



Aula 10 – Reconhecimento de Padrões : **Texturas** (parte 4).

Análise de Imagens - 2015

Aura Conci

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).

Vejam algumas formas de identificá-las

- **Entropia de uma imagem**
- **Coefficiente de Hurst**
- **Coefficientes de Variação Espacial**
- **Dimensão Fractal**
- **Momentos de Intensidades**
- **Matrizes de Co-ocorrência**
- **Descritores de Textura de Haralick**
- **Funções de Auto-correlação**
- **LZW**
- **Matriz de comprimentos corridos**
- **Spatiograms**
- **Descritores de Textura baseados nos Histogramas de Soma e Diferenças**

Entropia de uma imagem

- probabilidade de cada um dos a_j tons (histograma) ou de cada uma das a_j texturas (a partir da contagem de seus texels)

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

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

Entropia de uma imagem (cont)

- Entropia equivale à 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**.

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

Também na forma de $1/\log p(a_j)$ e sem o menos inicial devido as propriedades *logarítmicas*

Coeficiente de Hurst

É uma aproximação da DF (**dimensão fractal**) para imagens:

$$D = \frac{\ln N}{\ln\left(\frac{1}{r}\right)}$$

	0	1	2	3	4	5	6
0	85	70	86	92	60	102	202
1	91	81	98	113	86	119	189
2	96	86	102	107	74	107	194
3	101	91	113	107	83	118	198
4	99	68	107	107	76	108	194
5	107	94	93	115	83	115	198
6	94	98	98	107	81	115	194

Região de 7x7 pixels para exemplificar cálculo do coeficiente de Hurst.

$\sqrt{8}$	$\sqrt{13}$	$\sqrt{10}$	3	$\sqrt{10}$	$\sqrt{13}$	$\sqrt{8}$
$\sqrt{13}$	$\sqrt{8}$	$\sqrt{5}$	2	$\sqrt{5}$	$\sqrt{8}$	$\sqrt{13}$
$\sqrt{10}$	$\sqrt{5}$	$\sqrt{2}$	1	$\sqrt{2}$	$\sqrt{5}$	$\sqrt{10}$
3	2	1	0	1	2	3
$\sqrt{10}$	$\sqrt{5}$	$\sqrt{2}$	1	$\sqrt{2}$	$\sqrt{5}$	$\sqrt{10}$
$\sqrt{13}$	$\sqrt{8}$	$\sqrt{5}$	2	$\sqrt{5}$	$\sqrt{8}$	$\sqrt{13}$
$\sqrt{8}$	$\sqrt{13}$	$\sqrt{10}$	3	$\sqrt{10}$	$\sqrt{13}$	$\sqrt{8}$

Oito grupos de pixels correspondentes às distâncias Euclidianas.

Distância e máxima diferença de nível de cinza para região

Distância (d)	$\ln d$	máxima diferença de nível de cinza Δg para região	$\ln(\Delta g)$
$d=1$	0.000	113-83=30	3.401
$d=\sqrt{2}$	0.346	113-74=39	3.663
$d=2$	0.693	118-74=44	3.784
$d=\sqrt{5}$	0.804	118-68=50	3.912
$d=\sqrt{8}$	1.039	119-68=51	3.931
$d=3$	1.098	198-68=130	4.867
$d=\sqrt{10}$	1.151	198-60=138	4.297
$d=\sqrt{13}$	1.282	198-60=138	4.297
$d=\sqrt{18}$	1,445	202-60=142	4.955

Dados para cálculo da regressão linear.

Interações	$\ln d$	$\ln \Delta g$	$\ln d \ln \Delta g$	$(\ln d)^2$
1	0,00000	3,40120	0,00000	0,00000
2	0,34657	3,66356	1,26969	0,12011
3	0,69315	3,78419	2,62300	0,48045
4	0,80472	3,91202	3,14808	0,64757
5	1,03972	3,93183	4,08800	1,08102
6	1,09861	4,86753	5,34753	1,20695
7	1,15129	4,92725	5,67271	1,32547
8	1,28247	4,92725	6,31908	1,64474
9	1,44519	4,95583	7,16209	2,08856
Σ	7,86173	38,37067	35,63019	8,59489
Σ/n	0,874	4,263		
n	9			

A reta neste caso tem a equação:

$$y = 1,2229x + 3,1952.$$

Coefficiente de Hurst: inclinação da reta, $b=1,2229$.

Coeficientes de Variação Espacial

Coeficiente de variação:

$$Cv = \frac{\sigma}{x} . 100$$

Coeficiente de variação espacial da classe:

$$CVE = \frac{\text{ArcTang}\left(\frac{\bar{x}}{CV}\right)\pi}{180} \sqrt{\bar{x}^2 + CV^2}$$


Dados para cálculo do CVE.

Dist.	Média Classe	CV Classe	CVE Classe	Média CVE classe	CVCVE classe	CVE Textura
1,000	102,500	11,241	150,709	154,522	12,605	230,910
1,414	89,750	16,571	126,698			
2,000	109,250	9,781	162,502			
2,236	91,125	13,667	131,022			
2,828	102,250	15,173	147,145			
3,000	124,500	34,353	168,101			
3,162	113,500	42,245	147,082			
3,606	121,250	35,921	162,219			
4,243	143,750	37,855	195,223			


Exemplo de Aplicação:



(a)



(b)



(c)

Exemplo de uso do CVE: (a) Melanoma; (b) Segmentação considerando a área interior e (c) Localização do contorno ampliada.

Momentos de Intensidades de Regiões ou Medidas de Primeira Ordem

Baseados em estatísticas obtidas considerando
uma *janela móvel* com o *pixel* central circundado
por *pixels* adjacentes.

- **n -ésimo momento do histograma** de uma imagem:

$$\mu_n(z) = \sum_{i=1}^L (z_i - m)^n p(z_i)$$

$$m = \sum_{i=1}^L z_i p(z_i)$$

- **suavidade relativa R** da textura

$$R = 1 - \frac{1}{1 + \sigma^2(z)}$$

- **obliquidade** (*skewness*)

$$v = \frac{\mu_3}{\sigma^3(z)}$$

- **curtose** (achatamento da distribuição)

$$K = \frac{\mu_4}{\sigma^4(z)} - 3$$

Medidas de Segunda Ordem

Matrizes de Co-ocorrência

Descritores de Textura de Haralick


Funções de Auto-correlação

Descritores de Textura baseados nos Histogramas de Soma e Diferenças


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




Probabilidades possíveis para “Listras horizontais” – 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	0,25	0,25	0,25	0,25	0,25	0,25
0	0,5	0,25	0,25	0,25	0,25	0,25	0,25

Probabilidades possíveis para “Listras horizontais” – 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



Probabilidades possíveis para “Listras 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	0,5
0	0,5	0,5	0

Probabilidades possíveis para “Listras 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	0,5
0	0,5	0,5	0

Considere:

- $I(N, M)$ uma imagem quantizada em G níveis de cinza.
- I é uma matrix $G \times G$.
- Cada elemento da matriz é a função que designa a **probabilidade de ocorrência** simultânea de dois nível 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

$$p(i, j, d, \theta) \text{ ou } p(i, j) \Delta x, \Delta y.$$

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 $P(d, \theta)$:

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

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



Matriz de co-ocorrência de tons de cinza.

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).



<p style="text-align: center;">Momento de diferenças ordem k</p>	<p>Distorção da imagem. Este descritor apresenta valores pequenos se p tiver maiores valores na diagonal principal.</p>	$\sum_i \sum_j (i-j)^k p(i, j)$
<p style="text-align: center;">Momento inverso de diferenças de ordem k</p>	<p>Inverso de contraste. Este descritor apresenta valores maiores pequenos se p tiver pequenos valores na diagonal principal.</p>	$\sum_i \sum_j \frac{p(i, j)}{(i-j)^k}$
<p style="text-align: center;">Energia ou Uniformidade</p>	<p>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).</p>	$\sum_i \sum_j p^2(i, j)$

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. 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. Um valor de Homogeneidade 1 representa uma matriz diagonal de co-ocorrência de tons de cinza.</p>	$\sum_i \sum_j \frac{p(i, j)}{1 + i - j }$



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









Gráfico de Correlação x Vizinhaça da: (a) Textura 1; (b) Textura 2 e (c) Textura 3.



**Texturas de Classes Desconhecidas: (a) $E = 6.0881$; (b) $E = 5.1305$ e
(c) $E = 6.1882$.**



Gráficos de Correlação x Vizinhança.

Funções de Autocorrelação



A **autocorrelação** de uma imagem $I(r,c)$, ou a correlação da imagem com ela mesma deslocada em linhas e colunas de (dr,dc) , $I(r+dr,c+dc)$, pode ser utilizada para detectar padrões repetitivos nos elementos de uma textura.

$$\rho(dr,dc) = \frac{\sum_{r=0}^N \sum_{c=0}^N I(r,c) I(r+dr,c+dc)}{\sum_{r=0}^N \sum_{c=0}^N I^2(r,c)} = \frac{I(r,c) I_d(r,c)}{I(r,c) I(r,c)}$$


Descritores de Textura baseados nos Histogramas de Soma e Diferenças

$$S (di,dj) = (i+di , j+dj) + (i, j)$$


$$D (di,dj) = (i+di , j+dj) - (i, j)$$




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”.

Reconhecimento de texturas por LZW

Para texturas o algoritmo *LZW* usa um dicionário inicial de texturas que compõem uma base de características identificadoras para cada um dos tipos de textura a serem analisados futuramente, antes de efetivamente iniciar o processo de **classificação das texturas**.

Os dicionários podem ser subdivididos em:

- 1- Horizontal (H_n): percorre-se a **imagem linha a linha**.
- 2- Vertical (V_n): percorre-se a **imagem coluna a coluna**.



Percurso do algoritmo LZW.

Dicionário:

00 - dois *pixels* pretos

01 – *pixel* preto seguindo de branco

10 – *pixel* branco seguindo de preto

11 – dois *pixels* brancos

Reconhecimento de texturas:

- Treinamento.
- Classificação.

Classificação:

É calculada a taxa de codificação (r_i) a partir dos dicionários horizontal (h_i) e vertical (v_i), para cada uma dessas codificações .

$$r_i = \frac{h_i + v_i}{2}$$

Dimensão Fractal

Estimando a Dimensão Fractal de Imagens Binárias







Estimando a Dimensão Fractal de Imagens em Escala de Cinza

Estimando a Dimensão Fractal de Imagens Binárias

O teorema da **contagem de caixas** (*Box Counting Theorem*) oferece um método simples para estimar a dimensão fractal de imagens binárias (2D).

Sobre a imagem é realizada uma **contagem do número de “quadrados”** de área $N_n(A)$ de **lado $1/2^n$** o qual “cobre” A :

$$DF(A) = \lim_{n \rightarrow \infty} \frac{\text{Log}(N_n(A))}{\text{Log}(2^n)}$$



Divisão recursiva da imagem triângulo de Sierpinsky.

Cálculo experimental da DF do triângulo de Sierpinsky.

n	$N_n (A)$	2^n	$\log N_n (A)$	$\log 2^n$
1	4	2	1,386	0,693
2	12	4	2,484	1,386
3	36	8	3,583	2,079
4	108	16	4,682	2,772
5	324	32	5,780	3,465
6	972	64	6,879	4,158




Gráfico de $\log (N_n (A)) \times \log (2^n)$.

Estimando a Dimensão Fractal de Imagens em Escala de Cinza

Método Box-Counting (BC)

Método *Differential Box-Counting* (DBC)

Método Differential Box-Counting Modificado (MDBC)

Método da Contagem de D-Cubos (CDC)

Método Box-Counting (BC)





Imagem Original e como objeto ou superfície 3D.



Contagem de “caixas”.

Método *Differential Box-Counting* (DBC)

A superfície de uma imagem em níveis de cinza é considerada com espessura 2ϵ (“cobertor”).


A área da superfície é igual ao volume ocupado pelo “cobertor” dividido por 2ϵ .

O “cobertor” é envolvido e aproximado por sua **superfície superior u** e a **superfície inferior b** .

$$u_{\epsilon} = \max \{ u_{\epsilon-1}(i, j) + 1, \max_{|(m, n) - (i, j)| \leq 1} u_{\epsilon-1}(m, n) \}$$

$$b_{\epsilon} = \max \{ b_{\epsilon-1}(i, j) + 1, \min_{|(m, n) - (i, j)| \leq 1} b_{\epsilon-1}(m, n) \}$$

onde $|(m, n) - (i, j)|$ é a distância entre os *pixels* (m, n) de uma imagem, seus vizinhos (i, j) que distam de (m, n) no máximo 1.



Exemplo de limites superior e inferior do “cobertor” em diversas resoluções.

A área da superfície fractal se comporta de acordo com a equação:

$$A(\epsilon) = F \epsilon^{2-D}$$

Obtém-se DF através do ajuste de mínimos quadrados linear no gráfico de $A(\epsilon)$ versus ϵ (escala *log-log*) a partir da equação 7.22, obtendo-se uma linha com inclinação $2 - D$.

O método DBC introduz esse conceito na equação, computando adequadamente $N_n(A)$.

Seja k o **nível de cinza mínimo** da imagem na grade (i,j) , e l o nível de cinza máximo da imagem na grade $(i, j)^n$, na n -ésima interação, então a aproximação DBC é a espessura geral na grade (i, j) .

$$n_n(i, j) = l - k + 1$$

Fazendo a soma das contribuições de todas as grades na interação n tem-se:

$$N_n(A) = \sum n(i, j)$$

A DF pode ser estimada através do ajuste linear de mínimos quadrados no **gráfico de $\log(N_n(A))$ x $\log(1/2^n)$** contado para diferentes dimensões das caixas.

Método *Differential Box-Counting* Modificado (MDBC)

$$DF_n = \frac{\text{Log}(N_n)}{\text{Log}(2^n)}$$


onde N_n é o número *boxes* que **interceptam a imagem** representada:

$$N_n = \sum n_n(i, j)$$

$$N_n(i, j) = \frac{\text{inteiro}(\text{Cinza_Maximo}(i, j) - \text{Cinza_minimo}(i, j))}{s} + 1$$

Método da Contagem de D-Cubos (CDC)

Divisão recursiva de um segmento, um quadrado e um cubo, objetos Euclidianos de dimensão $1D$, $2D$ e $3D$:



Divisões recursivas de objetos $1D$, $2D$ e $3D$.

1-cubo (segmento reto).

Dimensão	Divisões	$N_{n,1\text{-cubos}}$	Regra
1	1	2	2^1
	2	4	2^2
	3	8	2^3

2-cubo (segmento reto).

Dimensão	Divisões	$N_{n,2\text{-cubos}}$	Regra
2	1	4	2^2
	2	16	2^4
	3	64	2^6

3-cubo (cubo).

Dimensão	Divisões	$N_{n,3\text{-cubos}}$	Regra
3	1	8	2^3
	2	64	2^6
	3	512	2^9

O número de **partes idênticas** da divisão recursiva de um *d-cubo* é:

$$N_{n, d\text{-cubos}} = 2^{d \times n}$$

onde d é a dimensão considerada e n é o número de divisões.

A **dimensão fractal** é dada por:


$$DF_n = \frac{\text{Log}(N_{n, d\text{-cubo}})}{\text{Log}(2^n)}$$

$N_{n, d\text{-cubo}}$ é:

$$N_n(i, j) = \frac{\text{inteiro}(\text{Cinza}_{\text{Maximo}}(i, j) - \text{Cinza}_{\text{minimo}}(i, j))}{s} + 1$$


Cálculo dos limites superiores da DF_n

Imagens	Dimensão (d)	Divisões (n)	$N_n(\text{d-cubos})$	$\log(N_{n,d\text{-cubos}})$	$\log(2^n)$	DF_n
Binárias (nenhum canal)	2	1	4	$\log(4)$	$\log(2)$	2
		2	16	$\log(16)$	$\log(4)$	2
		3	64	$\log(64)$	$\log(8)$	2
Em escala de cinza (1 canal)	3	1	8	$\log(8)$	$\log(2)$	3
		2	64	$\log(64)$	$\log(4)$	3
		3	512	$\log(512)$	$\log(8)$	3
(2 canais)	4	1	16	$\log(16)$	$\log(2)$	4
		2	256	$\log(256)$	$\log(4)$	4
		3	4096	$\log(4096)$	$\log(8)$	4
Coloridas (3 bandas)	5	1	32	$\log(32)$	$\log(2)$	5
		2	1024	$\log(1024)$	$\log(4)$	5
		3	32768	$\log(32768)$	$\log(8)$	5
<i>Multiespectrais</i> (acima de 3 bandas)	6	1	64	$\log(64)$	$\log(2)$	6
		2	4096	$\log(4096)$	$\log(4)$	6
		3	262144	$\log(262144)$	$\log(8)$	6



Valores obtidos pelo método CDC ($DF \approx 3.465$) em possíveis associações de bandas para os canais RGB

(4-5-6, 4-6-5, 5-4-6, 5-6-4, 6-4-5, 6-5-4).



Mosaico de texturas naturais e resultado da segmentação com CDC.

Bibliografia

- L. Bastos, P. Liatsis, A. Conci , "**Automatic Texture Segmentation Based on k-means Clustering and Efficient Calculation of Co-occurrence Features**" - Paper ID: 30, Presented in [IWSSIP](#) 15th International Conference on Systems, Signals and Image Processing - published in the paper (ISBN 978-80-227-2856-0) (IEEE catalog number CFP 0855E-PRT) and CD ISBN- 978-80-227-2880-5 (IEEE catalog number: CFP 0855E-CDR) - Proceedings of IWSSIP 2008- Edited by G. Rozinaj, J. Cepko, P. Truchly, J. Vrabec and J. Vojtko, pp. 141-144. (trabalho completo em anais de evento)
- Lucas Bastos, Panos Liatsis, Aura Conci, "[A Novel Algorithm for Grey Level Co-Occurrence Matrix Computation in Real Time Biomedical Image Analysis](#)" [WCCM - ECCOMAS 2008](#) Venice - Italy, 30 June- 4 July, 2008.