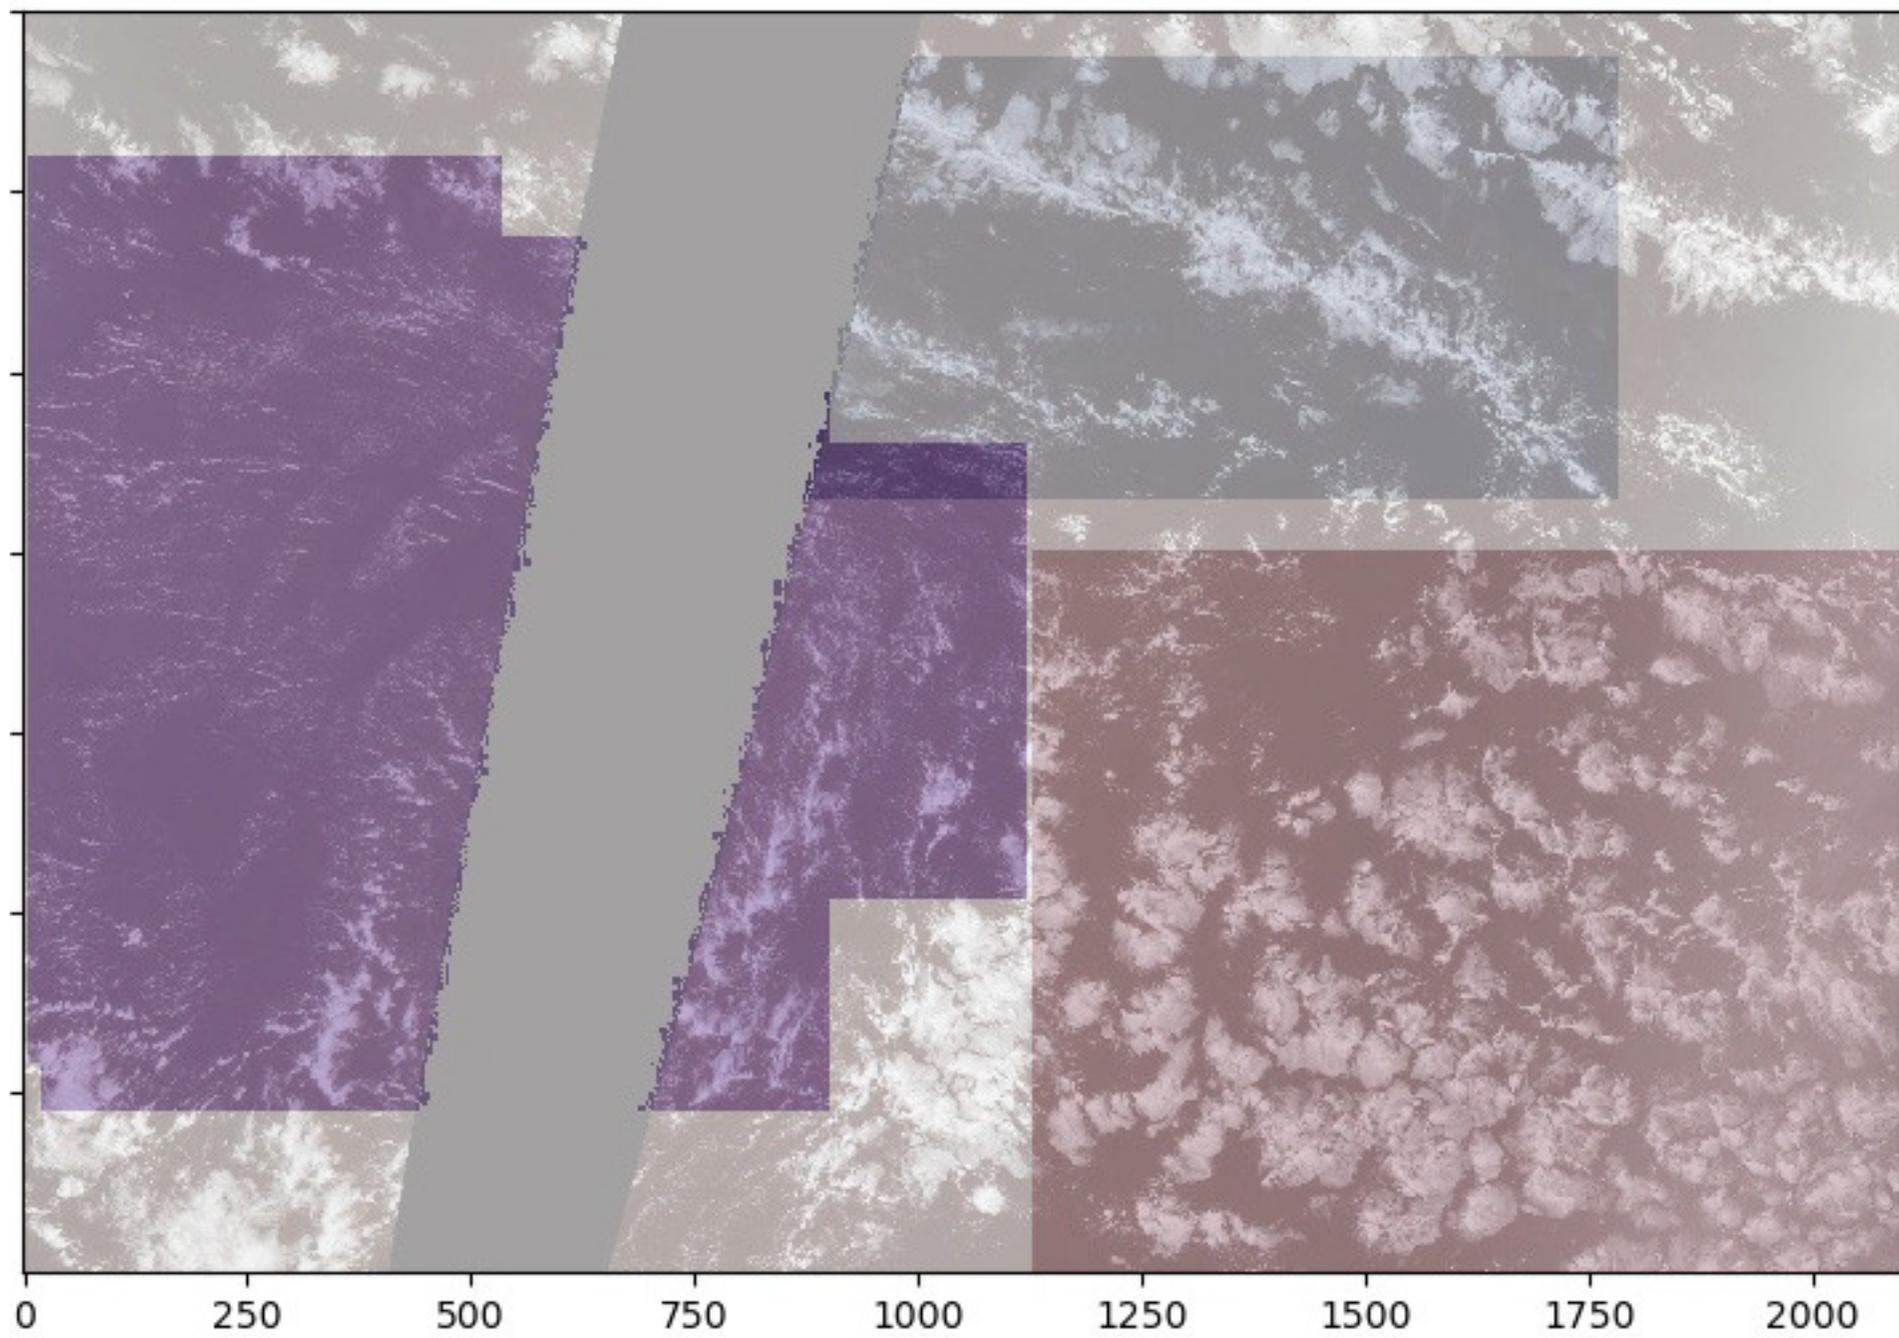
Gravel

Meso-beta lines or arcs defining randomly interacting cells with intermediate granularity.

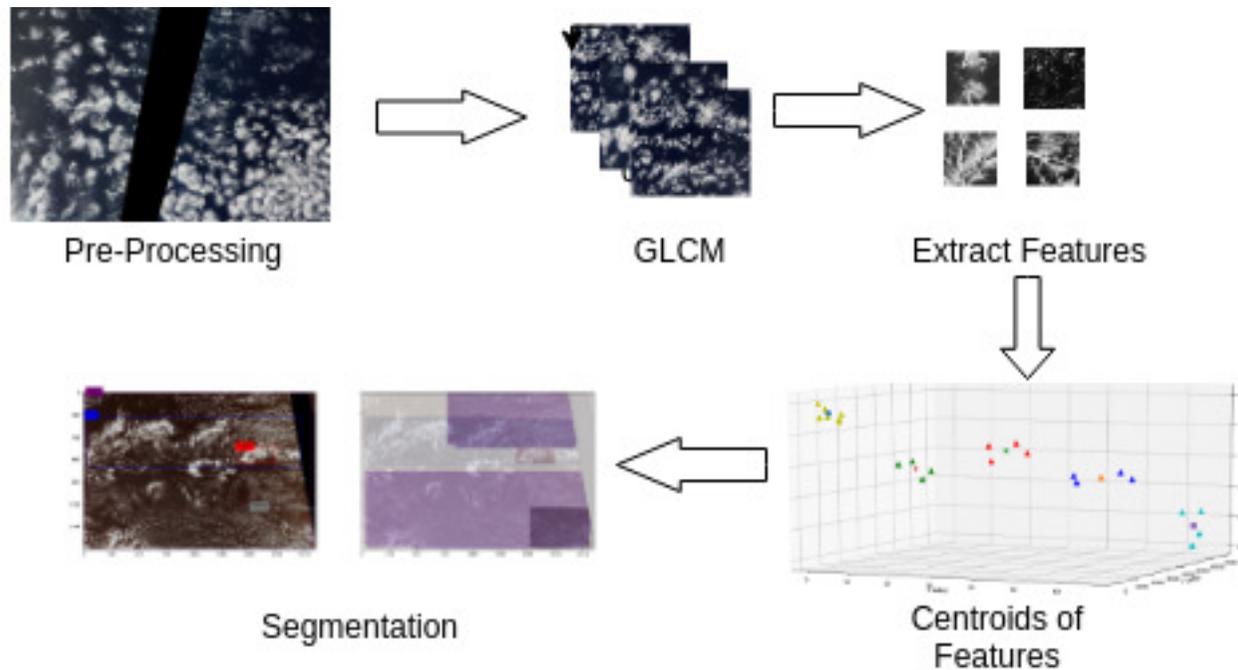


Usos em AI

- Segmentação de imagens a partir do perfil textural, dividindo a imagem em regiões consideradas de interesse.
- Descrição e extração das características baseadas em medidas que quantificam os elementos de textura de uma imagem



Metodologia usada

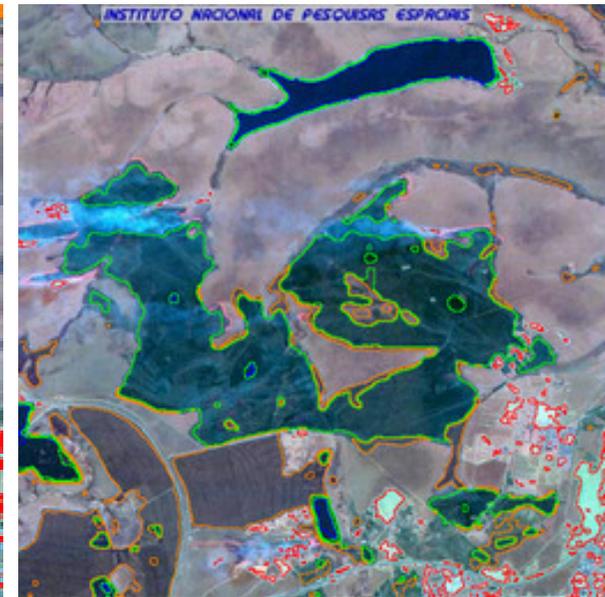
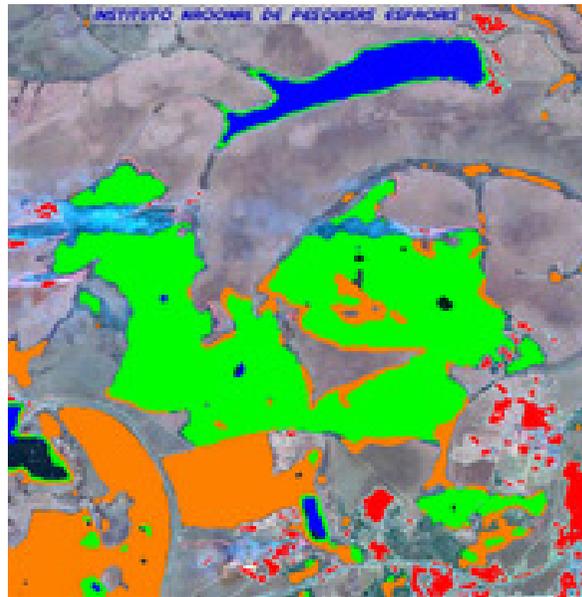
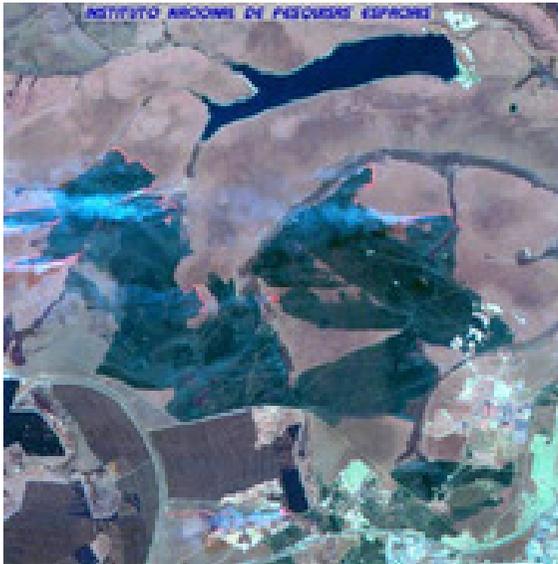


Aerial or Landsat satellite images

Original,

interior segmentation

boundaries segmentation



Alias

Gostaria que procurassem ver como ficam as imagens do veterinario depois de segmentadas por alguma das técnicas de

Limiarização apresentadas na aula por vocês, na aula passada.

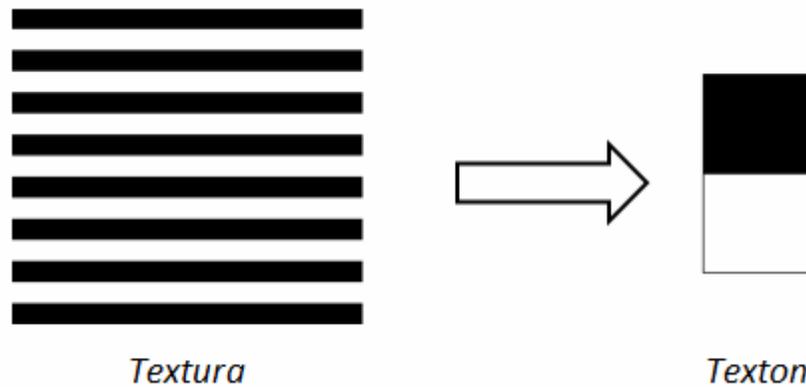
Alguma ficaria adequada para separar o objeto de interesse do fundo daquelas imagens?

Alguma daria para separa o objeto em 4 níveis de cinza?

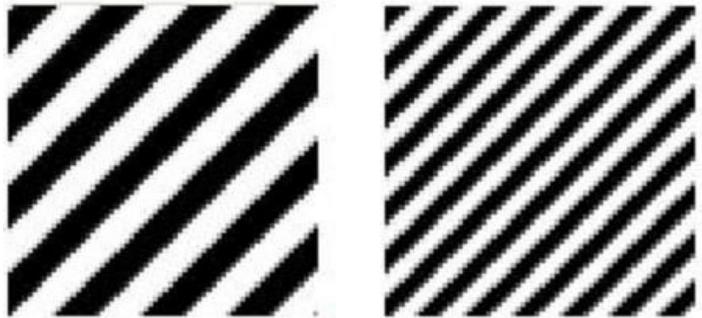
Na linguagem ou tools que vocês estão acostumados a usar há recursos de Analise de Imagens (MatLab, OpenCV, etc) ?

Elemento de textura (*texture element – **textel***)

Ou o menor conjunto de pixels com propriedades de texturais intensidade similares:
texton (Julesz, 1981).



Repare que esse menor conjunto de pixels depende de uma serie de fatores, como por exemplo quantos pixels podem descrever o padrão ...



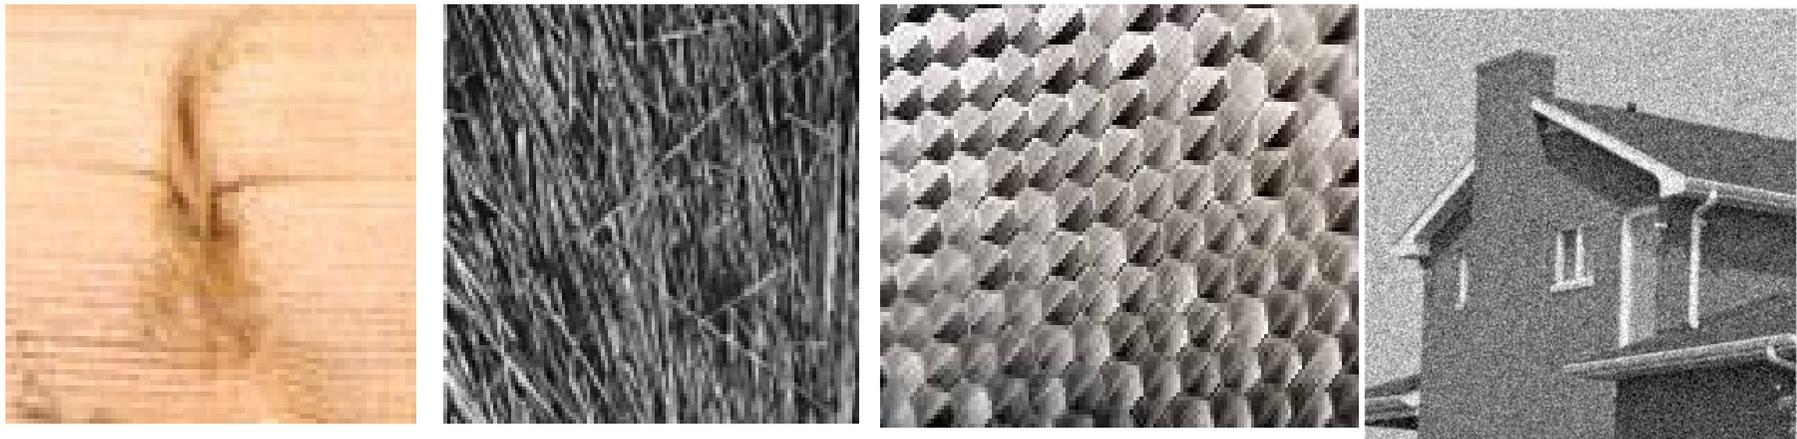
Abordagem textural mais utilizadas na literatura

- Descritores de HARALICK (1973), obtidos por:
 - Matriz de Coocorrência em Escala de Cinza (*Gray Level Co-occurrence Matrix - GLCM*).
 - Unser (1986) : Histogramas de Soma e Diferença (*Sum and Difference Histogram - SDH*).

Textura

Metodos mais usados:

- Matriz de co-ocorrência
- Vetores de Soma e diferença
- LBP
- Momentos geometricos na imagem em diversos tons



Dois tons é a forma geralmente usada: ou seja analise por banca cromática

MATRIZ DE COOCORRÊNCIA EM ESCALA DE CINZA (GLCM)

- ângulos de cálculo da GLCM são: 0° , 45° , 90° e 135° .
- a distância entre o pixel de referência e o pixel vizinho

$$P_{(i,j)} \quad d, \theta$$

Onde $P(i, j)$ é o pixel de referência, i e j definem a posição do pixel d e referência na imagem (linha, coluna).

Os elementos do conjunto d e θ representam, respectivamente, a distância e o ângulo do pixel de referência até o pixel vizinho.

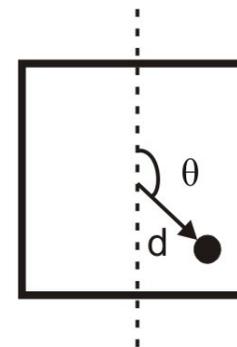
Para o cálculo da GLCM

- a imagem é percorrida registrando o número de ocorrências entre os tons dos pixels de referência e vizinho.
- A quantidade dessas ocorrências é computada e armazenada em uma matriz onde os índices de linhas e colunas representam os tons de cinza presentes na imagem.
- Assim, a GLCM sempre tem número de elementos igual ao quadrado de N , onde N representa a quantidade de tons de cinza da textura.

Matrizes de Co-ocorrência

Pode ser associada a:

- ângulo (q);
- distância (d) entre os *pixels* (i, j):
 - $p(i, j, d, q)$;
- forma de deslocamentos na horizontal e vertical
 - $(p(i, j), Dx, Dy)$.



Operador $p(i, j, d, \theta)$.

Considere:

- $I(N, M)$ uma imagem quantizada em **G níveis de cinza**.
- I é uma matriz $G \times G$.
- Cada elemento da matriz é a função que designa a **probabilidade de ocorrência** simultânea de dois níveis de cinza $i, j = 0 \dots G-1$ para pares de *pixels* nas direções e distâncias especificadas.
- A informação textural é caracterizada pela matriz de frequência relativa **$p(i, j, d, q)$** .

Considere:

- $I(N, M)$ uma imagem quantizada em **G níveis de cinza**.
- I é uma matriz $G \times G$.
- Cada elemento da matriz é a função que designa a **probabilidade de ocorrência** simultânea de dois níveis de cinza $i, j = 0 \dots G-1$ para pares de *pixels* nas direções e distâncias especificadas.
- A informação textural é caracterizada pela matriz de frequência relativa **$p(i, j, d, q)$** .

Assim:

1. Percorre-se a imagem na forma descrita pelo operador $p(i, j, d, \theta)$ ou $p(i, j) \Delta x, \Delta y$.
2. As frequências relativas ou as probabilidades são obtidas dividindo-se os valores obtidos pelo número de ocorrências totais.
3. A matriz de co-ocorrência é obtida dividindo-se cada elemento de $a_{i,j}$ pelo número de pares de pontos na imagem que satisfaça $P(d, \theta)$:

$$p(i, j, d, \theta) = P(i, j) \Delta x, \Delta y = a_{i,j} / n$$

$$\text{onde: } n = \sum_{i,j} a_{i,j}$$

Vamos supor a primeira configuração:

1. Percorre-se a imagem procurando ocorrências, onde os tons simultâneos serão o número das linhas e colunas da matriz

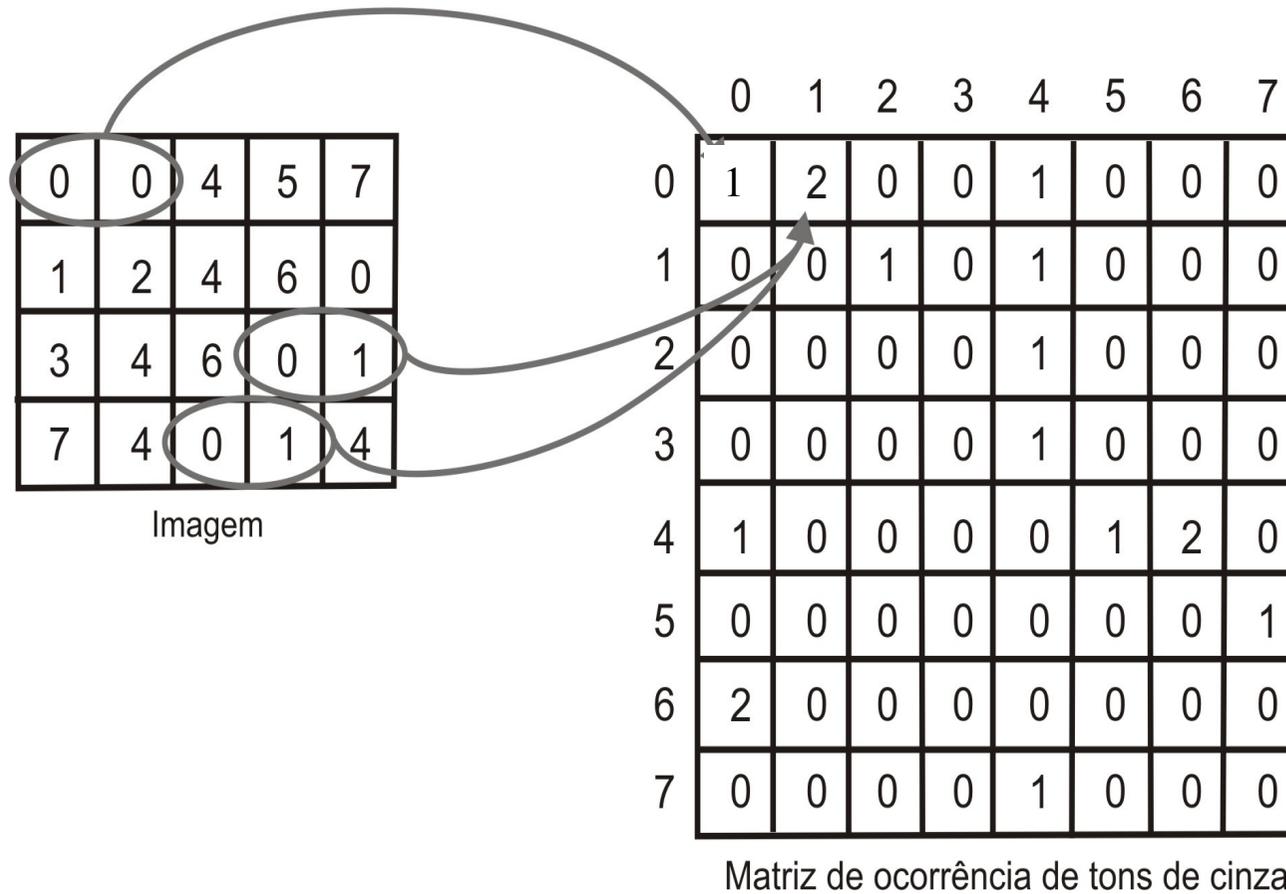
Na horizontal com distância de 1 pixel (ou seja entre o pixel e seu vizinho a direita)

$$p(i, j, 1, 0) \text{ ou } p(i, j) \ 1, 0.$$

Toda vez que acharmos algo aumentamos o contador de linha i , e da coluna j da matriz:

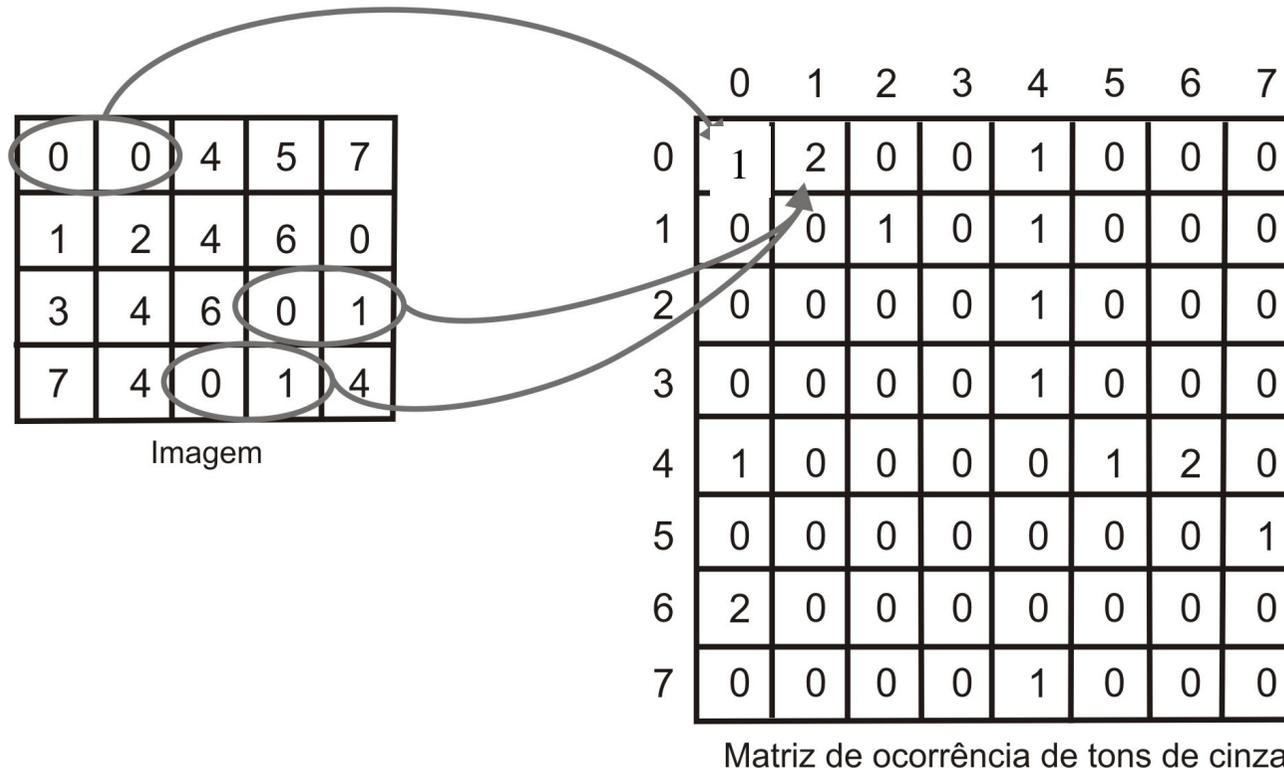
$$a_{i,j} = a_{i,j} + 1, \quad \text{ao final divide-se pelo número total de pixels: } n = \sum_{i,j} a_{i,j}.$$

$p(i, j, 1, 0)$ ou $p(i, j) 1, 0$.



Matriz de co-ocorrência em 8 tons de cinza com vizinhança 1 e percorrendo na Horizontal .

$p(i, j, 1, 0)$ ou $p(i, j) 1, 0$.



Matriz de co-ocorrência de tons de cinza (neste caso ficou ate maior que nossa micro imagem de teste inicial !).

Textura: Matriz de co-ocorrência

- Considere por exemplo uma imagem com 3 níveis de cinza, $z_0 = 0$, $z_1 = 1$ e $z_2 = 2$.

0	0	0	1	2
1	1	0	1	1
2	2	1	0	0
1	1	0	2	0
0	0	1	0	1

P = um píxel a direita e pixel abaixo



$p(i, j, 1, 45^\circ)$ ou $p(i, j) 1, 1$.

Sendo assim, A seria uma **matriz 3x3**.

a_{00} o número de vezes que o um ponto com nível de **cinza 0** aparece **abaixo e a direita** de outro pixel com **nível 0 de cinza** !

Nesse caso a_{00} teria o valor 4

Textura: Matriz de co-ocorrência

- Considere por exemplo uma imagem com 3 níveis de cinza, $z_0 = 0$, $z_1 = 1$ e $z_2 = 2$.

0	0	0	1	2	P = um píxel a direita e pixel abaixo 
1	1	0	1	1	
2	2	1	0	0	
1	1	0	2	0	
0	0	1	0	1	

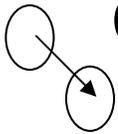
Sendo assim, A seria uma **matriz 3x3**.

a_{01} o número de vezes que o um ponto com nível de **cinza 0** aparece **abaixo e a direita** de outro pixel com **nível 1 de cinza** !

Nesse caso a_{01} teria o valor 1

Textura: Matriz de co-ocorrência

- O valor de a_{02} é o número de vezes que um ponto com nível z_0 aparece **abaixo e a direita** do ponto com nível z_2 . E assim por diante.



Desta maneira, a matriz de co-ocorrência
Para um píxel a direita e pixel abaixo
de toda essa mini imagem é

0	0	0	1	2
1	1	0	1	1
2	2	1	0	0
1	1	0	2	0
0	0	1	0	1

$$A = \begin{vmatrix} 4 & 1 & 0 \\ 2 & 3 & 2 \\ 1 & 2 & 0 \end{vmatrix}$$

A em geral deve ser normalizada depois de calculada.

E todas as demais direções computadas também

- Considere o mesma imagem com 3 níveis de cinza, $z_0 = 0$, $z_1 = 1$ e $z_2 = 2$. Mas agora com

P = um **píxel a esquerda e pixel abaixo**

0	0	0	1	2
1	1	0	1	1
2	2	1	0	0
1	1	0	2	0
0	0	1	0	1



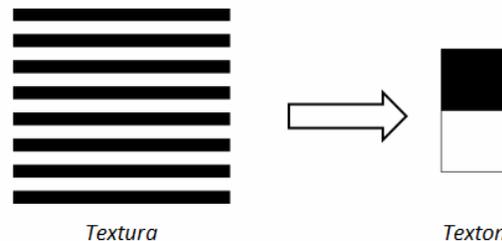
Sendo assim, A seria uma **matriz 3x3**.

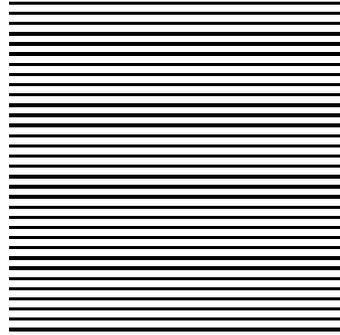
a_{00} o número de vezes que o um ponto com nível de **cinza 0** aparece **abaixo e a esquerda** de outro pixel com **nível 0 de cinza !**

Nesse caso a_{00} teria o valor 3

Todas as vizinhanças

- De direção geralmente são percorridas;
- As distâncias, ficam a cargo da “delicadeza” da textura !
- Para entender isso vamos ver um exemplo onde a gente supõem que nossa imagem teria direções “**infinitas**” na horizontal e vertical .





Probabilidades possíveis para “**Listras horizontais de 1 pixel**” – vizinhança de **1 pixel**.

$p(i, j, d=1, \theta=0^\circ)$ ou $P(i, j) \Delta_x=1, \Delta_y=0$		$p(i, j, d=1, \theta=90^\circ)$ ou $P(i, j) \Delta_x=0, \Delta_y=1$		$p(i, j, d=1, \theta=45^\circ)$ ou $P(i, j) \Delta_x=1, \Delta_y=1$		$p(i, j, d=1, \theta=135^\circ)$ ou $P(i, j) \Delta_x=-1, \Delta_y=1$	
0,5	0	0	0,5	0	0,5	0	0,5
0	0,5	0,5	0	0,5	0	0,5	0

Probabilidades possíveis para “**Listras horizontais 1 pixel**” – vizinhança de **2 pixels**.

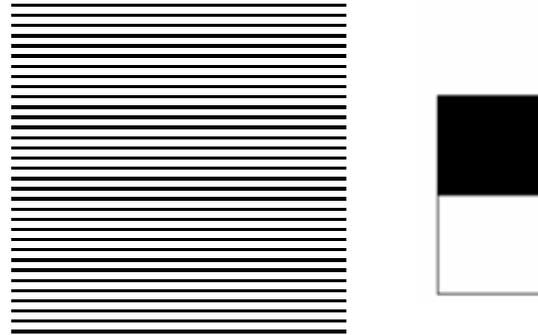
$p(i, j, d=2, \theta=0^\circ)$ ou $P(i, j) \Delta_x=2, \Delta_y=0$		$p(i, j, d=2, \theta=90^\circ)$ ou $P(i, j) \Delta_x=0, \Delta_y=2$		$p(i, j, d=2, \theta=45^\circ)$ ou $P(i, j) \Delta_x=2, \Delta_y=2$		$p(i, j, d=2, \theta=135^\circ)$ ou $P(i, j) \Delta_x=-2, \Delta_y=2$	
0,5	0	0	0,5	0	0,5	0	0,5
0	0,5	0,5	0	0,5	0	0,5	0

“Listras horizontais 1 pixel” com texel de
2x1



0	0	0	0	0	0	0	0
1	1	1	1	1	1	1	1
0	0	0	0	0	0	0	0
1	1	1	1	1	1	1	1
0	0	0	0	0	0	0	0
1	1	1	1	1	1	1	1
0	0	0	0	0	0	0	0
1	1	1	1	1	1	1	1
0	0	0	0	0	0	0	0

O mesmo ocorrido da
vizinhança de **1 pixel** ocorre
As demais vizinhanças!



Probabilidades possíveis para “Listras **horizontais de 1 pixel**” – vizinhança de **2 pixel**.

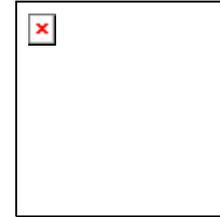
$p(i, j, d=1, \theta=0^\circ)$ ou $P(i, j) \Delta_x=1, \Delta_y=0$		$p(i, j, d=1, \theta=90^\circ)$ ou $P(i, j) \Delta_x=0, \Delta_y=1$		$p(i, j, d=1, \theta=45^\circ)$ ou $P(i, j) \Delta_x=1, \Delta_y=1$		$p(i, j, d=1, \theta=135^\circ)$ ou $P(i, j) \Delta_x=-1, \Delta_y=1$	
0,5	0	0	0,5	0	0,5	0	0,5
0	0,5	0,5	0	0,5	0	0,5	0

Probabilidades possíveis para “Listras **horizontais 1 pixel**” – vizinhança de **3 pixels**.

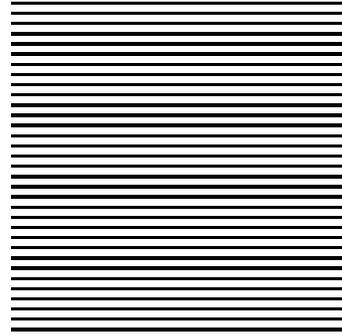
$p(i, j, d=2, \theta=0^\circ)$ ou $P(i, j) \Delta_x=2, \Delta_y=0$		$p(i, j, d=2, \theta=90^\circ)$ ou $P(i, j) \Delta_x=0, \Delta_y=2$		$p(i, j, d=2, \theta=45^\circ)$ ou $P(i, j) \Delta_x=2, \Delta_y=2$		$p(i, j, d=2, \theta=135^\circ)$ ou $P(i, j) \Delta_x=-2, \Delta_y=2$	
0,5	0	0	0,5	0	0,5	0	0,5
0	0,5	0,5	0	0,5	0	0,5	0

“Listras horizontais e 2 pixels”

i.e. com texel de 4x1



0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0
1	1	1	1	1	1	1	1
1	1	1	1	1	1	1	1
0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0
1	1	1	1	1	1	1	1
1	1	1	1	1	1	1	1
0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0



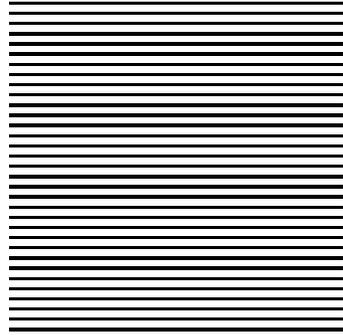
texel de 4x1

Probabilidades possíveis para “Listras 2 pixels horizontais” – vizinhança de 1 *pixel*.

$p(i, j, d=3, \theta=0^\circ)$ ou $P(i,j) \Delta_x=3, \Delta_y=0$	$p(i, j, d=3, \theta=90^\circ)$ ou $P(i,j) \Delta_x=0, \Delta_y=3$	$p(i, j, d=3, \theta=45^\circ)$ ou $P(i,j) \Delta_x=3 \Delta_y=3$	$p(i, j, d=3, \theta=135^\circ)$ ou $P(i,j) \Delta_x=-3 \Delta_y=3$
0,5	0	0,25	0,25
0	0,5	0,25	0,25

Probabilidades possíveis para “Listras 2 pixels horizontais” – vizinhança de 2 *pixels*.

$p(i, j, d=4, \theta=0^\circ)$ ou $P(i,j) \Delta_x=4 \Delta_y=0$	$p(i, j, d=4, \theta=90^\circ)$ ou $P(i,j) \Delta_x=0, \Delta_y=4$	$p(i, j, d=4, \theta=45^\circ)$ ou $P(i,j) \Delta_x=4 \Delta_y=4$	$p(i, j, d=4, \theta=135^\circ)$ ou $P(i,j) \Delta_x=-4 \Delta_y=4$
0,5	0	0	0,5
0	0,5	0,5	0



texel de 4x1

Probabilidades possíveis para “Listras **2 pixels horizontais**” – vizinhança de **3 pixel**.

$p(i, j, d=3, \theta=0^\circ)$ ou $P(i, j) \Delta_x=3, \Delta_y=0$	$p(i, j, d=3, \theta=90^\circ)$ ou $P(i, j) \Delta_x=0, \Delta_y=3$	$p(i, j, d=3, \theta=45^\circ)$ ou $P(i, j) \Delta_x=3, \Delta_y=3$	$p(i, j, d=3, \theta=135^\circ)$ ou $P(i, j) \Delta_x=-3, \Delta_y=3$
0,5	0	0,25	0,25
0	0,5	0,25	0,25

Probabilidades possíveis para “Listras **2 pixels horizontais**” – vizinhança de **4 pixels**.

$p(i, j, d=4, \theta=0^\circ)$ ou $P(i, j) \Delta_x=4, \Delta_y=0$	$p(i, j, d=4, \theta=90^\circ)$ ou $P(i, j) \Delta_x=0, \Delta_y=4$	$p(i, j, d=4, \theta=45^\circ)$ ou $P(i, j) \Delta_x=4, \Delta_y=4$	$p(i, j, d=4, \theta=135^\circ)$ ou $P(i, j) \Delta_x=-4, \Delta_y=4$
0,5	0	0,5	0
0	0,5	0	0,5

Conclusão deste experimento

- Para qq vizinhança as listas horizontais permaneceram INALTERADAS
- As demais mostrarm-se repetitivas para os numeros multiples do padrão de *pixels do texel*. E esse padrão deterministico sintetico fica bem caracterizado e relacionado ao *tamanho do texel* (por exemplo numero de listas pares ou impares).
- Essas obs são cosideradas nos descritores....

Descritores de Textura de Haralick

Descritores de Textura baseados nas matrizes de co-ocorrência.

Característica	Descrição	Fórmula Matemática
Homogeneidade	Distribuição de <i>pixels</i> .	$\sum_i \sum_j \frac{p(i, j)}{(1 + i - j)}$
Probabilidade Máxima	Indica a direção mais importante da textura a ser examinada.	$\max_{i, j} p(i, j)$
Entropia	Mede a informação contida em p, muitos valores nulos representam pouca informação.	$-\sum_i \sum_j p(i, j) \log_2 p(i, j)$

Descritores de Textura baseados nas matrizes de co-ocorrência (continuação).

Momento de diferenças ordem k	Distorção da imagem. Este descritor apresenta valores pequenos se p tiver maiores valores na diagonal principal.	$\sum_i \sum_j (i-j)^k p(i, j)$
Momento inverso de diferenças de ordem k	Inverso de contraste. Este descritor apresenta valores maiores pequenos se p tiver pequenos valores na diagonal principal.	$\sum_i \sum_j \frac{p(i, j)}{(i-j)^k}$
Energia ou Uniformidade	Retorna a soma dos elementos elevados ao quadrado dentro da matriz de co-ocorrência de tons de cinza. Faixa de valores possíveis: 0 a 1. A energia possui valor 1 para uma imagem constante (mesmo tom de cinza em toda a sua extensão).	$\sum_i \sum_j p^2(i, j)$

Descritores de Textura baseados nas matrizes de co-ocorrência (continuação).

Variância ou Contraste	Retorna uma medida do contraste entre as intensidades de um <i>pixel</i> analisado e do <i>pixel</i> vizinho. A comparação é realizada em todos os pixels da imagem. Para uma imagem constante (mesmo tom de cinza em toda a extensão), o contraste é 0 (zero). Contraste da imagem corresponde ao Momento de ordem 2.	$\sum_i \sum_j (i - j)^2 p(i, j)$
Variância Inversa	Inverso de contraste.	$\sum_i \sum_j \frac{p(i, j)}{(i - j)^2}, i \neq j$

Descritores de Textura baseados nas matrizes de co-ocorrência (continuação).

Correlação	<p>Retorna uma medida de quão correlacionado está um <i>pixel</i> com o seu vizinho. A comparação é realizada em todos os <i>pixels</i> da imagem.</p> <p>Faixa de valores possíveis: -1 a 1.</p> <p>A correlação é 1 para uma imagem totalmente correlacionada ou -1 para uma completamente descorrelacionada.</p>	$\frac{1}{(\sigma_i \sigma_j)} \sum_i \sum_j (i - \mu_i)(j - \mu_j) p(i, j)$ <p>Onde: σ representa o desvio padrão e μ a média</p>
Homogeneidade	<p>Retorna um valor que representa a proximidade da distribuição dos elementos em relação à diagonal da matriz de co-ocorrência dos tons de cinza.</p> <p>Faixa de valores possíveis: 0 a 1.</p> <p>Um valor de Homogeneidade 1 representa uma matriz diagonal de co-ocorrência de tons de cinza.</p>	$\sum_i \sum_j \frac{p(i, j)}{1 + i - j }$

Textura e Matriz de co-ocorrência

- Deficiências:
- Como para Medir textura a partir das GLCM tem-se que fazer **muitas configurações** sobre a posição relativa dos pixels em relação uns aos outros.
- Alguns descritores tem muitos contos e são semelhantes. (Solução entender o que significa)
- Uma maneira de trazer essa informação não ser **tão cara** foram os Histogramas de Somas e diferenças.

Alguns Descritores da co-ocorrência com significado similares

Descritor (significado)	Equação	Descritor (significado)	Equação
Variância (contraste da imagem)	$\sum_i \sum_j (i-j)^2 P(i, j)$	Homogeneidade (distribuição de pixels)	$\sum_i \sum_j P(i, j) / (1 + i - j)$
Entropia (suavidade)	$\sum_i \sum_j P(i, j) \log P(i, j)$	Momento 3ª ordem (distorção da imagem)	$\sum_i \sum_j (i-j)^3 P(i, j)$
Energia (uniformidade)	$\sum_i \sum_j P^2(i, j)$	Variância Inversa (inverso de contraste)	$\sum_i \sum_j P(i, j) / (i-j)^2$

•Deficiências:

Matriz de co-ocorrência

- Seja Q um operador de posição e A uma matriz $k \times k$, cujo elemento a_{ij} seja o número de vezes que os pontos com o nível de cinza z_i ocorrem (na posição especificada por Q), relativamente a pontos com o nível de cinza z_j , com $i \leq k$, $j \leq k$.

•Deficiências:

HISTOGRAMAS DE SOMA E DIFERENÇA (SDH)

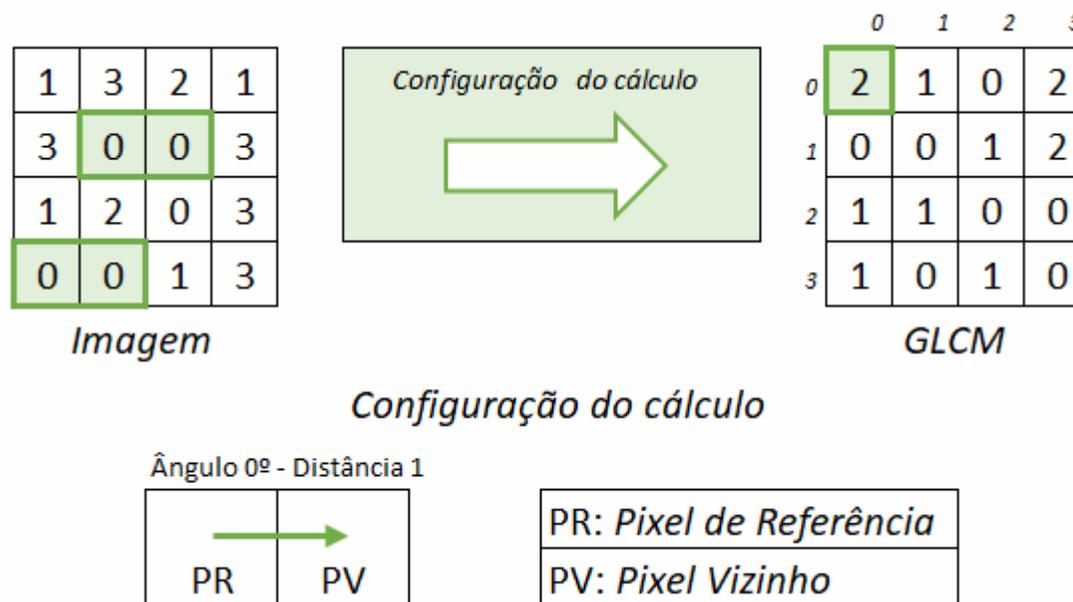
- Os ângulos e distâncias utilizados nos cálculos da matriz de co-ocorrência são representados nos SDH através de duas configurações de distâncias: horizontal e vertical, descritas por d_i e d_j .

COMPLEXIDADE DOS SDH: $O(N)$, para todo $N \geq 2$

•Deficiências:

Exemplo:

- distância 1 e ângulo 0° .



COMPLEXIDADE DA GLCM: o custo computacional para o cálculo da GLCM é N^2 : $O(N \times N)$

Representação de ângulo e distância nos SDH a partir da vizinhança

0	0	0	0
0	0	0	0
1	1	1	1
1	1	1	1

Ângulo 0°
 $di: 1$
 $dj: 0$

0	0	0	0
0	0	0	0
1	1	1	1
1	1	1	1

Ângulo 45°
 $di: -1$
 $dj: 1$

0	0	0	0
0	0	0	0
1	1	1	1
1	1	1	1

Ângulo 90°
 $di: 0$
 $dj: 1$

0	0	0	0
0	0	0	0
1	1	1	1
1	1	1	1

Ângulo 135°
 $di: 1$
 $dj: 1$

	Pixel de Referência
	Pixel Vizinho

cálculo dos histogramas de soma e diferença

- *Histograma da Soma:*

$$P(i, j) + P(i + di, j + dj)$$

- *Histograma da Diferença:*

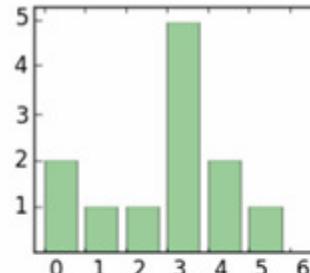
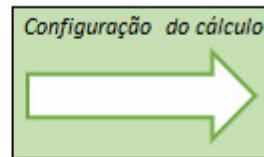
$$P(i, j) - P(i + di, j + dj)$$

Onde $P(i, j)$ é o pixel de referência, di é a distância horizontal e dj é a distância vertical.

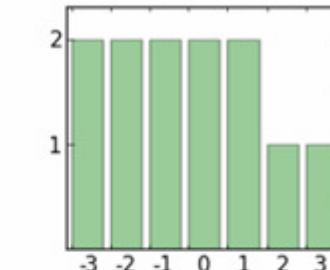
Cálculo dos SDH em uma imagem com quatro tons

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

Imagem



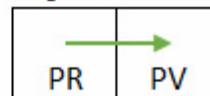
Histograma da Soma



Histograma da Diferença

Configuração do cálculo

Ângulo 0° - Distância 1



PR: Pixel de Referência

PV: Pixel Vizinho

Embora o tamanho máximo de cada histograma seja o mesmo, os extremos de cada um são diferentes.

Os HS começam com o índice zero e podem possuir até $2N$ células.

Já os HD, por sua vez podem ter um intervalo de $-N$ à N células.

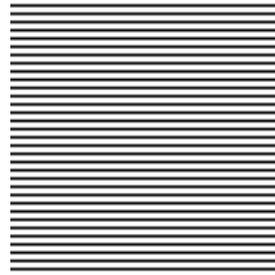
Somando e subtraindo os tons

1	$3+1$	$2+3$	$1+2$	1
3	$0+3$	$0+0$	$3+0$	3
1	$2+1$	$0+2$	$3+0$	3
0	$0+0$	$1+0$	$3+1$	3
1	$3-1$	$2-3$	$1-2$	-1
3	$0-3$	$0-0$	$3-0$	-3
1	$2-1$	$0-2$	$3-0$	-3
0	$0-0$	$1-0$	$3-1$	-3

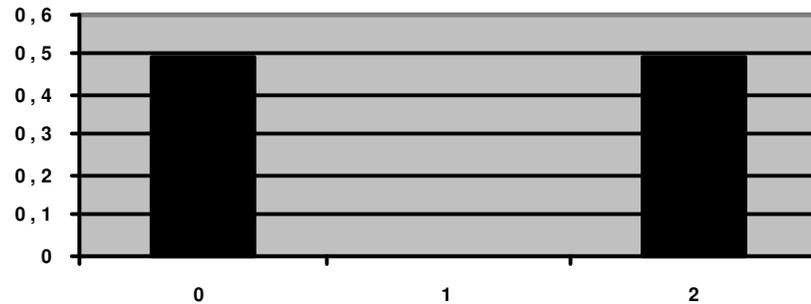
Somando e subtraindo os tons

1	4	5	3	1
3	3	0	3	3
1	3	2	3	3
0	0	1	4	3
1	2	-1	-1	-1
3	-3	0	3	-3
1	1	-2	3	-3
0	0	1	2	-3

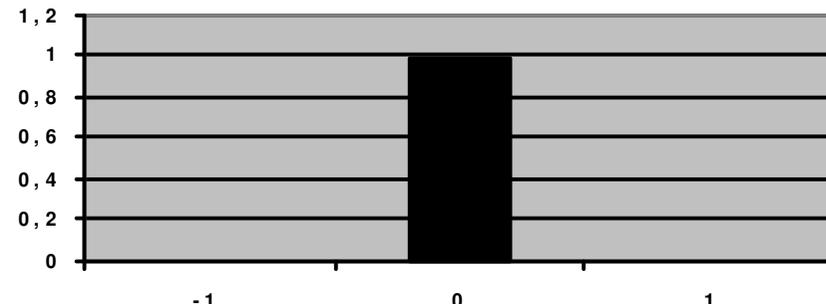
Para as



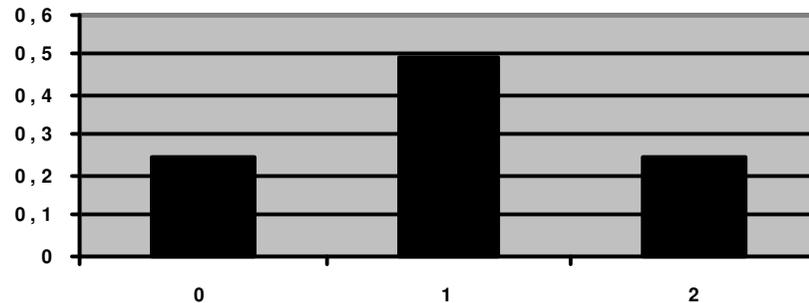
listas



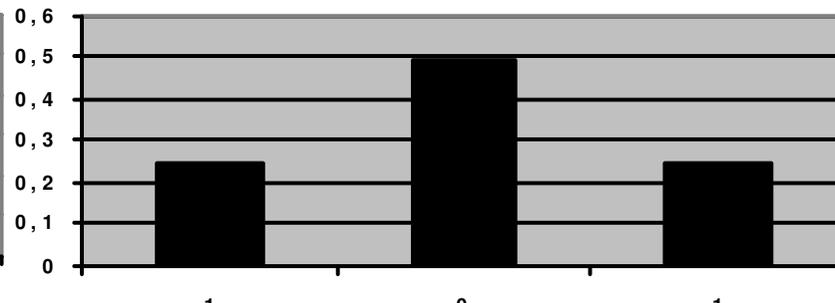
Histograma Soma $d_i=1, d_j=0$



Histograma Diferença $d_i=1, d_j=0$



Histograma Soma $d_i=0, d_j=1$



Histograma Diferença $d_i=0, d_j=1$

Histogramas soma e diferença da imagem “Listras Horizontais”.

DESCRITORES DE TEXTURA

representam 15 características de uma textura e são comumente chamados de descritores de Haralick.

- Segundo Momento Angular (SMA),
- Energia (ENE),
- Entropia (ENT),
- Contraste (CON),
- Dissimilaridade (DIS),
- Homogeneidade (HOM),
- duas medidas de Correlação (COR-1 e COR-2),
- duas medidas de Assimetria: *Cluster Shade* e *Cluster Prominence* (CSHA, CPRO);
- Variância e Desvio Padrão (VAR e DPA-J)
- Média calculadas de 3 formas : MED-I, MED-J e MED-G (linhas, colunas e ambas) .

descritores de textura SD x GLCM

	<i>GLCM</i>	<i>SDH</i>	
		<i>Unser</i>	<i>Propostas</i>
MED - I (μ_i)	$\sum_i \sum_j i \times G_{(i,j)}$	$\frac{1}{2} \sum_i i \times Hs_{(i)}$	$\frac{1}{4} \left(\sum_i i \times Hs_{(i)} + \sum_j j \times Hd_{(j)} \right)$
VAR ($\sigma \mid \sigma_i$)	$\sum_i \sum_j (i - \mu_i)^2 \times G_{(i,j)}$	$\frac{1}{2} \left(\sum_i (i - 2\mu_i)^2 \times Hs_{(i)} + \sum_j j^2 \times Hd_{(j)} \right)$	$\frac{1}{4} \left(\sum_i (i - 2\mu_i)^2 \times Hs_{(i)} + \sum_j j^2 \times Hd_{(j)} \right)$
COR-1	$\sum_i \sum_j (i - \mu) \times (j - \mu) \times G_{(i,j)}$	$\frac{1}{2} \left(\sum_i (i - 2\mu_i)^2 \times Hs_{(i)} - \sum_j j^2 \times Hd_{(j)} \right)$	$\frac{1}{4} \left(\sum_i (i - 2\mu)^2 \times Hs_{(i)} - \sum_j j^2 \times Hd_{(j)} \right)$
MED - J (μ_j)	$\sum_j \sum_i j \times G_{(i,j)}$	N/A	$\frac{1}{4} \left(\sum_i i \times Hs_{(i)} - \sum_j j \times Hd_{(j)} \right)$
MED - G (μ)	$\mu_i + \mu_j$	N/A	$\sum_i i \times Hs_{(i)}$
DPA - J (σ_j)	$\sum_i \sum_j (j - \mu_j)^2 \times G_{(i,j)}$	N/A	$\cong \sigma$
ENE	\sqrt{ASM}	N/A	\sqrt{ASM}
DIS	$\sum_i \sum_j i - j \times G_{(i,j)}$	N/A	$\sum_j j \times Hd_{(j)}$
COR - 2	$\sum_i \sum_j G_{(i,j)} \left \frac{(i - \mu_i)(j - \mu_j)}{\sqrt{\sigma_i^2 \sigma_j^2}} \right $	N/A	$\frac{COR1}{\sigma}$

descritores de textura SD x GLCM cont

	<i>GLCM</i>	<i>SDH</i>	
		<i>Unser</i>	<i>Propostas</i>
ENT	$-\sum_i \sum_j G_{(i,j)} \times \log(G_{(i,j)})$	$-\sum_i Hs_{(i)} \times \log(Hs_{(i)}) - \sum_j Hd_{(j)} \times \log(Hd_{(j)})$	
SMA	$\sum_i \sum_j G_{(i,j)}^2$	$\sum_i Hs_{(i)}^2 \times \sum_j Hd_{(j)}^2$	
CON	$\sum_i \sum_j (i-j)^2 \times G_{(i,j)}$	$\sum_j j^2 \times Hd_{(j)}$	
HOM	$\sum_i \sum_j \frac{1}{1+(i-j)^2} \times G_{(i,j)}$	$\sum_j \frac{1}{1+j^2} \times Hd_{(j)}$	
CSHA	$\sum_i \sum_j (i+j-2\mu)^3 \times G_{(i,j)}$	$\sum_i (i-2\mu_i)^3 \times Hs_{(i)}$	
CPRO	$\sum_i \sum_j (i+j-2\mu)^4 \times G_{(i,j)}$	$\sum_i (i-2\mu_i)^4 \times Hs_{(i)}$	

Outras caracterizações de texturas

A **entropia** (do grego *εντροπία*) é uma medida que aparece geralmente associada ao que se denomina de "grau de desordem" de um sistema .

- Seja J o numero de diferenças possíveis de informação, tons, ou texeis.
- E $p(a_j)$ a probabilidade de ocorrer cada uma destas possíveis informações, tons, ou texeis.
- As contagens desta propriedade geralmente iniciam não em Zero.

Entropia desta informação / imagem

- É o somatório da probabilidade de cada um dos a_j tons (por exemplo obtido do histograma normalizado) ou de cada uma das a_j texturas (a partir da contagem de seus texels) multiplicado pelo logaritmo destas probabilidades

$$H(Pa) = - \sum_{i=1}^J p(a_j) \log p(a_j)$$

A **entropia** também pode aparecer na forma de $1 / \log p(a_j)$ e sem o menos inicial devido as propriedades *logarítmicas* :
 $\log a - \log b = \log a / b$
 $\log 0 = 1$
 $\Rightarrow \log 1 / b = - \log b$

PROPRIEDADES DOS LOGARITMOS

1) $\log_a b \cdot c = \log_a b + \log_a c$

2) $\log_a \left(\frac{b}{c}\right) = \log_a b - \log_a c$

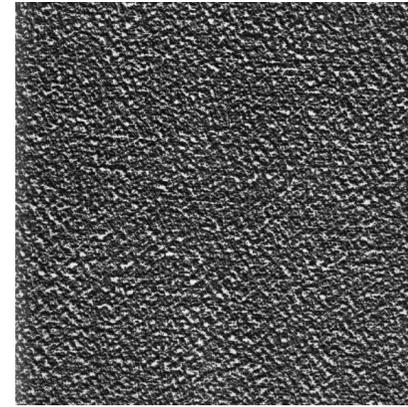
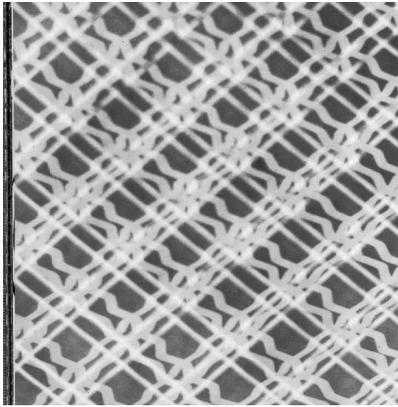
3) $\log_a b^a = a \cdot \log_a b$

4) $\log_{a^x} b = \frac{1}{x} \cdot \log_a b$

Entropia de uma imagem (cont)

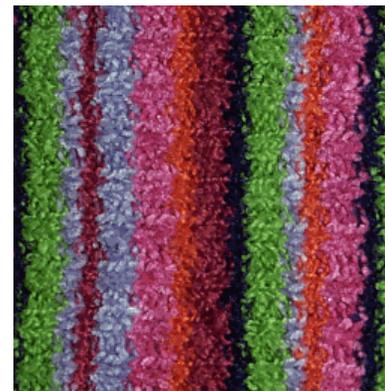
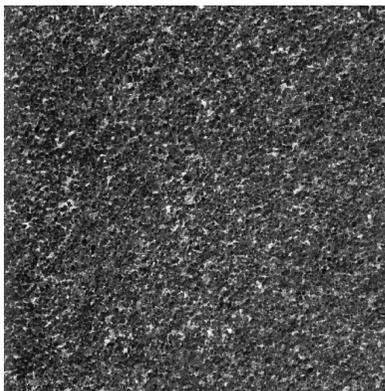
- Entropia quantifica a perda de energia ou até mesmo desordem.
- Sendo considerada por Einstein como a primeira lei de todas as ciências.
- Na área de comunicação, tem-se a **entropia da informação** que é definida como sendo uma forma de **medir a quantidade de informação**.
- Ou seja, uma mensagem tem certa quantidade de informação em relação ao seu grau de **incerteza ou imprevisibilidade**.

$$H(Pa) = -\sum_{i=1}^J p(a_j) \log p(a_j)$$



Texturas naturais monocromática. (a) Textura 1 - Entropia = 5.8766. (b) Textura 2 - Entropia = 5.9851. (c) Textura 3 - Entropia = 6.2731.

Exemplo de algumas imagens e suas entropias calculadas a partir dos histogramas



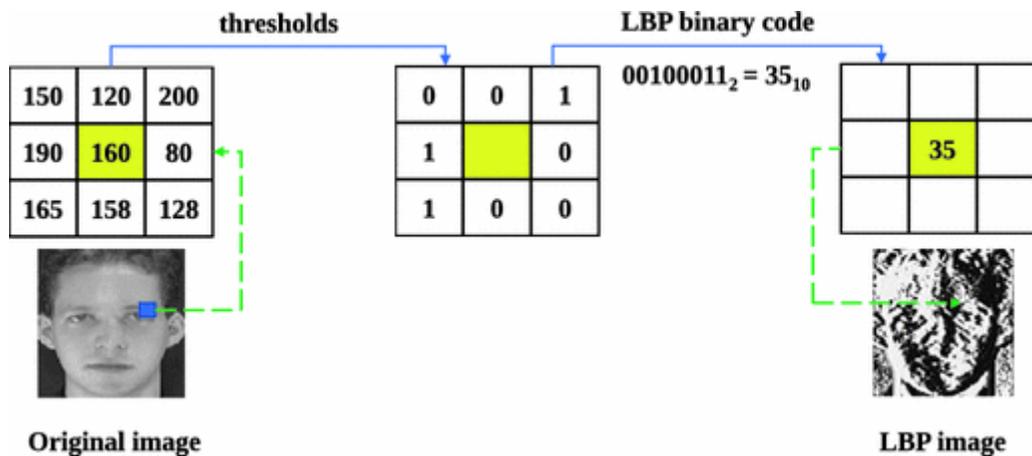
Texturas de Classes Desconhecidas: (d) E = 6.0881; (e) E = 5.1305 e (f) E = 6.1882.

Local binary patterns

- Os padrões binários locais são um tipo de descritor visual usado para classificação em visão computacional.
- O LBP foi descrito pela primeira vez em 1994.
- A partir de um janela de $n \times n$ valores ímpares da imagem se chega a um padrão em binário.

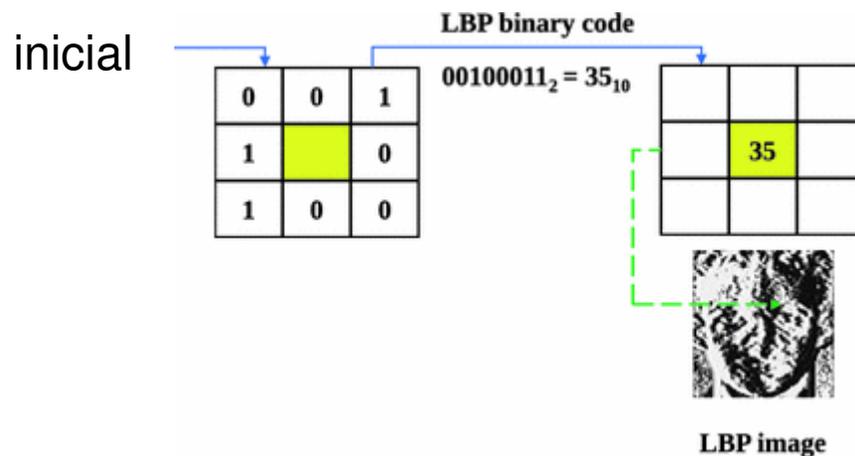
Etapas

- Primeiro limiarizando (*tresholding*) todos os tons maiores (=1) e menores (=0) que o central



Etapas

- Depois fazendo um somatório com as posições possíveis de pesos binários (geração dos valores) em múltiplos de 2^n ($n=0,1,2,\dots,n \times n - 1$) a partir do inicial e esse valor será atribuído ao central



Etapas

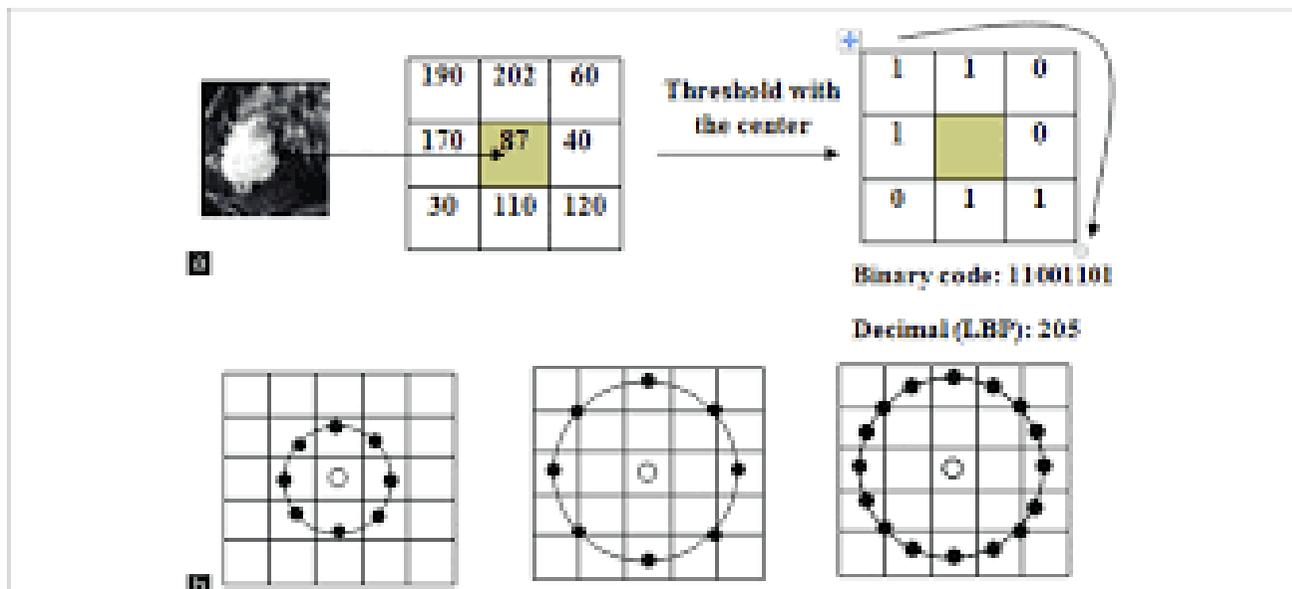
- Depois diversas configurações de possibilidades devem ser geradas, fazendo-se todos os possíveis somatório com as posições possíveis de pesos binários para a geração dos valores, a partir de diversos inícios e esse valor será atribuído ao central:

- $(10001100)_2 = 1+16+32= 59$ (em decimal !)

0	0	1	← inicial
1		0	
1	0	0	

E continua-se por cada pixel da imagem

- Ela passa a ser descritas por esses valores.
- Há diversas variações desta metodologia



- Local Binary Pattern (LBP)

- É um operador não paramétrico para descrever a estrutura local espacial da imagem, mostrando alta capacidade para distinguir características de textura.

$$LBP(x_c, y_c) = \sum_{n=0}^{n-1} S(i_n - i_c)2^n$$

6	5	2
7	6	1
9	3	7

a)

1	0	0
1		0
1	0	1

b)

1	2	4
8		16
32	64	128

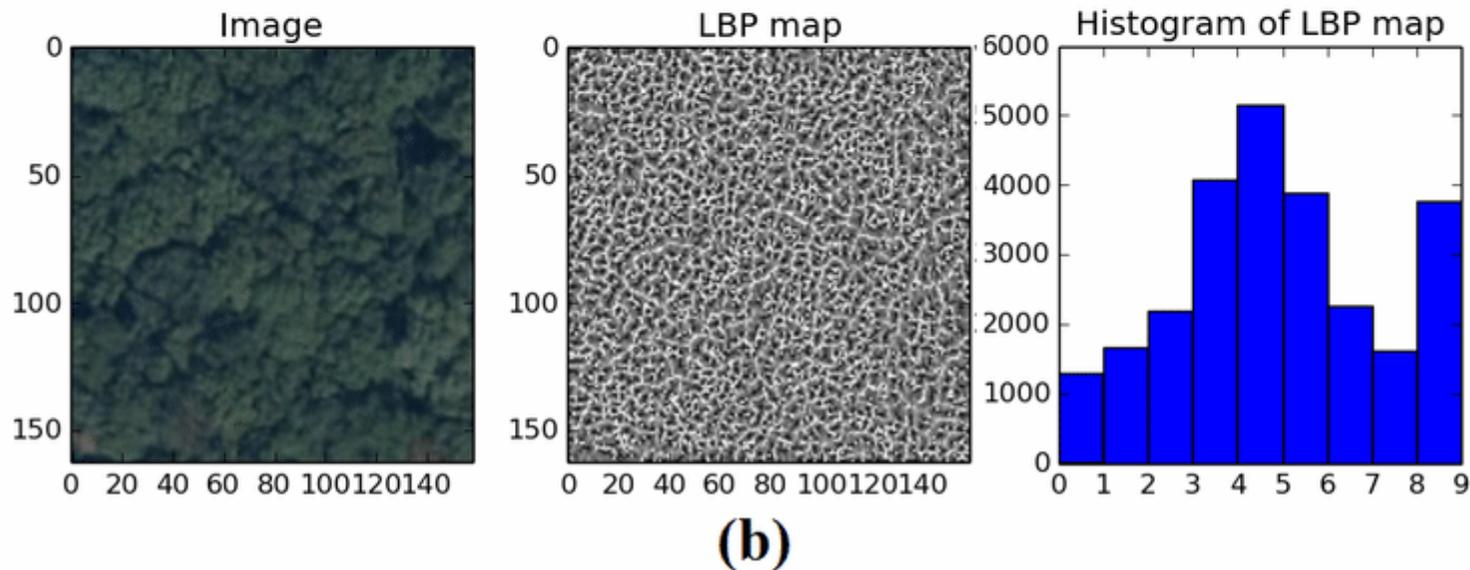
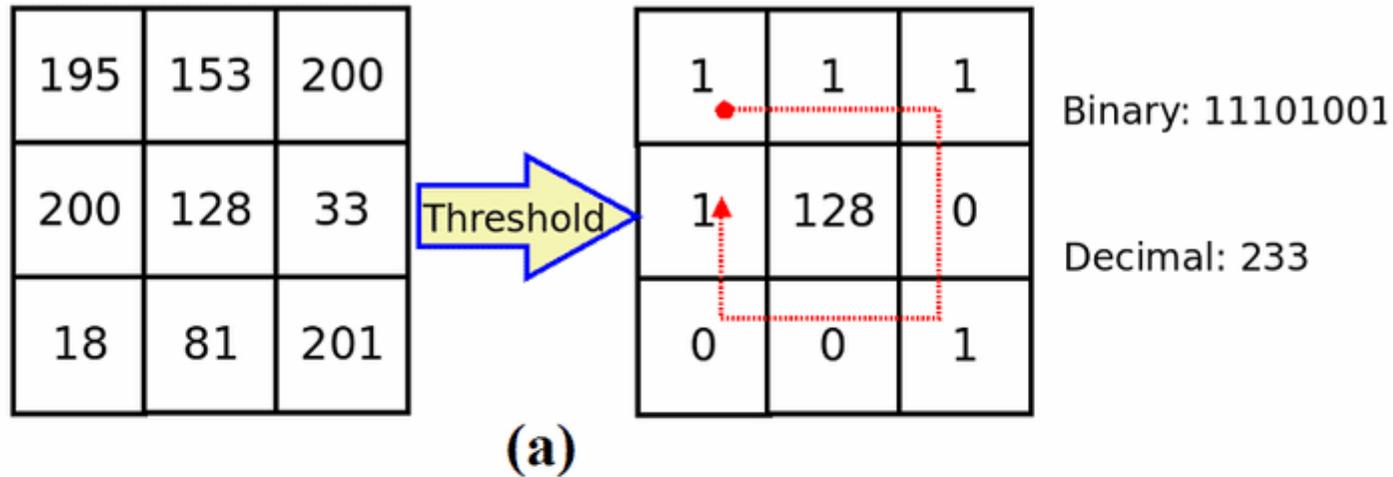
c)

1	0	0
8		0
32	0	128

d)

Histogramas com esses valores são geralmente usados
Para vetor de features e para reconhecer padrões

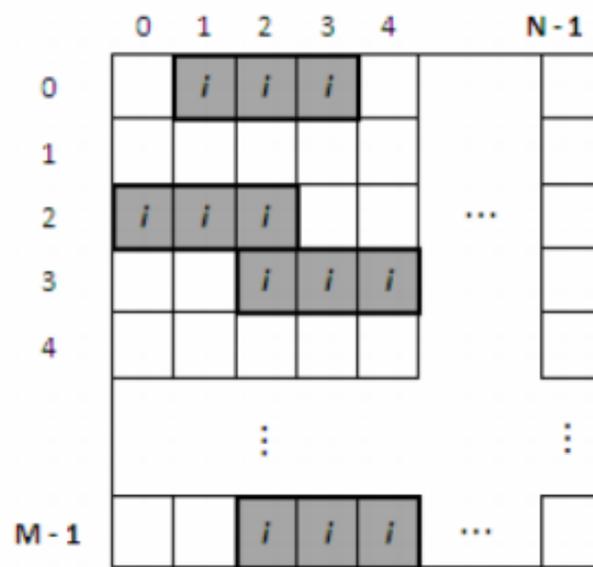
Montando o histograma para ser a o vetor de feature



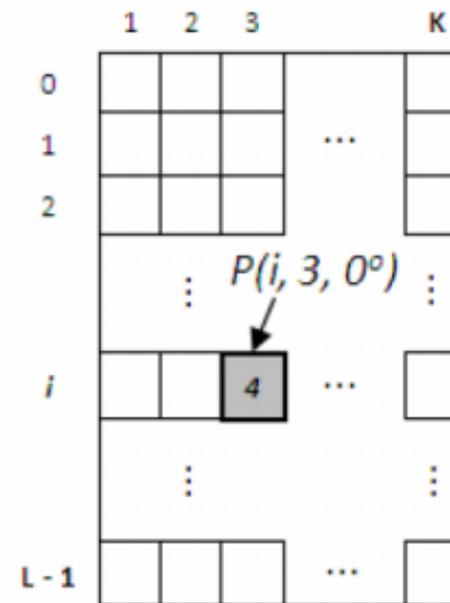
Outros metodos

- Verifique se algum estaria pornto nas ferramentas que voce tem acesso (C# Python, OpenCv, Matlab, etc)

MATRIZ DE COMPRIMENTOS DE CORRIDA DE CINZA (GLRLM)

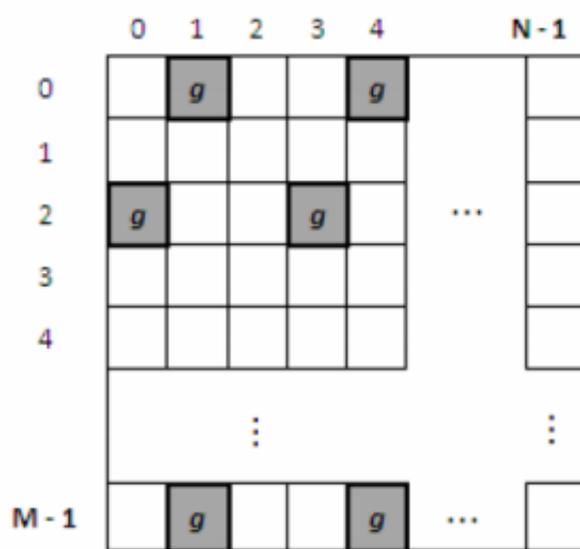


(a)

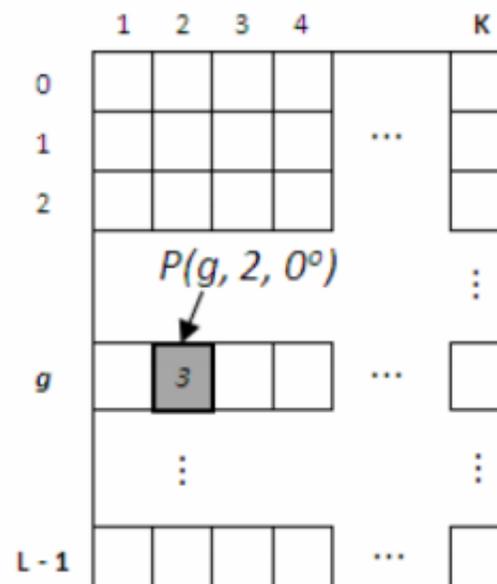


(b)

MATRIZ DE COMPRIMENTOS DE LACUNA DE CINZA (GLGLM)



(a)



(b)

Matriz de frequência de tons corridos em direções: 0, 45 e 90 graus

quando qualquer nível de cinza p é continuamente repetido l vezes, o valor da matriz de comprimento de percurso na posição (p, l) é aumentado em um.

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

Input Image

	1	2	3	4	$\leftarrow l$
0	6	3	0	1	
1	6	2	0	0	
2	9	1	0	0	
3	6	0	0	0	
4	6	0	0	0	

Run Length Matrix(0°)

$\uparrow p$

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):

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

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

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

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

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

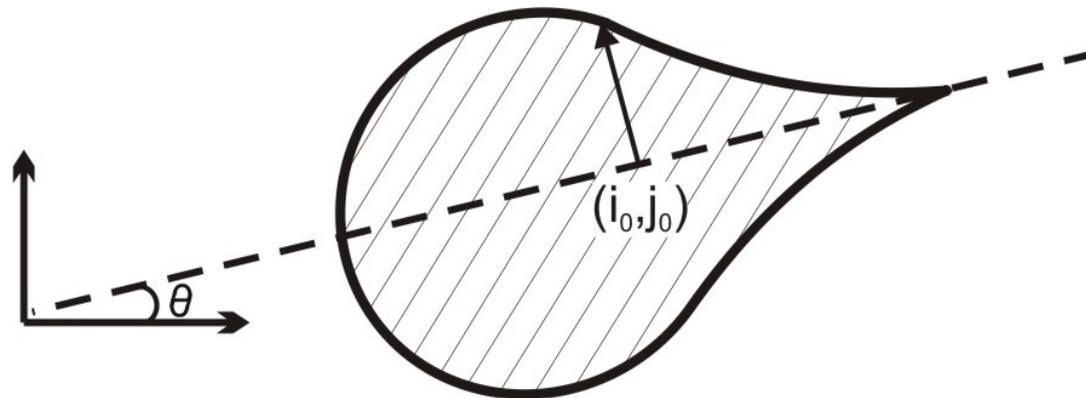
Momentos geométricos invariantes de [Hu](#) (1962):

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

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

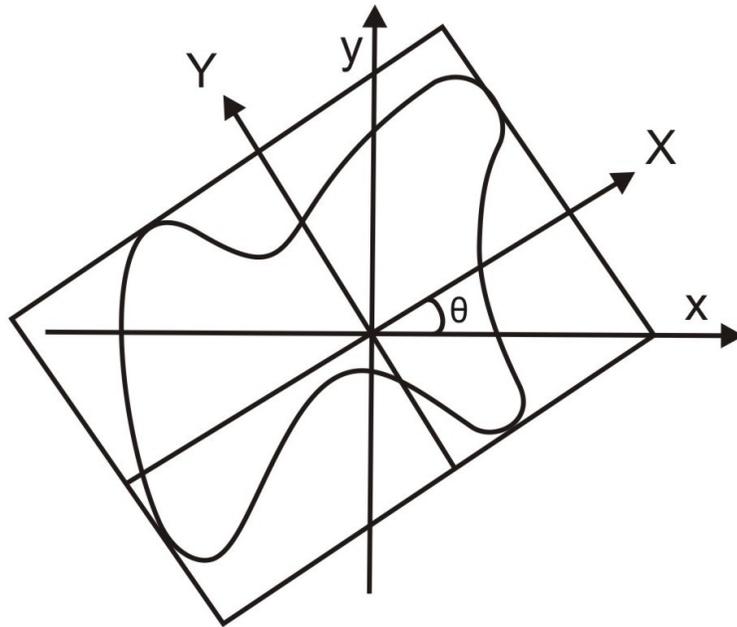
θ - orientação dos eixos principais:

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

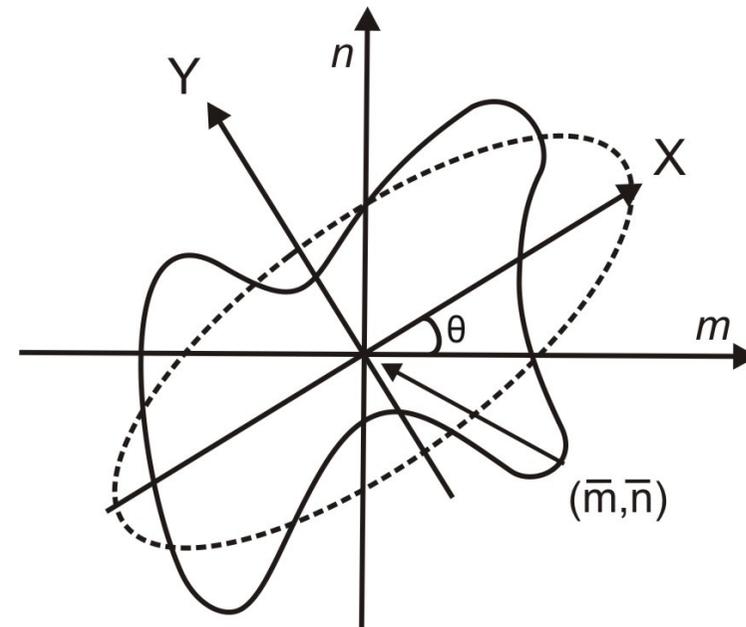


Orientação.

Retângulos e Elipses ajustados



Retângulo ajustado.



Elipse ajustada.

REFERENCES

- [1] Gotlieb, C. C., & Kreyszig, H. E. (1990). Texture descriptors based on co-occurrence matrices. *Computer Vision, Graphics, & Image Processing*, 51(1), 70–86. [https://doi.org/10.1016/S0734-189X\(05\)80063-5](https://doi.org/10.1016/S0734-189X(05)80063-5)
- [2] Haralick, Robert M., Shanmugam, K. A., & Dinstein, I. (1973). Textural Features. *IEEE Transactions on Systems, Man and Cybernetics*, pp. 610–621.
- [3] Mohanaiah, P., Sathyanarayana, P., & Gurukumar, L. (2013). Image Texture Feature Extraction Using GLCM Approach. *International Journal of Scientific & Research Publication*, 3(5), 1–5. <https://doi.org/10.1.1.414.96981>
- [4] Bony, S., Dufresne, J. L., Le Treut, H., Morcrette, J. J., & Senior, C. (2004). On dynamic and thermodynamic components of cloud changes. *Climate Dynamics*, 22(2–3), 71–86. <https://doi.org/10.1007/s00382-003-0369-6>
- [5] Rasp, S., Schulz, H., Bony, S., & Stevens, B. (2019). Combining crowdsourcing and deep learning to explore the meso-scale organization of shallow convection. 1–12. Retrieved from <http://arxiv.org/abs/1906.01906>
- [6] Max Planck Institute for Meteorology. Understanding clouds from satellite images(2019). <https://www.kaggle.com/c/understanding-cloud-organization>
- [7] Hartigan, J. A., & Wong, M. A. (1979). Algorithm AS 136: A K-Means Clustering Algorithm. In *Source: Journal of the Royal Statistical Society. Series C (Applied Statistics)* (Vol. 28). Retrieved from http://www.labri.fr/perso/bpinaud/userfiles/downloads/hartigan_1979_kmeans.pdf

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.

Adriel Dos Santos Araújo , Estudo Da Equivalência Entre Descritores De Textura Baseados Na Matriz De Coocorrência Em Escala De Cinza E Histogramas De Soma E Diferença , Dissertação De Mestrado, UFF, 2018;

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.