

CLASSIFICAÇÃO DE IMAGENS

Ronei Marcos de Moraes

Departamento de Estatística

Universidade Federal da Paraíba

nov/1999

Introdução

Pretende-se introduzir conceitos básicos de Classificação de Imagens e apresentar as técnicas usuais.

Serão estudadas técnicas de classificação supervisionada e não supervisionada.

As técnicas não supervisionadas estudadas serão:

- Classificação Hierárquica
- K-Médias
- ISODATA
- Fuzzy C-Médias
- Fuzzy ISODATA

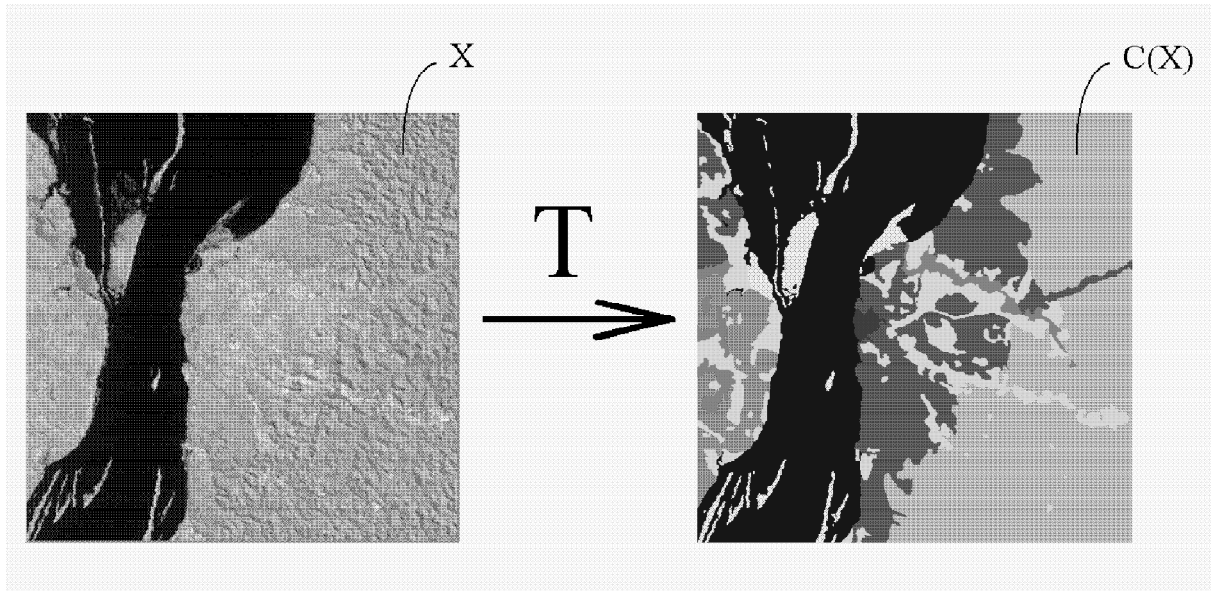
Os Classificadores Supervisionados Clássicos estudados serão:

- Método do Paralelepípedo
- Mínima Distância
- Método dos K-Vizinhos Próximos - KNN
- Máxima Verossimilhança
- Redes Neurais

E os Classificadores Supervisionados Contextuais:

- Método Geral
- Método p,q,r

Classificação de Imagens



T pode ser:

- classificador numérico
- classificador visual
- classificador assistido por sistema especialista

Classificadores Não Supervisionados

Dois tipos básicos:

- Agrupam vetores de dados semelhantes entre si
- Separam vetores de dados diferentes entre si

Não recebem informação do usuário

Resulta agrupamentos não identificados. Identificação fica por conta do usuário após a classificação [1]

Utilização iterativa até que o agrupamento se estabilize ou as variações sejam aceitáveis

Utilizam uma medida de similaridade [2]. Em geral, a distância Euclideana:

$$\begin{aligned}
d(x_1, x_2) &= \|x_1 - x_2\| \\
&= \sqrt{(x_1 - x_2)^t (x_1 - x_2)} ; \\
&= \sqrt{\sum_{i=1}^N (x_{1i} - x_{2i})^2}
\end{aligned}$$

ou a distância L1:

$$d(x_1, x_2) = \sum_{i=1}^N |x_{1i} - x_{2i}|$$

onde N é o número de componentes espectrais.

A distância L1 é computacionalmente mais rápida, porém menos acurada que a distância Euclideana.

É um critério utilizado para se verificar a qualidade dos agrupamentos é a Soma de Quadrados dos Erros:

$$SQE = \sum_{j=1}^K \sum_{x_j \in C_i} \|x_j - m_i\|^2$$

onde m_i é a média do i -ésimo agrupamento, $i = 1, \dots, K$ e $x \in C_i$ é um padrão atribuído àquele agrupamento.

Classificação Hierárquica

Não requer a especificação de um número de classes

Inicia com cada "pixel" formando uma classe

Calcula uma matriz de distâncias entre todos os agrupamentos

Para cada iteração, reúne "pixels" formando agrupamentos, diminuindo o número inicial de agrupamentos e recalculando a matriz de distâncias

Continua até que todos os "pixels" formem um único agrupamento

Cada fusão de agrupamentos é indicada num gráfico denominado Dendograma, indicando qual era a distância que existia entre os centros desses agrupamentos

K-Médias

Requer a especificação de um número K de classes

Procedimento iterativo que desloca cada vetor de média pelo espaço até que sua posição defina bem a classe que representa.

O método consta de 4 passos básicos:

- 1) K vetores \widehat{m}_i , $i = 1, \dots, K$ devem ser inicializados formando o centro dos K agrupamentos. A inicialização pode ser feita por vários métodos
- 2) Calcula-se a distância (Euclideana ou L1) de cada vetor m_i aos "pixels" e verifica-se quais são os mais próximos de cada \widehat{m}_i para serem inseridos em cada agrupamento i
- 3) É computado os novos centros médios m_i de cada agrupamento i produzidos no passo 2

4) Se todos os centros $m_i = \widehat{m}_i$ não se modificaram do passo 2 para o passo 3, então o procedimento está terminado; senão, cada \widehat{m}_i recebe o valor do m_i do passo 3 e o procedimento retorna ao passo 2. Esse procedimento também pode terminar se a Soma de Quadrados dos Erros (SQE) é inferior a um valor ε pré-definido.

A inicialização dos vetores pode ser feita aleatoriamente ou adotando-se alguma concepção lógica, como iniciar agrupamentos espaçados equitativamente sobre o espaço multidimensional, ou ainda em áreas de correspondência espectral a possíveis classes presentes na imagem, como solo, água, tipos determinados de vegetação, rochas, etc.

ISODATA

É um procedimento iterativo que utiliza uma concepção similar ao K-médias, porém podendo alterar o número de classes pré-estabelecido [3,4].

- 1) Requer a especificação de cinco parâmetros iniciais: número K de classes, inicialização dos K vetores, limiar de divisão de agrupamentos, limiar de união de agrupamentos e o número mínimo de "pixels" que um agrupamento deve possuir.
- 2) Calcula-se a distância (Euclideana ou L1) de cada vetor m_i aos "pixels" e verifica-se quais são os mais próximos de cada \widehat{m}_i para serem inseridos em cada agrupamento i
- 3) Computa-se os novos centros médios m_i de cada agrupamento i produzidos no passo 2
- 4) Se qualquer *limiar de divisão* é excedido para algum agrupamento, ele é dividido em dois agrupamentos.

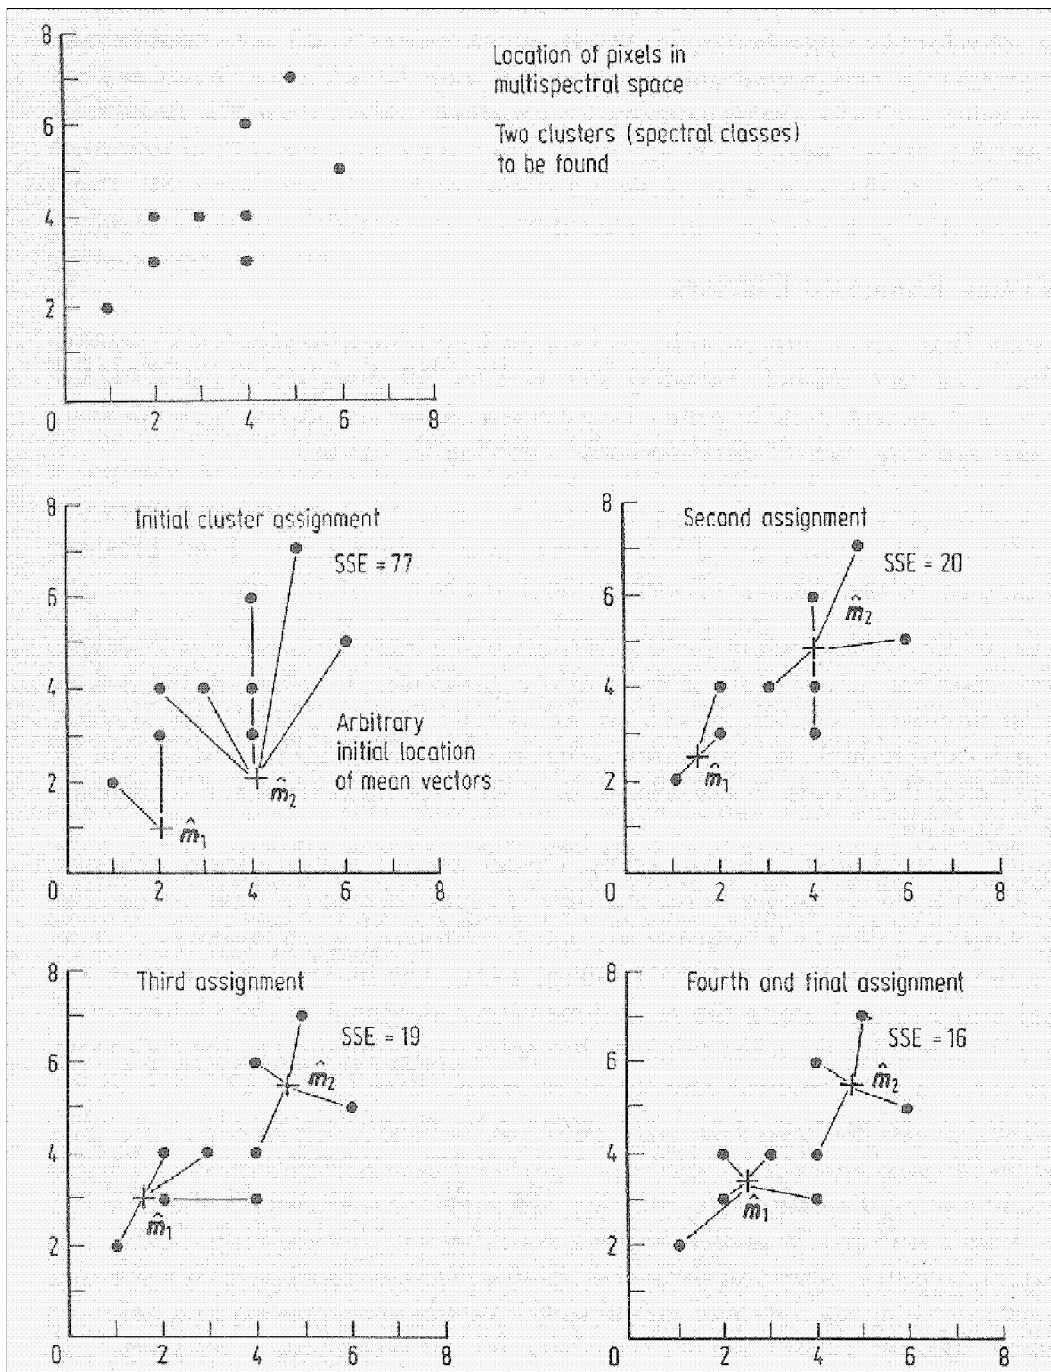


Figure 1: Agrupamento pelo Método das K-Médias.

- 5) Se houve alguma divisão no passo 4, recalcular os centros dos agrupamentos
- 6) Se algum agrupamento possui um número de "pixels" inferior ao *número mínimo*, elimina-se esse agrupamento
- 7) Se houve algum agrupamento foi eliminado no passo 6, reagrupar os "pixels" e recalcular os centros dos agrupamentos
- 8) Se a distância entre dois agrupamentos é inferior ao *limiar de união*, combinar os dois agrupamentos em um único.
- 9) Se quaisquer dois agrupamentos foram unidos no passo 8, recalcular os centros dos agrupamentos
- 10) Repetir os passos 2 a 9, até que os agrupamentos se estabilizem (SQE), ou até que o número máximo de iterações seja excedido.

Teoria dos Conjuntos Nebulosos ("Fuzzy Sets")

Origens remontam ao ano de 1965 - Lofti A. Zadeh

Generaliza a função característica da Teoria dos Conjuntos Cássica.

Definição. Seja X um espaço de pontos, com um elemento genérico de X denotado por x . Um *conjunto nebuloso* A em X é caracterizado por uma *função de pertinência* $\mu_A(x)$ que associa a cada ponto em X um número real no intervalo $[0, 1]$, onde $\mu_A(x)$ representa para x o seu grau de pertinência em A .

Fuzzy C-Médias

É baseado em K-médias, mas considera que um vetor pode possuir uma pertinência parcial para mais de um grupo.

Algoritmo e iteração similar ao K-médias

Durante a execução e ao final do algoritmo, uma tabela de pertinência μ de cada vetor para cada grupo é criado

Minimiza a SQE com ponderação pela pertinência

$$SQE_p^\eta = \sum_{j=1}^K \sum_{x_j \in C_i} \mu_i(x_j)^\eta \|x_j - v_i\|^2$$

onde: $\mu_i(x_j)$ é a função de pertinência de x_j para a classe C_i ; $\eta \in [1, \infty)$ e v_i é a média ponderada para a classe C_i .

Fuzzy ISODATA

Procedimento iterativo que utiliza uma concepção similar ao Fuzzy C-médias, podendo alterar o número de classes pré-estabelecido [4].

Utiliza uma sistemática de passos similar ao ISODATA

Referências

- [1] Santos, Rafael; Introdução à Classificação de Imagens. Tutorial SIBGRAPI'99
- [2] Richards, J. A.; Remote Sensing Digital Image Analysis - An Introduction. Springer-Verlag, 1995.
- [3] Kandel, A.; Fuzzy Techniques in Pattern Recognition. John Wiley & Sons, 1982.
- [4] Mather, P. M.; Computer Processing of Remotely-Sensed Images. John Wiley & Sons, 1987.