

# Segmentação de imagens

24 de maio de 2002

Nina S. T. Hirata  
Depto. de Ciência da Computação  
IME - USP

A **segmentação de imagens** consiste em subdividir uma imagem em regiões ou objetos que a constituem. Geralmente, a segmentação constitui um passo preliminar à análise de imagens e a noção de região ou objeto pode depender da particular aplicação ou análise pretendida.

Idealmente, deseja-se que a segmentação seja automática. No entanto, devemos estar cientes de que a segmentação é uma das tarefas mais difíceis em processamento de imagens e a falha na segmentação implicará falhas na posterior análise. Portanto, na medida do possível deve-se controlar o ambiente e os dispositivos de aquisição de imagens de forma que as imagens obtidas sejam fáceis de segmentar.

Os algoritmos de segmentação de imagens são em geral baseadas em duas características: detecção de descontinuidades (bordas, linhas e pontos isolados) e de similaridades.

O resultado da segmentação é também uma imagem, porém deve-se notar que os valores dos pixels da imagem resultante representam informações sobre as regiões e objetos presentes na imagem (não são apenas intensidades de luz, como nas operações de filtragem e restauração).

Referências: capítulo 10 de [1] ou capítulo 7 de [2], capítulo 2 de [3].

## 1 Detecção de descontinuidades

Podemos pensar em três tipos de descontinuidades que constituem objetos de interesse em uma imagem: pontos isolados, linhas e contornos.

Algumas máscaras que atuam no domínio espacial podem ser utilizadas para realçar estes objetos. A maior parte das máscaras tenta realçar as diferenças de intensidade entre pixels vizinhos. Por exemplo, uma máscara para realçar pontos isolados pode ser a seguinte:

-1	-1	-1
-1	8	-1
-1	-1	-1

## 2 Thresholding

Thresholding pode ser útil como ferramenta de segmentação quando desejamos separar objetos do fundo. A imagem resultante de um thresholding é uma imagem binária. Portanto, em geral, o thresholding deve ser a última etapa em um processo de segmentação pois a perda de informação (devido à binarização) é grande.

Thresholding simples funciona quando os pontos correspondentes aos objetos têm tons de cinza distintos do tom de cinza do fundo (por exemplo quando objetos são mais escuros ou mais claros em relação ao fundo). Uma combinação de thresholding simples pode ser utilizado se os objetos correspondem a faixas (eventualmente mais de uma faixa) de tons de cinza que não tem interseção com os tons de cinza do fundo.

Quando a imagem apresenta luminosidade irregular (muitas vezes devido a condições não uniformes de iluminação na aquisição da imagem), objetos podem aparecer mais escuros em parte da imagem e mais claros em outra parte, impossibilitando uma segmentação simples. Nestes casos, pode-se particionar a imagem em regiões homogêneas (com relação a luminosidade) e aplicar um limiar de thresholding adequado para cada região. Existem também métodos adaptativos nos quais o limiar de thresholding é escolhido pontualmente levando-se em conta as características locais ou globais.

### 3 Abordagens baseadas em similaridades

Nestas abordagens, considera-se que os pontos das partes constituintes de uma imagem podem ser caracterizados por algum critério de similaridade. O objetivo é, então, particionar a imagem de forma que quaisquer dois pontos façam parte de uma única região se, e somente se, forem similares segundo este critério.

Alguns critérios de similaridade são: a intensidade do ponto (por exemplo, dois pontos podem ser considerados similares se e somente se a diferença absoluta dos níveis de cinza for menor do que um certo valor); padrão (dois pontos podem ser considerados similares se fazem parte de um mesmo padrão presente na imagem. Para isto, em geral é necessário analisar uma vizinhança desses pontos); atributos (dois pontos podem ser considerados similares se os valores de um conjunto de atributos é bastante próximo. Os atributos podem ser vários: intensidade do ponto, média da intensidade em uma determinada vizinhança, variância da intensidade em uma determinada vizinhança, valor máximo/mínimo/mediano em uma vizinhança, etc).

#### 3.1 Crescimento de regiões

A idéia básica desta abordagem consiste em inicialmente impor marcadores (sementes) para cada região, de forma manual ou automática. Em seguida, as regiões são formadas crescendo-se as sementes. O processo de crescimento de regiões consiste em agregar à região da semente os pontos vizinhos que são similares aos pontos da região. Este processo é interrompido quando nenhum ponto pode mais ser agregado e nenhuma das regiões.

Note que, neste processo, duas sementes distintas podem eventualmente formar uma única região. Além disso, alguns pontos podem não ser agregados a nenhuma das sementes. Neste caso, eles formarão uma região extra.

#### 3.2 Splitting & Merging de regiões

Nesta abordagem, a imagem original é inicialmente particionada em quatro partes (quadrantes). Cada quadrante no qual o critério de similaridade não é satisfeito é sucessivamente subdividido em sub-quadrantes. A subdivisão de um quadrante é interrompida assim que o critério de similaridade é satisfeito. Durante o processo de subdivisão, podem ser criados quadrantes adjacentes que são similares. Estes devem ser unidos (merged) para formar uma única região (parte). A dinâmica do processo de *split & merge* é ilustrado para o caso de uma imagem binária na figura 1. A figura 1a é a imagem original e (b) é o resultado após a primeira subdivisão. Note que o primeiro quadrante é homogêneo e portanto não precisa mais ser subdividido. A figura 1c mostra o resultado da segunda subdivisão, onde apenas dois quadrantes resultantes não são homogêneos. Note também que vários quadrantes adjacentes são homogêneos e portanto são agrupados para formar uma região (figura 1d). Ao final (figura 1f), é mostrado o resultado final composto de duas regiões.

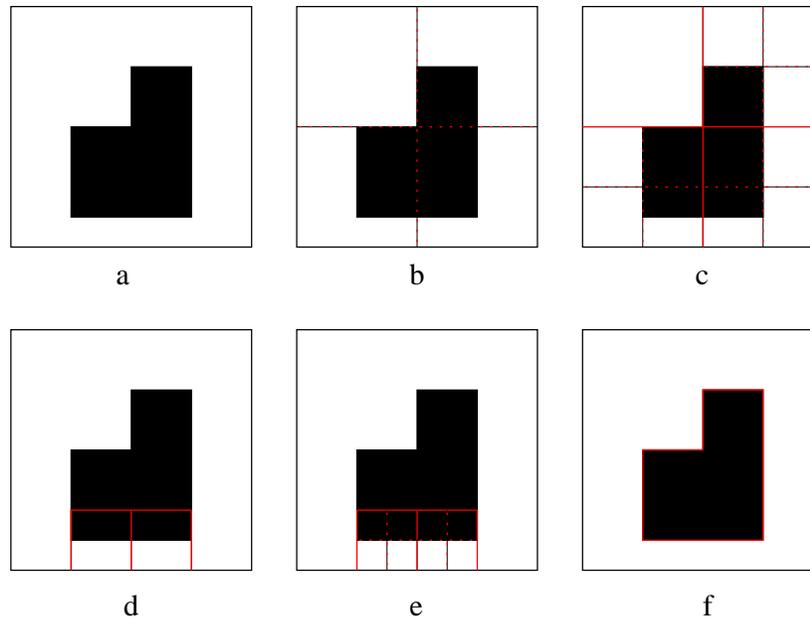


Figura 1: Segmentação pelo método split & merge de regiões.

#### 4 Segmentação baseada em clustering (aglomeração)

Nesta abordagem, os pontos da imagem são caracterizados por vetores de  $n$  atributos. Os vetores de atributos podem ser vistos como pontos no espaço  $n$ -dimensional. Tais pontos podem ser aglomerados nesse espaço levando-se em conta algum critério de semelhança (por exemplo proximidade em termos de distância Euclideana) e formar aglomerados (clusters). Cada aglomerado recebe um rótulo e estes podem ser mapeados de volta para os pontos correspondentes na imagem, onde formarão as regiões.

#### Referências

- [1] R. C. Gonzalez and R. E. Woods. *Digital Image Processing*. Addison-Wesley Publishing Company, second edition, 2002.
- [2] R. C. Gonzalez and R. E. Woods. *Digital Image Processing*. Addison-Wesley Publishing Company, 1992.
- [3] R. Hirata Jr. Segmentação de Imagens por Morfologia Matemática. Master's thesis, Instituto de Matemática e Estatística - USP, março 1997.