


Classificação de imagens

Autor: Gil Gonçalves
Disciplinas: Detecção Remota/Detecção Remota Aplicada
Cursos: MEG/MTIG
Ano Lectivo: 11/12

Sumário

- ◆ Classificação da imagem (ou reconhecimento de padrões): objectivos
- ◆ Métodos de reconhecimento de padrões
 - Classificação supervisionada
 - Classificação não-supervisada
 - Classificação contextual
 - Classificação orientada por objectos
- ◆ Avaliação da precisão

Classificação de imagens



Classificação das técnicas de reconhecimento de padrões

- ◆ Se são utilizados zonas de treino ou não
 - Classificação supervisionada
 - Classificação não-supervisada
- ◆ Se forem utilizados parâmetros estatísticos tais como vector médio e matriz de covariância
 - Paramétricos
 - Não-paramétricos
- ◆ Se for utilizada informação espacial ou não
 - Espectrais
 - Contextual
 - Mista

Classificação da imagem

- ◆ Objectivo: categorizar automaticamente todos os pixels de uma imagem em classes do coberto do solo ou temas
- ◆ A classificação da imagem pode ser definida como o processo de reduzir uma imagem a classes informativas
- ◆ A categorização dos pixels de uma imagem é baseada nos valores de cinzento (NR) de uma ou mais bandas espectrais



- Unclassified
- Clear Water
- Corn
- Forest
- Hay / Grasslands
- Industrial
- Quarries / Landfill Sites
- Residential
- Turbid Water

Classes espectrais e informativas

- ◆ Classes informativas
 - São as classes que interessam aos utilizadores: (coberto do solo, por exemplo, residencial, industrial, floresta, corpos de água, etc)
- ◆ Classes espectrais
 - São as classes/clusters inerentes nos dados de detecção remota: grupos distintos com NR similares (curvas de respostas espectrais)

Classificação de imagens

- ♦ Hipóteses
 - Entidades semelhantes têm respostas espectrais semelhantes
 - A resposta espectral de algumas entidades é única quando comparada com outras entidades
 - Quantificando a resposta espectral duma entidade conhecida, podemos utilizar esta informação para procurar todas as ocorrências (instâncias) desta entidade.
- ♦ Classificação supervisionada (paramétrica e não-paramétrica)
 - Conceito: Utilizando amostras de entidades conhecidas (i.e atribuindo pixels a classes de informação), o algoritmo classifica os pixels com entidades desconhecidas
 - Procedimento de classificação: i) o utilizador selecciona e denomina áreas na imagem, que correspondem a classes de interesse (estas classes correspondem a classes informativas); ii) Seguidamente o algoritmo de classificação irá encontrar áreas semelhantes (depende do algoritmo utilizado).
- ♦ Classificação não supervisionada
 - Conceito: a imagem é automaticamente segmentada em classes espectrais baseado no agrupamento natural encontrado nos dados
 - Procedimento de classificação: i) o utilizador introduz alguns parâmetros de classificação; ii) o algoritmo procura pixels com propriedades espectrais semelhantes; iii) Depois da classificação o utilizador renomeia cada classe (isto é o utilizador relaciona as classes espectrais com as classes informativas relevantes)

Classificação supervisionada e não-supervisada

- ♦ Procedimento de classificação supervisionada
 - Seleccionar os dados de treino
 - Classificar a imagem
 - Avaliar a precisão da classificação
- ♦ Procedimento de classificação não supervisionada
 - Classificar as imagens
 - Identificar os clusters
 - Avaliar a precisão da classificação

Clas. Supervisada	Clas. não-supervisada
Classes pré-definidas	Classes desconhecidas
As classes definidas podem não emparelhar com as classes espectrais	As classes espectrais podem não concordar com as classes pretendidas
Os dados de treino podem ser inadequados	Os clusters derivados podem ser inadequados
Um treino a priori das classes é dispendioso em termos de tempo e tediosa	Uma identificação á posteriori dos clusters é dispendiosa em termos de tempo e tediosa
Apenas serão identificadas classes pré-definidas	Podem ser encontradas categorias não esperadas

Classificação da imagem: bandas utilizadas

- ◆ Geralmente são utilizadas duas ou mais bandas no processo de classificação
- ◆ Trabalhando com mais do que uma banda melhoraremos a nossa capacidade de identificar a procura das classes de informação
- ◆ Trabalhando com bandas transformadas (tais como quocientes) podemos melhorar a precisão da classificação
 - Por exemplo o quociente entre as bandas do infravermelho e do visível são úteis para a identificação da vegetação

Classificação supervisionada de imagens

Sumário:

Procedimento

Classificadores principais

Classificação supervisionada da imagem

- ◆ Procedimento
 - Visualizar uma única banda ou uma combinação RGB de três bandas
 - Adquirir os conjuntos de treino
 - Escolher o tipo de classificador
 - Executar a classificação
 - Refinar os dados de treino
 - Calcular as medidas de avaliação da precisão
- ◆ A classificação supervisionada da imagem é feita usualmente segundo um processo iterativo

Conjunto de treino


- ◆ Um conjunto de dados de treino é um subconjunto da imagem para o qual o analista acredita que contem uma classe espectral associada a uma certa classe informativa
- ◆ O conjunto de dados de treino contem informação sobre todas as bandas espectrais dentro da área espacial indicada pelo analista
- ◆ A maior parte das vezes, existe mais do que uma classe espectral para uma dada classe informativa.

Tipos de classificadores

- ◆ Classificador do paralelepípedo
- ◆ Classificador da distância mínima
- ◆ Classificador da máxima verosimilhança

Classificador do paralelepípedo

- ◆ Valores min e max de cada amostra
- ◆ Classifica-se cada pixel tendo em conta os paralelepípedos min-max
- ◆ Problemas: alguns pixels/pontos podem pertencem a vários paralelepípedos
- ◆ Vantagem: muito rápida.




Classificador da distância mínima

- ◆ Média m e desvio padrão σ de cada amostra
- ◆ Calcula-se a distância de cada ponto a cada média da amostra
- ◆ Classifica-se o pixel/ ponto em função da distância à classe mais próxima
- ◆ A utilização de distâncias normalizadas

$$\vec{d} = \vec{D} - \vec{\mu}$$

$$\vec{d} = \frac{\vec{D} - \vec{\mu}}{\sigma}$$



Classificação não supervisionada

Objectivos

Técnicas de classificação

K-Means

ISODATA

Expectation Maximization

Classificação não-supervisada

- ◆ Conceito: é baseado na identificação de grupos/estruturas naturais dentro dos dados multi-espectrais (classes espectrais)
- ◆ Vantagens
 - Não é necessário um conhecimento extensivo à priori da zona
 - A possibilidade de introdução de erros humanos é reduzida
 - As classes únicas são reconhecidas como unidades distintas
 - Não é necessário tempo de treino
- ◆ Desvantagens
 - Dificuldade em encontrar uma correspondência entre as classes espectrais e as categorias de informação desejadas
- ◆ Premissa básica: os valores espectrais dentro de um dado tipo de coberto estão muito próximos, enquanto que dados noutras classes diferentes estão comparativamente bem separadas
- ◆ As classes identificadas são classes espectrais e não classes do coberto ou uso do solo (ou classes informativas)
- ◆ A analista denomina os clusters espectrais identificados na classificação

Classificação não supervisada: k-means

- ◆ Procedimento
 - É introduzido o número desejado de clusters/classes
 - São inicializados as posições dos centros para as médias dos clusters
 - São atribuídos pixels aos clusters com valores de média mais próximos
 - São calculados para cada cluster os novos vectores das médias
 - São repetidas as duas últimas operações até que se atinja um determinado critério de convergência (as médias dos clusters não mudam entre as iterações).
- ◆ Características
 - Computacionalmente exigente
 - Sensível aos valores das médias inicialmente escolhidos

Classificação não-supervisada: ISODATA

- ◆ Desvantagens do algoritmo k-means
- ◆ O número de clusters é fixo (i.e uma vez k escolhido, obtêm-se sempre k centros dos clusters)
- ◆ O algoritmo ISODATA contorna o problema da remoção de clusters redundantes e da criação de novos clusters
- ◆ Por exemplo, se um centro de um cluster não for atribuído a amostras suficientes, pode ser removido
- ◆ Desta forma, ficaremos com um número óptimo de clusters
- ◆ O problema da escolha de um número inicial de clusters permanece ainda. No entanto se escolhermos um número grande para k reduziremos o efeito deste problema
- ◆ Por outras palavras, o ISODATA é uma k-means modificada, onde juntamos e separamos clusters
- ◆ Os clusters são juntos
 - Se o número de membros (pixeis) num cluster é menor que um determinado valor, ou
 - Se a distância entre os centros de dois clusters for menor do que um determinado valor
- ◆ Os clusters são divididos em dois clusters diferentes:
 - Se o desvio padrão do cluster exceder um determinado valor

Métodos contextuais

Sumário:

1. Introdução
2. Integração do contexto por pré-processamento
3. Integração do contexto por pós-processamento

Introdução

- ◆ Os métodos contextuais são aqueles que utilizam o contexto espacial de cada elemento imagem no processo de reconhecimento, ou seja utilizam a relação espacial entre elementos de imagem (pixeis ou objectos) adjacentes para classificar um determinado elemento
- ◆ Os diferentes tipos de relações espaciais entre elementos de imagem (ou agrupamentos de elementos de imagem) geralmente utilizados são
 - Distância
 - Direcção
 - Conectividade
 - Inclusão

Objectivos

- ◆ O objectivo da aplicação destes métodos é produzir mapas temáticos consistentes do ponto de vista espacial, o que por vezes não acontece quando se explora apenas a informação espectral.
- ◆ Os vários métodos podem dividir em:
 - Métodos que realizam **pré-processamento** sobre a imagem de modo a integrarem informação contextual antes de aplicar um processo de reconhecimento de padrões
 - Métodos que geram, à custa da imagem **bandas adicionais** com informação sobre o contexto espacial, como por exemplo bandas de textura, bandas estruturais, etc; estas bandas contextuais são utilizadas como bandas adicionais no processo de reconhecimento de padrões em conjunto com bandas espectrais ou são utilizadas por classificadores contextuais
 - Métodos que integram a informação contextual num processo de **pós-processamento**, depois de produzido um mapa temático; estes métodos podem analisar o contexto de cada elemento de imagem ou de um conjunto de elementos de imagem

Integração do contexto por pré-processamento

- ◆ O processo mais simples de introduzir informação contextual num processo de reconhecimento de padrões é aplicar filtros à imagem na fase de pré-processamento.
- ◆ A aplicação de um filtro para atenuar as diferenças entre os elementos de imagem contíguos (filtro passa baixo) permite aumentar a homogeneidade espectral de elementos contíguos, aumentando o sucesso dos métodos de reconhecimento de padrões por métodos estatísticos
- ◆ Esta metodologia tem também o efeito preverso de reduzir também as diferenças espectrais entre elementos de imagem pertencentes a classes diferentes, tornando mais difícil a sua separação espectral

Geração de bandas contextuais

- Informação estrutural
 - Constituída, usualmente, pelas fronteiras radiométricas entre os objectos presentes na imagem
- Informação textural
 - A textura é um índice local que tem a ver com a variabilidade e arranjo dos NR numa vizinhança.
 - Medidas de textura: contraste, entropia, energia, segundo momento da diferença inversa, variância, correlação.

Integração do contexto por pós-processamento

- Filtros
 - Passa-baixo: têm por objectivo deixar passar as baixas frequências dos NR e eliminar na imagem as variações de alta frequência
 - média, mediana, gaussiano
 - Passa-alto: têm por objectivo deixar passar as variações de alta frequência dos NR e eliminar as variações de baixa frequência.
 - Gradiente,
- Método da Relaxação de Etiquetas
 - É um reclassificador contextual sobre mapas temáticos, que considera os modelos estocásticos da probabilidade de certos temas ocorrerem em conjunto, e explora o facto de certos tipos de ocupação do solo ocorrerem mais frequentemente num determinado contexto do que noutro.

Avaliação da exactidão da classificação

Problemática

Matriz de erro

Indicadores de qualidade

Índices relativos a uma classe

Índices globais

Comparação entre classificadores

Matriz de confusão/erro

- Dados (3 classes)
 - Ref = [1,1,2,1,1,2,3,3] é a verdade terreno
 - Clas = [1,2,2,1,1,3,1,3] é o resultado da classif.
- Construção da matriz de erro

		Ref			Totais			Ref			Totais	U(i)
		1	2	3				1	2	3		
Totais	1	3	0	1	4		1 <td>3</td> <td>0</td> <td>1</td> <td>4</td> <td>75%</td>	3	0	1	4	75%
	2	1	1	0	2		2 <td>1</td> <td>1</td> <td>0</td> <td>2</td> <td>50%</td>	1	1	0	2	50%
	3	0	1	1	2		3 <td>0</td> <td>1</td> <td>1</td> <td>2</td> <td>50%</td>	0	1	1	2	50%
	Totais	4	2	2	8		Totais	4	2	2	8	
							P(i)	75%	50%	50%		

Matriz de confusão

- ◆ Os totais das linhas representam os resultados da classificação

		W	S	F	U	C	H	Row Total
Classified	W	480	0	5	0	0	0	485
	S	0	52	0	20	0	0	72
	F	0	0	313	40	0	0	353
	U	0	16	0	126	0	0	142
	C	0	0	0	38	342	79	459
	H	0	0	38	24	60	359	481
	Column total	480	68	356	248	402	438	1992

Matriz de confusão

- Os totais das colunas representam os dados de referência (verdade terreno)

	Reference						Row Total
	W	S	F	U	C	H	
W	480	0	5	0	0	0	485
S	0	52	0	20	0	0	72
F	0	0	313	40	0	0	353
U	0	16	0	126	0	0	142
C	0	0	0	38	342	79	459
H	0	0	38	24	60	359	481
Column total	480	68	356	248	402	438	1992

Matriz de confusão

- Os elementos da diagonal representam os elementos correctamente classificados

	W	S	F	U	C	H	Row Total
W	480	0	5	0	0	0	485
S	0	52	0	20	0	0	72
F	0	0	313	40	0	0	353
U	0	16	0	126	0	0	142
C	0	0	0	38	342	79	459
H	0	0	38	24	60	359	481
Column total	480	68	356	248	402	438	1992

Matriz de confusão

- ◆ Os elementos fora da diagonal representam os erros de classificação (comissão e omissão)

	W	S	F	U	C	H	Row Total
W	480	0	5	0	0	0	485
S	0	52	0	20	0	0	72
F	0	0	313	40	0	0	353
U	0	16	0	126	0	0	142
C	0	0	0	38	342	79	459
H	0	0	38	24	60	359	481
Column total	480	68	356	248	402	438	1992

Avaliação da precisão

- ◆ Os elementos da diagonal correspondem a classes correctamente classificadas
- ◆ Os elementos fora da diagonal correspondem a classes erroneamente classificadas (i.e erros de classificação)
 - Uma metodologia de classificação óptima conduziria a elementos fora da diagonal iguais a zero

$$\text{Precisão global} = \frac{\sum \text{elementos da diagonal}}{\text{Número total de amostras}}$$

- ◆ Erros de omissão (exclusão)
 - Elementos fora da diagonal sobre as colunas
 - Precisão do produtor (em %)
- ◆ Erros de comissão (inclusão)
 - Elementos fora da diagonal sobre as linhas
 - Precisão do utilizador (em %)

Erros de omissão e precisão do produtor

		Reference						Row Total
		W	S	F	U	C	H	
Classified	W	480	0	5	0	0	0	485
	S	0	52	0	20	0	0	72
	F	0	0	313	40	0	0	353
	U	0	16	0	126	0	0	142
	C	0	0	0	38	342	79	459
	H	0	0	38	24	60	359	481
Column total		480	68	356	248	402	438	1992

- ◆ Erro de omissão: Quando a classe U está presente nos dados e foi erroneamente classificada 49% do tempo
- ◆ Precisão do produtor: Quando U está presente nos dados e foi correctamente classificada 51% das vezes

Producer's Accuracy

W = 480/480 = 100%
S = 052/068 = 76%
F = 313/356 = 88%
U = 126/248 = 51%
C = 342/402 = 85%
H = 359/438 = 82%

Erros de comissão e precisão do utilizador

		Reference						Row Total
		W	S	F	U	C	H	
Classified	W	480	0	5	0	0	0	485
	S	0	52	0	20	0	0	72
	F	0	0	313	40	0	0	353
	U	0	16	0	126	0	0	142
	C	0	0	0	38	342	79	459
	H	0	0	38	24	60	359	481
Column total		480	68	356	248	402	438	1992

- ◆ Erro de comissão: Quando um pixel é classificado como U, foi erroneamente classificada 11% do tempo
- ◆ Precisão do utilizador: Quando um pixel é classificado como U é correctamente classificado 89% das vezes

User's Accuracy

W = 480/485 = 99%
S = 052/072 = 72%
F = 313/353 = 87%
U = 126/142 = 89%
C = 342/459 = 74%
H = 359/481 = 75%

Avaliação da precisão - notas finais

- ◆ A avaliação da precisão depende do conjunto de dados de treino
- ◆ Os valores de precisão obtidos podem não reflectir correctamente o que acontece fora do conjunto de dados de treino

Exemplo 2

- Em alguns casos as classes de referência são colocadas no topo.

Classes	Classes de Referência			
	A	B	C	D
A	65	4	22	24
B	6	81	5	8
C	0	11	85	19
D	4	7	3	90