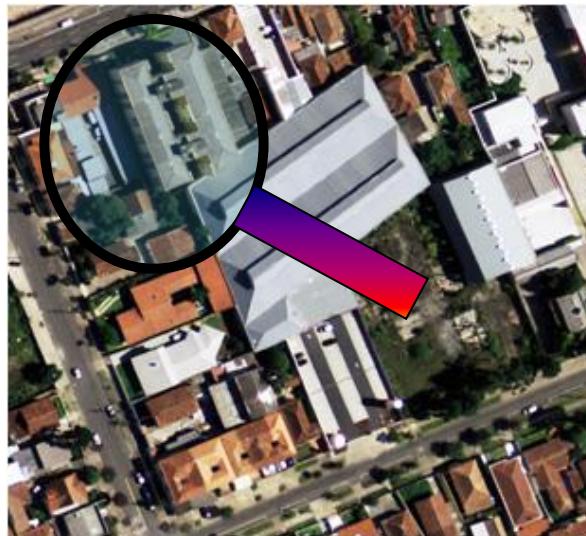


# Sensoriamento Remoto II

## Algoritmos de Segmentação Local



UFPR – Departamento de Geomática  
Prof. Jorge Centeno  
2020  
copyright@ centenet

# segmentação

- Divisão da imagem em regiões, ou partes, compostas por pixels que de alguma maneira apresentam uma característica comum.
- O resultado ideal de uma segmentação seria, por exemplo, a demarcação dos limites espaciais dos objetos visíveis ou suas partes componentes.
- O grau de fragmentação da imagem em segmentos depende da aplicação pretendida. Geralmente, a segmentação é um passo preliminar no processo de reconhecimento de padrões, pois permite simplificar o problema isolando partes da imagem para uma segunda etapa de análise.



# Segmentação local

- geralmente baseados em análise de descontinuidade ou similaridade de valores digitais.
- descontinuidade : a abordagem é dividir a imagem baseando-se em mudanças bruscas dos valores digitais.
- Similaridade: pixels adjacentes com propriedades similares são agrupados para formar regiões uniformes. Exemplo: crescimento de regiões e divisão e fusão de regiões.

# Regras da Segmentação

- Sendo  $R$  a imagem completa, a segmentação é o processo de dividir  $R$  em  $n$  regiões  $R_1, R_2, \dots, R_n$ , tal que:
  - a)  $\bigcup (R_i) = R$
  - b)  $R_i$  é uma região conexa;
  - c)  $R_i \cap R_j = \emptyset$  (vazio) para todo  $i \neq j$ ,  $i \neq j$ ;
  - d)  $P(R_i) = \text{VERDADEIRO}$  para  $i = 1, 2, \dots, n$ ;
  - e)  $P(R_i \cup R_j) = \text{FALSO}$  para  $i \neq j$ ,
- $P(R_i)$  é o predicado lógico sobre os pontos do conjunto  $R_i$  e  $\emptyset$  é o conjunto vazio.

# Regras ...

- (a) indica que a segmentação deve ser completa;
- (b) fixa a existência de regiões conexas.
- (c) indica que as regiões devem ser disjuntas.
- (d) todos os pixels de uma mesma região tem as mesmas características
- (e) indica que regiões diferentes são diferentes no sentido do predicado  $P$ .
  - *VENTURIERI e SANTOS (1998)*



# Crescimento de regiões

# Crescimento de regiões

Procurar grupos de elemento similares



# Crescimento de regiões

1. Para iniciar o crescimento de regiões são necessários pixels semente.
2. A cada iteração, os pixels vizinhos à região são analisados. Se forem similares à região, então são anexados.
3. Para anexar novos pixels na fronteira da região é necessário definir um critério de similaridade. Por exemplo, distância Euclidiana entre o pixel semente e o pixel novo.

Considere a seguinte matriz (poderia ser uma pequena imagem)



99	87	78	83	98	83	87
99	87	78	83	98	83	87
67	99	9	89	71	89	99
69	87	10	83	77	83	87
92	13	11	12	98	92	13
89	87	13	83	78	83	87
09	77	78	73	98	73	77
99	87	10	83	77	83	87

A princípio não conhecemos os grupos espacialmente contínuos e uniformes, então vamos escolher um pixel aleatoriamente.

Por exemplo: linha 4 , coluna 3.

Este pixel tem valor  $v(4,3)=9$  e será considerado a “semente de uma região”. Então, o valor típico da região é 9.

A seguir, analisamos a vizinhança deste pixel (4,3). Neste exemplo consideraremos a vizinhança 8, ou seja, usando uma janela 3x3.

99	87	78	83	98	83	87
99	87	78	83	98	83	87
67	99	9	89	71	89	99
69	87	10	83	77	83	87
92	13	11	12	98	92	13
89	87	13	83	78	83	87
09	77	78	73	98	73	77
99	87	10	83	77	83	87

Devemos definir o grau de “similaridade” aceitável. Consideremos que se a diferença entre o valor do pixel e o valor da semente for menor que 20, o pixel pertence à região:

$$|v(i,j) - 20| \leq 20$$



99	87	78	83	98	83	87
99	87	78	83	98	83	87
67	99	9	89	71	89	99
69	87	10	83	77	83	87
92	13	11	12	98	92	13
89	87	13	83	78	83	87
09	77	78	73	98	73	77
99	87	10	83	77	83	87

Analisando os 8 vizinhos, calculamos a diferença  $v(i,j)$  e constatamos que um vizinho pode ser aceito, aquele localizado na mesma coluna e na linha abaixo:

Linha\_v=linha+1  
Coluna\_v=coluna

Como foi incluído um vizinho, a região cresceu, logo suas fronteiras mudaram. Devemos repetir a análise, com os novos vizinhos.



99	87	78	83	98	83	87
99	87	78	83	98	83	87
67	99	9	89	71	89	99
69	87	10	83	77	83	87
92	13	11	12	98	92	13
89	87	13	83	78	83	87
09	77	78	73	98	73	77
99	87	10	83	77	83	87

Achamos novos vizinhos parecidos. Então a região continua crescendo.

Devemos repetir a análise.



99	87	78	83	98	83	87
99	87	78	83	98	83	87
67	99	9	89	71	89	99
69	87	10	83	77	83	87
92	13	11	12	98	92	13
89	87	13	83	78	83	87
09	77	78	73	98	73	77
99	87	10	83	77	83	87

Nenhum vizinho novo com valor similar a 20 foi encontrado. Então, A região parou de crescer.,

Neste ponto, todos os pixels localizados são “similares” e formam uma região contínua no espaço.

# Split / Merge

Dividir e depois juntar

Neste caso se parte da imagem como uma grande região única.

1. Em cada iteração é se avalia se a(s) região(ões) é uniforme. Caso não seja uniforme, divide-se a região em 4 quadrantes e se repete a análise efetuando a divisão progressiva da imagem em quadrados cada vez menores.
2. Como a divisão é progressiva, sua evolução pode ser representada por uma árvore quaternária (quadtree)
3. Importante: definir critério de uniformidade.

# quadtree

“Uniformidade”: Região é uniforme se  $|\min - \max| < 20$

1	2	3	4	3	6	2	2
1	1	1	1	1	2	1	1
1	1	1	1	1	1	1	2
1	2	8	2	3	91	90	1
1	2	2	1	91	82	92	93
1	2	2	91	91	82	92	93
1	2	2	91	91	82	92	93
1	2	2	1	91	82	92	93

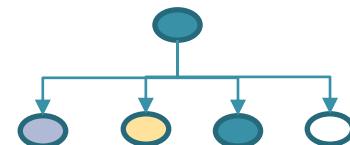
Considerando a imagem toda como uma região.  
A região é uniforme?

Não. Min=1: max=91. dif=90.

Como a região não é uniforme, dividimos ela em quatro partes.

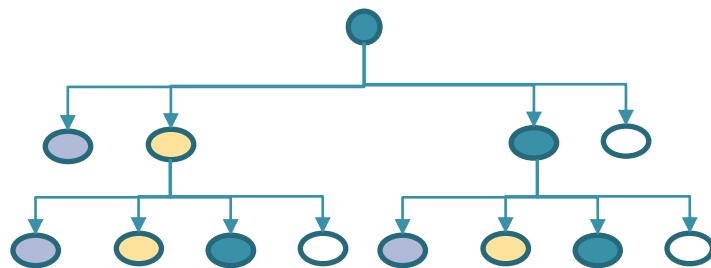
- Agora repetimos a análise considerando estas novas regiões.  
As 4 regiões são uniformes?

1	2	3	4	3	6	2	2
1	1	1	1	1	2	1	1
1	1	1	1	1	1	1	2
1	2	8	2	3	91	90	1
1	2	2	1	91	82	92	93
1	2	2	91	91	82	92	93
1	2	2	91	91	82	92	93
1	2	2	1	91	82	92	93





1	2	3	4	3	6	2	c 2
1	1	1	1	1	2	1	1
1	1	1	1	1	1	1	2
1	2	8	2	3	91	90	1
1	2	2	1	91	82	92	93
1	2	2	91	91	82	92	93
1	2	2	91	91	82	92	93
1	2	2	1	91	82	92	93



d- Todas são uniformes



1	2	3	4	3	6	2	2
1	1	1	1	1	2	1	1
1	1	1	1	1	1	1	2
1	2	8	2	3	91	90	1
1	2	2	1	91	82	92	93
1	2	2	91	91	82	92	93
1	2	2	91	91	82	92	93
1	2	2	1	91	82	92	93

Não é necessário dividir mais as regiões. Chegamos a obter somente regiões uniformes.

Porém:

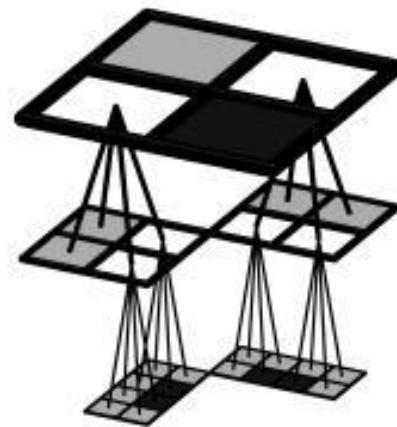
d)  $P(R_i) = \text{VERDADEIRO}$  para  $i = 1, 2, \dots, n$ ; OK!

e)  $P(R_i \cup R_j) = \text{FALSO}$  para  $i \neq j$ , FALSO!

Existem regiões adjacentes que são similares.

e- Juntar similares/adjacentes

1	2	3	4	3	6	2	2
1	1	1	1	1	2	1	1
1	1	1	1	1	1	1	2
1	2	8	2	3	91	90	1
1	2	2	1	91	82	92	93
1	2	2	91	91	82	92	93
1	2	2	91	91	82	92	93
1	2	2	1	91	82	92	93

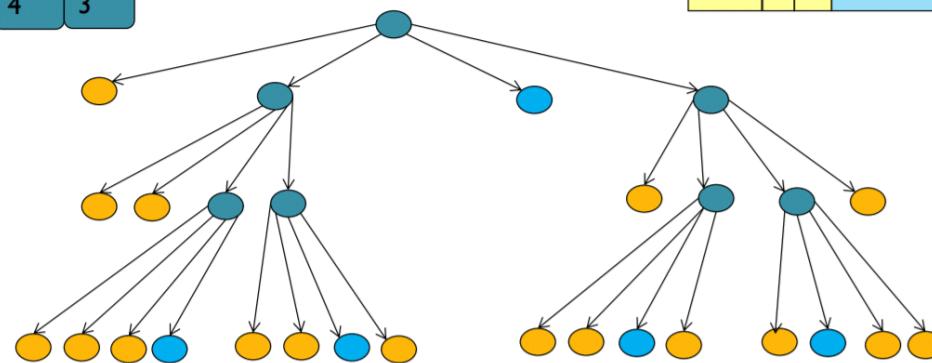
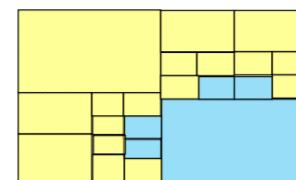


<http://graphics.cs.niu.edu/projects/egview/index.html>

1	2	3	4	3	6	2	2
1	1	1	1	1	2	1	1
1	1	1	1	1	1	1	2
1	2	8	2	3	91	90	1
1	2	2	1	91	82	92	93
1	2	2	91	91	82	92	93
1	2	2	91	91	82	92	93
1	2	2	1	91	82	92	93

## quadtree

- não uniforme
- uniforme (A)
- uniforme (B)



# Sensoriamento Remoto II

Segmentação FNEA (*eCognition*)

UFPR – Departamento de Geomática  
Prof. Jorge Centeno  
2016  
copyright@ centenet

- a segmentação de imagens baseada em dados espectrais tem por finalidade agrupar pixels adjacentes segundo um critério de similaridade puramente espectral.
- Este método não leva em consideração a forma dos segmentos resultantes, sua uniformidade em termos espaciais.

# Fractal Net Evolution Approach

Um algoritmo que leva em consideração os dois aspectos é o método de segmentação conhecido como FNEA, disponível no software eCognitions de Definiens.

- Método baseado em crescimento de região.
- É similar ao método de crescimento de regiões por agregação de pixels tradicional. A diferença reside no critério usado para agregar ou não um pixel ou uma região

# Segmentação FNEA

Inicialmente, cada pixel da imagem é considerado como sendo uma região.

A cada passo, as duas regiões que geram um novo segmento mais uniforme em termos espectrais e espaciais são fundidas.

Para isto, cada região e suas regiões vizinhas são analisadas.

O par de vizinhos que mais se assemelham é escolhido para a fusão

Caso exista mais de um vizinho semelhante, é escolhido o que possui menor fator de heterogeneidade

O processo continua até que um número de iterações seja atingido ou não haja mais fusões

- Para iniciar a segmentação é necessário definir o grau de uniformidade espacial e espectral desejado.
- A cada iteração é então necessário analisar o custo de cada possível fusão e escolher aquela mais adequada para a finalidade, descartando as fusões mais heterogêneas, segundo o critério fixado.

# Heterogeneidade espectral

A heterogeneidade espectral pode ser descrita pela variância ou desvio padrão dos pixels (do segmento) em cada banda. É adotado o somatório dos desvios padrão ( $\sigma$ ) dos valores espectrais em cada banda ( $c$ ) ponderados com o peso ( $w$ ) atribuído para cada banda:

$$h_{\text{espectral}} = \sum_c w_c \cdot \sigma_c$$

1	2	1	3	2	1
4	2	4	2	3	2
3	4	7	6	9	8
1	3	9	7	8	10

- Quais regiões devem ser combinadas para produzir um grupo mais uniforme, considerando os valores?
- Qual combinação produz um grupo com menor desvio padrão ou Variância menor?

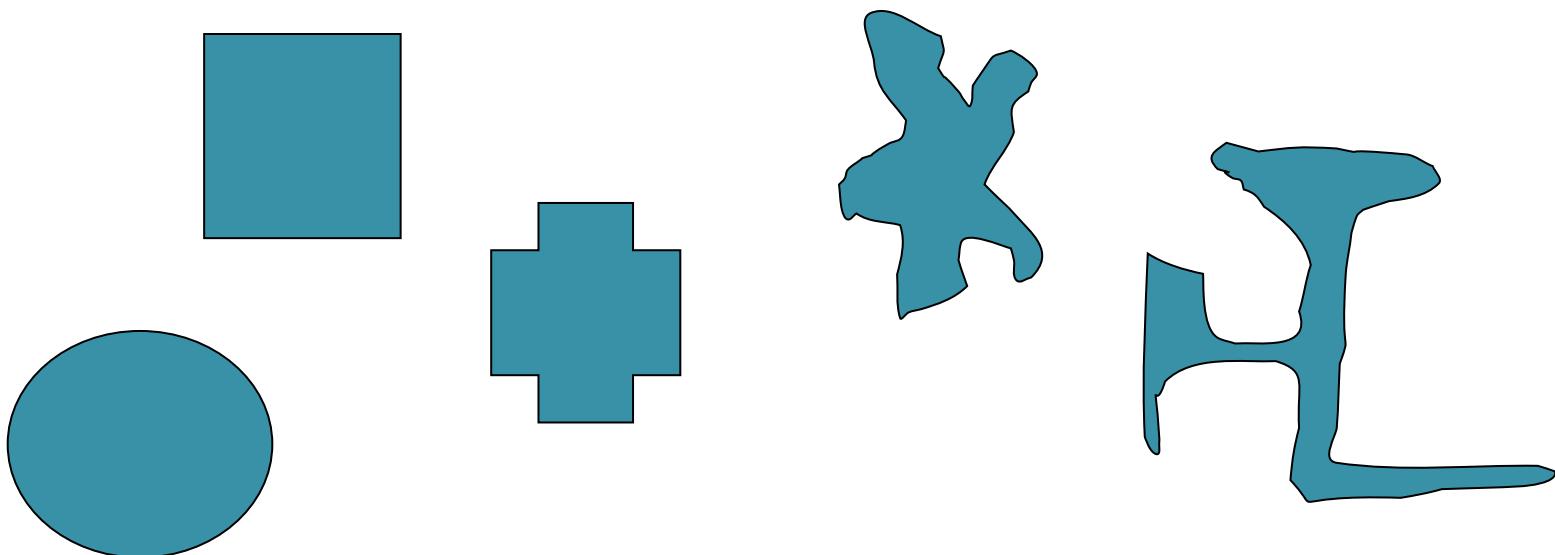
- A uniformidade espacial pode ser medida em termos de:
  - Compacidade
  - Suavidade (dos contornos)

# Uniformidade espacial

- A forma: compacidade
- Uma região numa imagem digital é dita compacta, se existe grande concentração de seus pixels em torno de um ponto, por exemplo seu centróide.

# compacidade

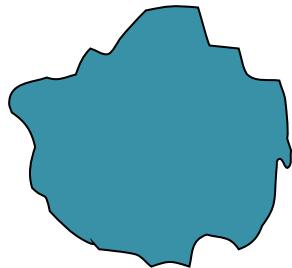
- Para uma mesma área: a compacidade decresce na medida em que os pixels se afastam do centro da região.



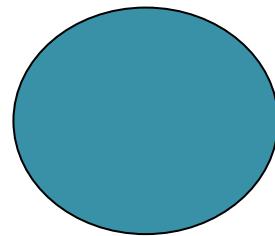
# Heterogeneidade espacial compacidade

- Sendo  $A$  a área da região ( $A=N$ , numero de pixels) e  $P$  seu perímetro, a área da circunferência equivalente é dada por :
- $A = \pi * R^2$   $A=N$
- Do que pode-se calcular seu raio como:
- $R = (N/ \pi )^{1/2}$
- E o perímetro desta circunferência é:
- $P_c = 2 * R * \pi$
- Substituindo:
- $P_c = 2 * \pi * (N/ \pi )^{1/2} = 2 * (\pi * N)^{1/2}$
- O coeficiente de compacidade é calculado comparando o perímetro da região com o perímetro da circunferência equivalente.
- $C_c = L/ P_o = L/ (2 * \pi * N)^{1/2}$
- $C_c = 1/ (2\pi)^{1/2} * L/ (N)^{1/2}$
- $C_c = L/ (N)^{1/2}$

# Coeficiente de compacidade



Área = N pixels  
Perímetro = L



Área = N pixels  
Perímetro = P<sub>c</sub>

- $A = N = \pi * R^2$
- $R = (N / \pi)^{1/2}$
- $\text{Perímetro} : P_c = 2 * \pi * R$
- ou
- $P_c = 2 * \pi * (N / \pi)^{1/2} = 2 * (\pi * N)^{1/2}$

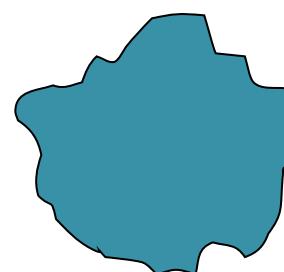
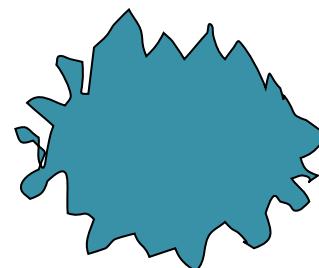
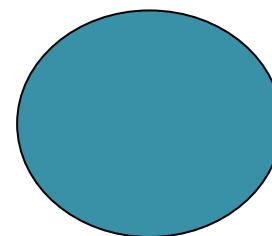
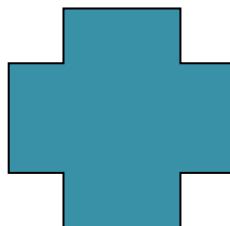
$$Cc = L / P_o = L / (2 * \pi * N)^{1/2}$$

$$Cc = (1 / (2\pi)^{1/2}) * L / (N)^{1/2}$$

$$Cc = L / (N)^{1/2}$$

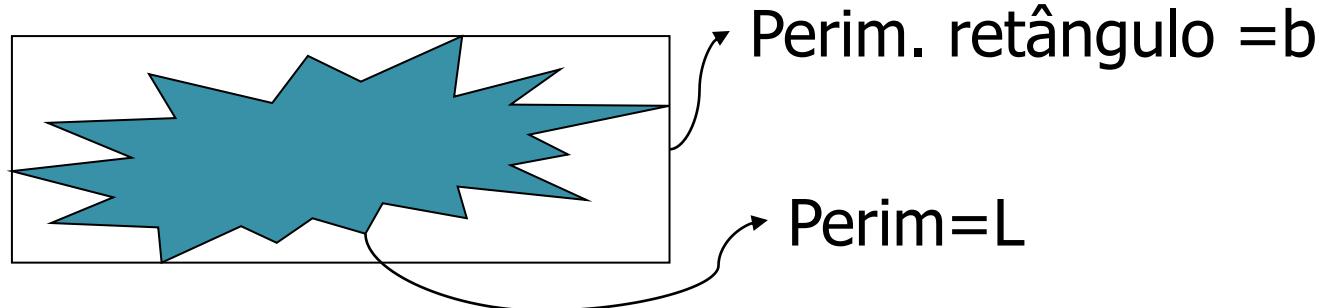
# Uniformidade espacial

- **suavidade** do contorno
- O contorno de uma forma é suave não apresenta variações bruscas.



# suavidade

- A suavidade do contorno de uma região é obtida comparando o perímetro da região com o perímetro do menor retângulo envolvente, paralelo ao raster.

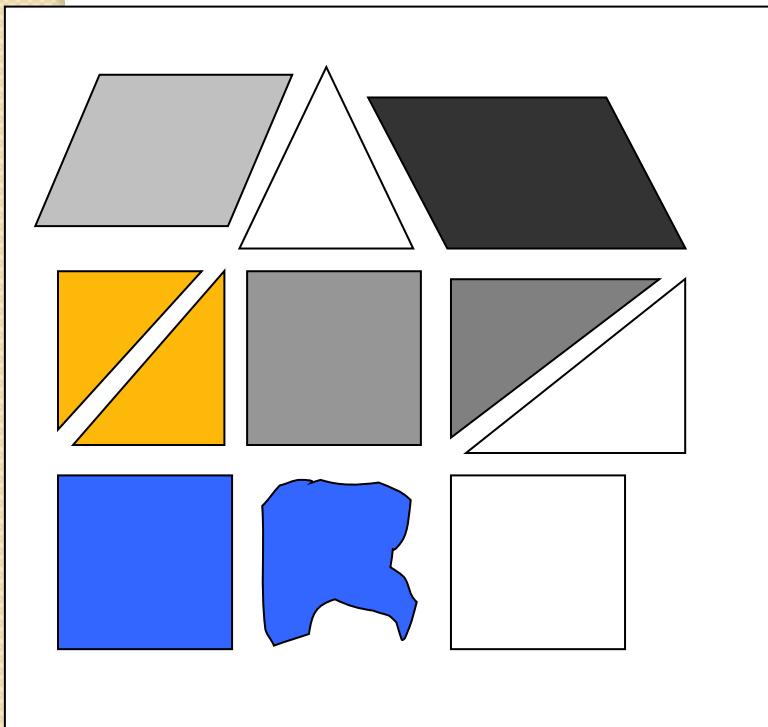


$$h_{\text{forma\_suavidade}} = L / b$$

# Heterogeneidade espacial

- a) compacidade
- B) suavidade

# similaridade



- A cada iteração, a fusão que gera o segmento mais uniforme é escolhida.
- Quais segmentos deveriam ser fundidos para gerar uma imagem mais uniforme em termos:
  - A) espectrais?
  - B) espectrais e espaciais?
  - C) espaciais?

# Uniformidade

Espectral

espacial

Se espacial:

Compacta

suave

análise

Espacial

Espectral

Compacidade?

Suavidade?

# Segmentação eCognition

- O custo de fusão  $f$  de dois objetos é dado por

$$f = w_{espectral} \cdot h_{espectral} + (1 - p) \cdot h_{forma}$$

sendo  $w_{espectral}$  um peso para o critério espectral no intervalo de 0 a 1

$h_{espectral}$  é a heterogeneidade espectral

$h_{forma}$  é a heterogeneidade da forma

- Haverá fusão entre os objetos se o custo de fusão for menor que um critério definido como escala

# Segmentação eCognition

- Heterogeneidade da forma:

$$f = w_{espectral} \cdot h_{espectral} + (1 - w_{espectral}) \cdot h_{forma}$$

- Ou  $w_{forma} = 1 - w_{espectral}$
- sendo  $w_{forma}$  um peso para o critério de compacidade no intervalo de 0 a 1

# Cálculo de h

- Espectral

$$h_{\text{espectral}} = \sum_c w_c \cdot \sigma_c$$

Soma das variâncias

- Espacial     $h_{\text{forma}}$   
                  compacidade

Combinação:  
Compacidade e suavidade

$$h_{\text{forma\_compacidade}} = L / (N)^{1/2}$$

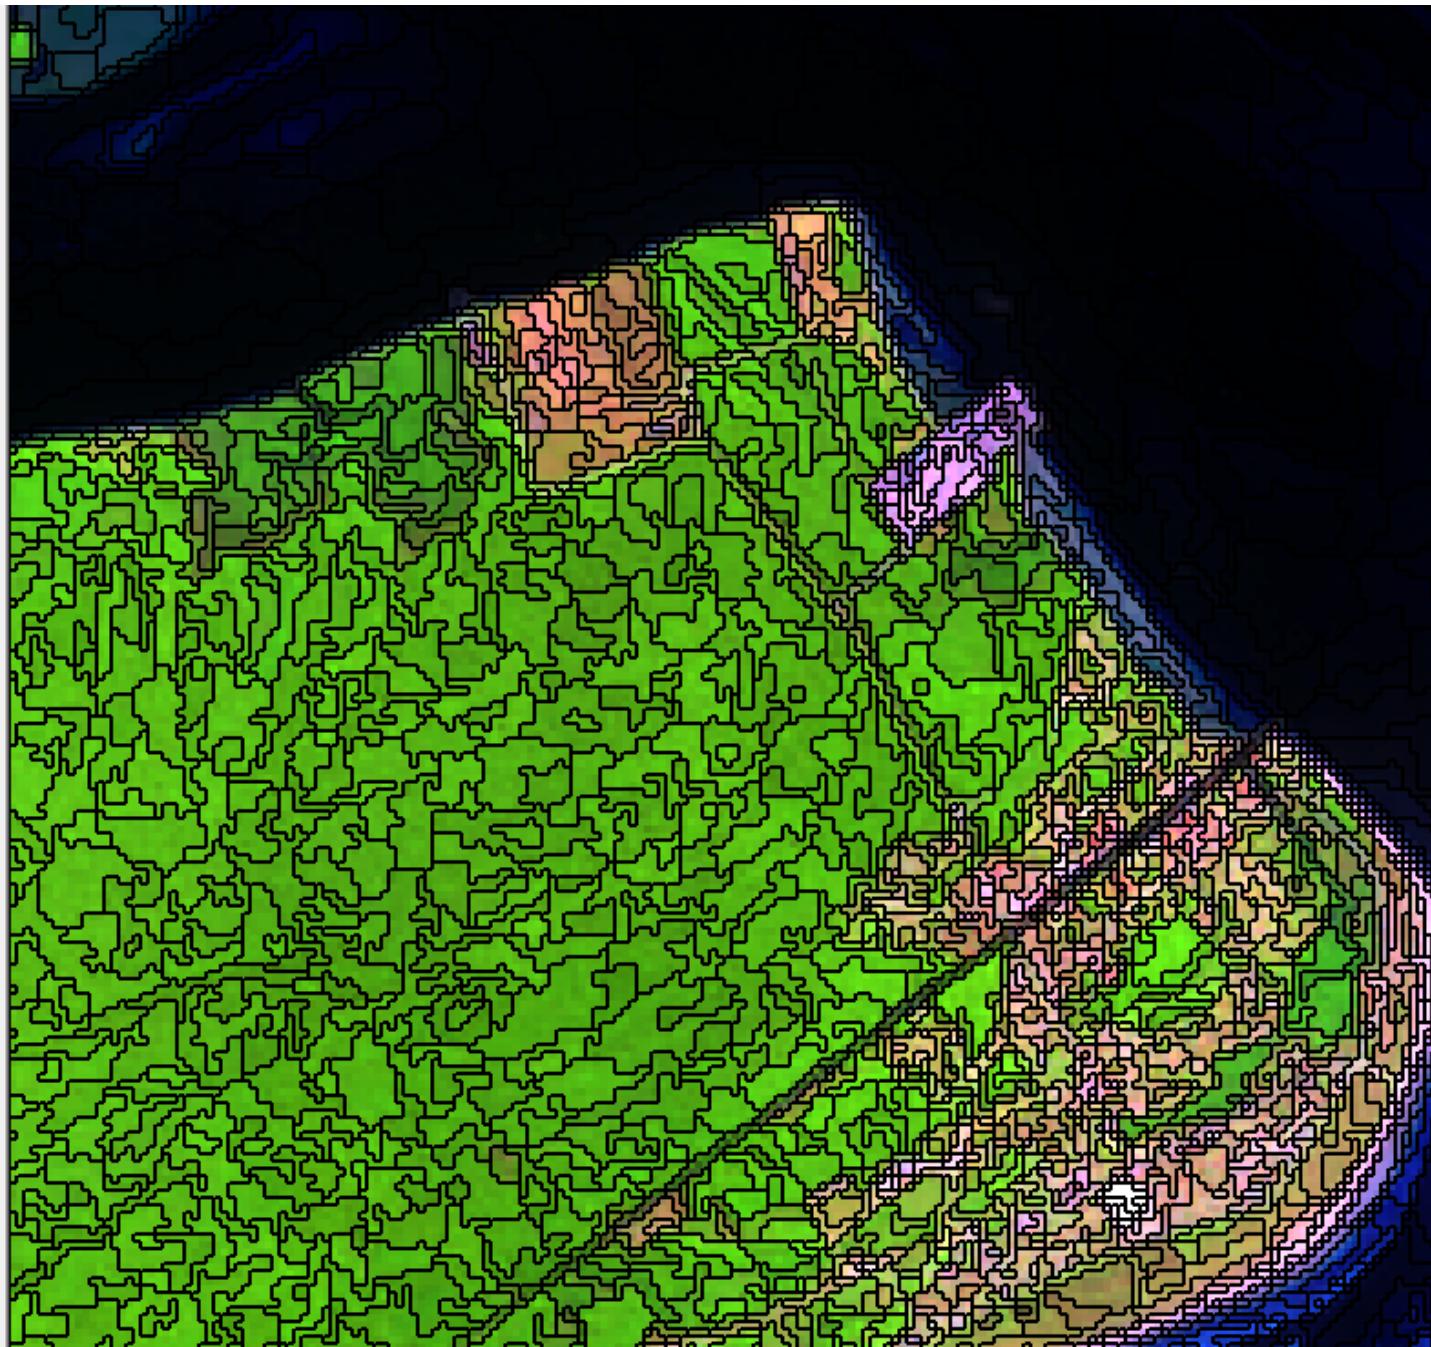
suavidade

$$h_{\text{forma\_suavidade}} = L / b$$

# Cálculo de h forma

- Espacial
- $h_{\text{forma}} = p \cdot h_{\text{forma\_compacidade}} + (1-p) \cdot h_{\text{forma\_suavidade}}$

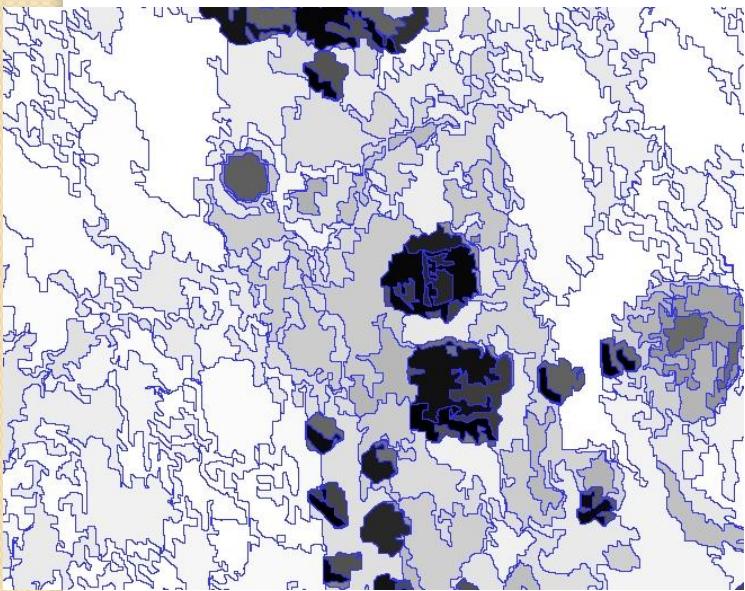
P variando de 0-1...



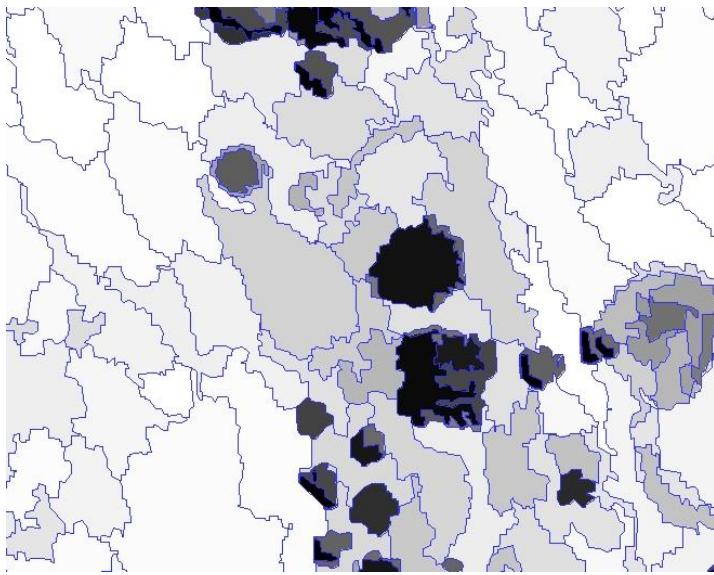


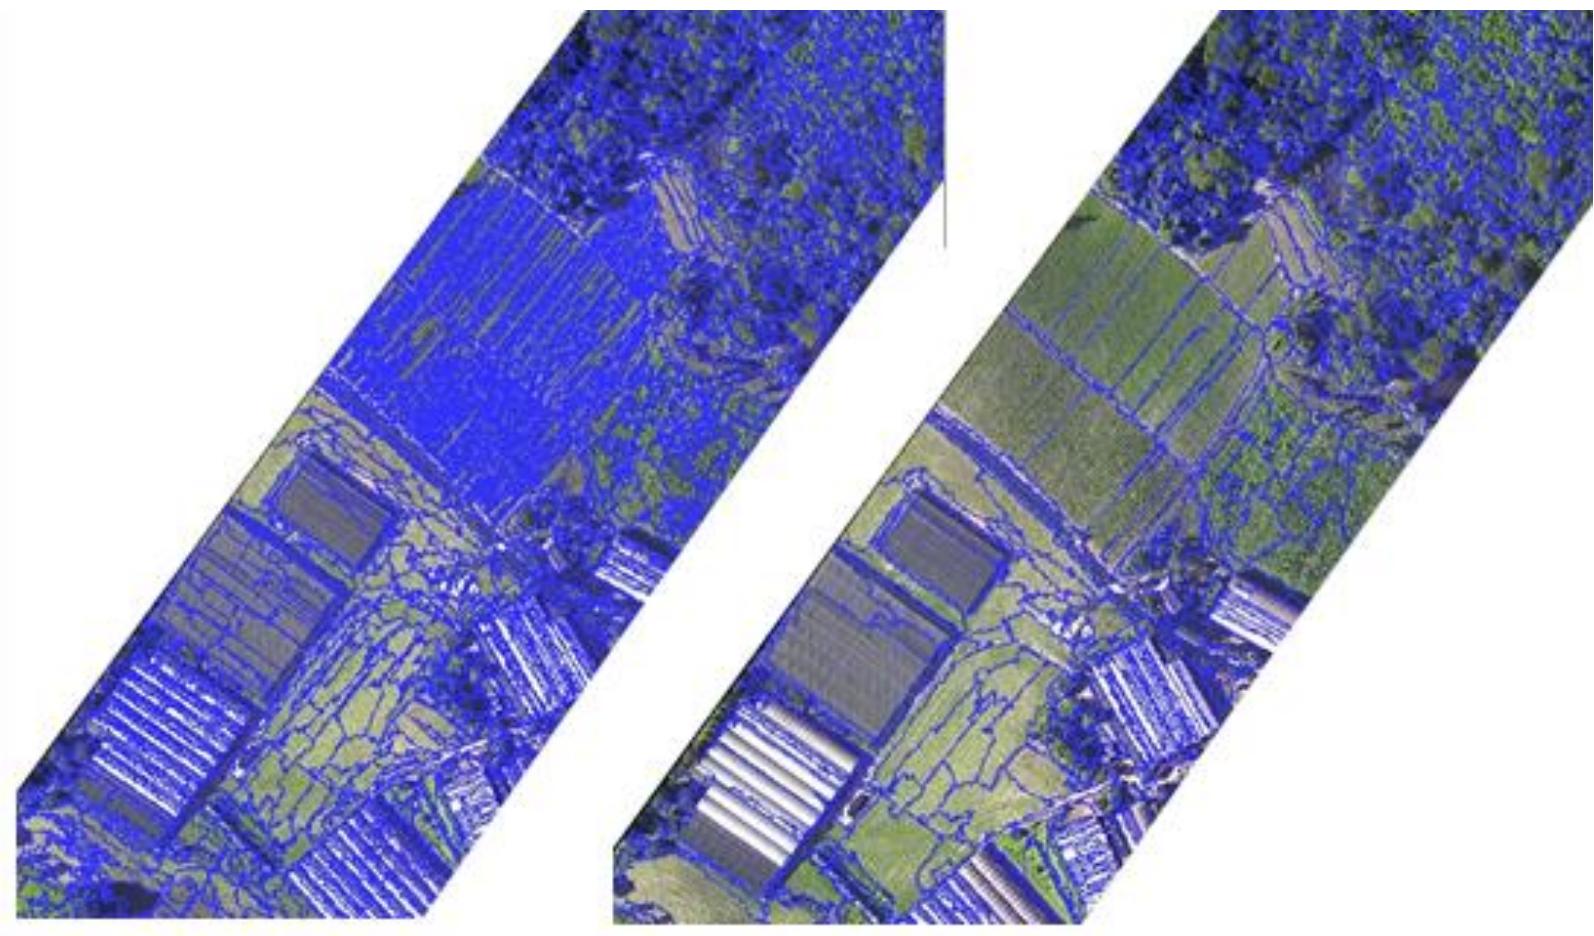
**(A) FATOR DE FORMA IGUAL A 0,1. (B) FATOR DE FORMA IGUAL A 0,4.**

**(a)**



**(b)**





# observa̞o

A grande variedade de imagens, com a correspondente variação das propriedades dos objetos nelas visíveis, torna difícil a obtenção de uma solução geral para todos os problemas de segmentação. Por isso, existe, na atualidade, uma grande variedade de métodos de segmentação desenvolvidos para finalidades específicas.