
Obrazová klasifikácia 1

Základy obrazovej klasifikácie

Lekcia 4

Obsah lekcie


1. Obrazová klasifikácia - definícia
 2. Multispektrálna klasifikácia
 3. Druhy obrazovej klasifikácie
 4. Nekontrolovaná klasifikácia - postup, algoritmy
 5. Kontrolovaná klasifikácia - postup, algoritmy
 6. Hodnotenie správnosti klasifikácie
-

Obrazová klasifikácia

- proces triedenia pixlov do konečného počtu tried na základe ich údajových hodnôt
 - klasifikácia obrazu je úzko spätá s pojmom **rozoznávanie vzoru (Pattern Recognition)**
 - ide o hľadanie zmysluplných vzorov v údajoch (spektrálnych, ale aj iných vizuálnych alebo akustických), ktoré môžeme extrahovať klasifikáciou
 - napr. technika OCR (Optical Character Recognition), rozoznávanie PSČ, ľudskej reči, ľudských tvárí atď.
-

Obrazová klasifikácia



- klasifikácia obrazových údajov DPZ – na základe **digitálnych hodnôt pixlov (DN – Digital Number)**
- numerická klasifikácia




71	25	120	43	25	25	14
71	120	120	71	43	14	14
43	71	120	71	71	43	43
120	43	71	120	71	43	71
120	43	71	43	14	71	71
71	120	25	14	14	25	25
120	120	71	43	14	25	14

Multispektrálna klasifikácia

- zaradovanie pixlov do tried na základe ich **meracích vektorov (measurement vector)** – sada údajových hodnôt pre jeden pixel vo všetkých n pásmach



Multispektrálna klasifikácia





Príznakový priestor

- n spektrálnych pásiem tvorí n -rozmerný spektrálny priestor
 - **príznakový priestor (feature space)** – n -rozmerný abstraktný priestor s počtom rozmerov odpovedajúcim počtu vlastností (príznakov), ktorými je objekt (pixel,vzor) opísaný
-

Príznakový priestor

grafické znázornenie príznakového priestoru –
dvojrozmerný histogram **scatter plot**




Rozoznávanie vzoru

- **rozoznávanie spektrálneho vzoru** – hodnoty pixlov v n pásmach (základ multispektrálnej klasifikácie)
 - **rozoznávanie priestorového vzoru** – textúra, veľkosť a tvar objektov, smerovanie, kontext (napodobňovanie vizuálnej interpretácie, komplexnejšie a výpočtovo náročnejšie)
 - **rozoznávanie časového vzoru** – napr. klasifikácia poľnohosp.pôdy (zmeny počas rastovej sezóny)
-



Delenie klasifikácie

1. založená na pixloch – pixel-based, per pixel
2. založená na objektoch – object-based, per field



Delenie klasifikácie



1. založená na pixloch – pixel-based, per pixel
2. založená na objektoch – object-based, per field



Delenie klasifikácie

Podľa spôsobu priradovania príslušnosti pixlov/objektov do tried:



1. **tvrdá klasifikácia** – hard classification
2. **mäkká klasifikácia** – soft classification



Delenie klasifikácie

Podľa stupňa zasahovania užívateľa do klasifikačného procesu:

1. **nekontrolovaná klasifikácia** – unsupervised
2. **kontrolovaná klasifikácia** – supervised



Nekontrolovaná klasifikácia


- **zhlukovanie** - prirodzené zoskupovanie pixlov v spektrálnom priestore
 - **zhluky (klastre)** - spektrálne triedy (identita neznáma)
 - podmienka - hodnoty pixlov jednej triedy musia byť v spektrálnom priestore blízko seba, kým hodnoty pixlov rôznych tried musia byť oddeliteľné
 - zhlukovanie prebieha iteratívne
-

Nekontrolovaná klasifikácia

- vyžaduje minimálny vstup operátora
 - parametre: počet výsledných zhlukov, veľkosť zhlukov, vzdialenosť zhlukov, smerodajná odchýlka v rámci zhluku, počet iterácií
 - najpoužívanéjšie metódy:
 - metóda k priemerov (*k*-means clustering)**
 - metóda zhlukovania ISODATA**
 - metóda štatistického zhlukovania**
-


Metóda zhukovania *k*-means

- produkuje užívateľom zadaný počet ***k* zhukov**, pričom každý zhuk je reprezentovaný **stredom (priemerom)** v spektrálnom priestore
- počiatočná poloha stredov zhukov je určená na základe analýzy vstupného rastra




Metóda zhlukovania *k*-means

- pixle sú zaradené do zhluku, k stredu ktorého majú najmenšiu spektrálnu vzdialenosť



Metóda zhlukovania *k*-means

- následne sú vypočítané nové stredy zhlukov
- nový stred je bod, ktorý minimalizuje sumu štvorcov vzdialeností medzi bodmi zhluku a jeho stredom
- proces sa iteratívne opakuje, až kým posun stredov zhlukov nie je menší než zadaný limit al. kým sa nedosiahne max. počet iterácií



Metóda zhlukovania ISODATA

ISODATA (Iterative Self-organizing Data Analysis Technique) – často používaná verzia metódy *k*-means

- dovoľuje meniť počet zhlukov medzi jednotlivými iteráciami ich spájaním, delením al. vymazávaním
 - ak je vzdialenosť priemerov dvoch zhlukov menšia ako zadaná minimálna hodnota, zhluky sa spoja
 - ak je smerodajná odchýlka zhluku menšia ako zadaná maximálna hodnota, zhluk sa rozdelí na dva
 - ak je počet pixlov zhluku menší ako zadaná minimálna hodnota, pixle zhluku sa priradia susedným zhlukom
-

Štatistické zhľukovanie

- berie do úvahy textúru obrazu, ktorá je definovaná rozptylom (varianciou) v rámci pohybujúceho sa okna (napr. 3x3) po obraze
 - homogénne okná (s nízkym rozptylom) sa zoberú za počiatočné stredy zhľukov
 - ďalej zhľukovanie pokračuje ako pri metóde *k*-means
-

Typy výstupov zhľukovania


TABLE 7.2 Spectral Classes Resulting from Clustering a Forested Scene

Spectral Class	Identity of Spectral Class	Corresponding Desired Information Category
Possible Outcome 1		
1	Water	Water
2	Coniferous trees	Coniferous trees
3	Deciduous trees	Deciduous trees
4	Brushland	Brushland
Possible Outcome 2		
1	Turbid water	Water
2	Clear water	
3	Sunlit conifers	Coniferous trees
4	Shaded hillside conifers	
5	Upland deciduous	Deciduous trees
6	Lowland deciduous	
7	Brushland	Brushland
Possible Outcome 3		
1	Turbid water	Water
2	Clear water	
3	Coniferous trees	Coniferous trees
4	Mixed coniferous/deciduous	
5	Deciduous trees	Deciduous trees
6	Deciduous/brushland	Brushland

Kontrolovaná klasifikácia

1. **trénovací krok** - analyzátor identifikuje reprezentatívne trénovacie oblasti a vytvára numerický opis spektrálnych vlastností každej záujmovej triedy na scéne
 2. **klasifikačný krok** - každý pixel obrazu zaradí do tej triedy, na ktorú sa najviac podobá (ak nie je dostatočne podobný žiadnej triede, obyčajne sa označí ako "neznámy")
-

Kontrolovaná klasifikácia



Trénovací krok

- výber klasifikačnej schémy: Aké triedy chceme extrahovať?
 - informácie o údajoch: Aké triedy sa tam pravdepodobne vyskytujú?
 - informácie o území – najlepšie tzv. **ground truth**, t.j.najpresnejšie z dostupných údajov (napr.terénny prieskum, LMS...), zberaných najlepšie v čase snímania
-

Trénovací krok


- **trénovacie množiny (signatúry)** – sady pixlov, ktoré reprezentujú rozoznateľný vzor alebo potenciálnu triedu
 - dôležité je, aby obsahovali len pixle danej triedy
 - dostatočný počet pixlov (minimálne 10, najlepšie 100 a viac)
 - musia byť reprezentatívne a kompletné
-

Trénovací krok

- trénovacie množiny môžeme vytvoriť zberom jednotlivých pixlov alebo digitalizáciou polygónov (zhluky pixlov)
 - iteratívny proces – zahŕňa pridávanie, vymazávanie a spájanie signatúr
 - štatistické charakteristiky jednotlivých tried (minimálna, maximálna, priemerná hodnota jasv v jednotlivých pásmach, smerodajná odchýlka...)
-


Hodnotenie signatúr

- porovnanie signatúr



Hodnotenie signatúr

- zobrazenie v dvojrozmernom histograme (scatter plot)



Hodnotenie signatúr

- predbežná chybová matica

ERROR MATRIX

		Reference Data			

Classified Data		Les	Koso	Trava 1	Trava 2
-----		-----	-----	-----	-----
Les		37466	136	7	112
Koso		44531	3453	1	181
Trava 1		2127	0	1541	557
Trava 2		3190	10	191	563
Column Total		87314	3599	1740	1413

Hodnotenie signatúr

- oddeliteľnosť v spektrálnom priestore:

Divergence

Transformed Divergence

Bhattacharya Distance

Jeffries-Matusita Distance

Best Minimum Separability								
Bands			AVE	MIN	Class Pairs:			
1	2	3			1: 2	1: 3	1: 4	2: 3
							2: 4	3: 4
1	2	3	1765	1293	1997	1942	1293	2000
							2000	1357

Klasifikačný krok


- aplikácia **rozhodovacieho pravidla (decision rule)** - matematický algoritmus, ktorý s využitím trénovacích údajov vykonáva triedenie pixlov do oddelených tried
 - stovky typov klasifikátorov
 - tri najznámajšie:
 1. **Minimum Distance**
 2. **Parallelepiped**
 3. **Maximum Likelihood**
-

Klasifikačný krok

- dva typy rozhodovacích pravidiel (klasifikátorov):
1. **parametrické pravidlo** - rozhodovací priestor je spojitý, pretože je založené na modeli údajov (napr. normálne rozdelenie)
 2. **neparametrické pravidlo** - založené na tréningových údajoch samotných (zjednodušene určuje, či pixel je alebo nie je lokalizovaný vo vnútri hraníc neparametrickej signatúry)
-


Minimum Distance

- klasifikátor **minimálnej vzdialenosti**
- najjednoduchšia metóda
- počíta sa vzdialenosť neznámeho pixla od stredu (priemeru) každej triedy v spektrálnom priestore




Minimum Distance

- neberie do úvahy variabilitu tried




Parallelepiped

- **rovnobežkový** klasifikátor
- rýchla a jednoduchá metóda
- triedy sú ohraničené minimálnymi a maximálnymi hodnotami – rovnobežnosteny v spektrálnom priestore




Parallelepiped

- problémy pri prekryte
- neklasifikované pixle




Maximum Likelihood

- klasifikátor **maximálnej pravdepodobnosti**
- parametrický klasifikátor – vyžaduje normálne (Gaussovo) rozdelenie
- triedy sú ohraničené izolíniami pravdepodobnosti




Maximum Likelihood

- poloha: priemer
- veľkosť: rozptyl
- tvar: kovariancia




Maximum Likelihood

- poloha: priemer
- veľkosť: rozptyl
- tvar: kovariancia




Maximum Likelihood

- poloha: priemer
- veľkosť: rozptyl
- tvar: kovariancia



Spectral Angle Mapper

- klasifikátor **spektrálnych uhlov**
- neparametrický klasifikátor
- meranie uhlov medzi vektormi v spektrálnom priestore




$$\alpha = \cos^{-1} \left[\frac{\sum_{i=1}^{nb} t_i r_i}{(\sum_{i=1}^{nb} t_i^2)^{1/2} (\sum_{i=1}^{nb} r_i^2)^{1/2}} \right]$$

α spectral angle
 t pixel spectrum
 r reference spectrum
 nb number of bands

k-nearest neighbors

- klasifikátor ***k* najbližších susedov**
 - neparametrický klasifikátor
 - pixel/objekt sa zaradí do triedy, do ktorej patrí väčšina z jeho *k* susedov
 - patrí k najjednoduchším algoritmom *strojového učenia* (tzv. lazy learning, instance-based learning)
- > *k* → redukcia šumu, rozostrenie hraníc



Hodnotenie správnosti

- klasifikácia nie je úplná, kým nie je zhodnotená jej **správnosť**
 - chyba klasifikácie obsahuje systematickú a náhodnú zložku
 - **systematická** – miera vychýlenia (napr. nesprávne stanovené trénovacie množiny)
 - **náhodná** – napr. prekryt trénovacích množín
-

Hodnotenie správnosti

- porovnanie s údajmi, ktoré sú považované za správne (ground truth)
 - **testovacie pixle** - náhodný výber
 - môžu sa zanedbať malé, ale potenciálne dôležité oblasti
 - riešenie - **stratifikovaný výber** - náhodný výber v rámci jednotlivých klasifikačných tried
 - problémy vyplývajúce z chybnéj registrácie pixlov
 - riešenie - výber pixlov ďalej od hraníc areálov
-

Hodnotenie správnosti

- **testovacie polygóny** - mali by byť odlišné od trénovacích a mali by byť zásadne väčšie
- hodnotenie:

klasifikačná chybová matica (error matrix)

Kappa index

Klasifikačná chybová matica

		Referenčné údaje [m ²]								EC	UA
	Kategória	TP s obn. pôdou	obnažená pôda s TP	obnažená pôda	krovité porasty	trávne porasty	vodná plocha	les	Spolu	[%]	[%]
Klasifikované údaje [m ²]	TP s pôdou	4665	3026	0	0	3094	0	0	10785	56.75	43.25
	pôda s TP	494	10846	403	0	0	0	0	11743	7.64	92.36
	obnažená pôda	782	128	9866	0	0	0	0	10776	8.44	91.56
	krovité porasty	158	0	168	8166	610	0	4492	13594	39.93	60.07
	trávne porasty	1488	131	164	132	27506	0	504	29925	8.08	91.92
	vodná plocha	0	0	0	0	0	6118	0	6118	0	100
	les	99	21	89	645	714	0	232237	233805	0.67	99.33
	Spolu	7686	14152	10690	8943	31924	6118	237233	316746		
EO [%]		39.31	23.36	7.71	8.69	13.84	0	2.11		5.48	
PA [%]		60.69	76.64	92.29	91.31	86.16	100	97.89			94.52

- chyby z nadhodnotenia (Errors of Commission)
- chyby podhodnotenia (Errors of Omission)
- na diagonále - správne klasifikované pixle

Klasifikačná chybová matica

- celková správnosť (Overall Accuracy):

$$OA = \frac{1}{N} \sum_{i=1}^r n_{ii} = \sum_{i=1}^r p_{ii}$$

n - počet pixlov N - celkový počet pixlov
 p - podiel pixlov r - počet tried

- užívateľská správnosť (User's Accuracy):

$$UA_i = \sum_{j=1}^r \frac{n_{ij}}{n_{i.}} = \frac{p_{ii}}{p_{i.}}$$

p_{ii} - podiel pixlov v i-tom riadku a i-tom stĺpci (na diagonále)
 $p_{i.}$ - celkový podiel pixlov v i-tom riadku

- producentská správnosť (Producer's Accuracy)

$$PA_i = \sum_{j=1}^r \frac{n_{ji}}{n_{.i}} = \frac{p_{ii}}{p_{.i}}$$

p_{ii} - podiel pixlov v i-tom riadku a i-tom stĺpci (na diagonále)
 $p_{.i}$ - celkový podiel pixlov v i-tom stĺpci

Kappa index

Kappa index, Kappa koeficient zhody (KIA, KHAT) – je štatistickou mierou zhody medzi referenčnými a klasifikovanými údajmi, vylučujúc zhodu z titulu náhody

- vychádza z prepokladu, že aj pri úplne náhodnej klasifikácii môže byť časť výsledkov správna
- vyjadruje rozdiel medzi skutočnou zhodou referenčných a klasifikovaných dát a medzi pravdepodobnou zhodou referenčných a náhodne klasifikovaných dát

Kappa index

$$k = \frac{\left(N \sum_{i=1}^r x_{ii} - \sum_{i=1}^r (x_{ir} * x_{ic}) \right)}{\left(N^2 - \sum_{i=1}^r (x_{ir} * x_{ic}) \right)}$$

$$k = \frac{\text{zistená správnosť} - \text{pravdepodobná zhoda}}{1 - \text{pravdepodobná zhoda}}$$

r - počet riadkov v matici chýb

x_{ii} - počet pixlov v i -tom riadku a i -tom stĺpci (na hlavnej diagonále)

x_{ir} - počet všetkých pixlov v i -tom riadku

x_{ic} - počet všetkých pixlov v i -tom stĺpci

N - počet všetkých pixlov

Kappa index

$$\hat{k} = \frac{p_o - p_e}{1 - p_e}$$

$$p_o = \sum_{i=1}^r p_{ii}$$

$$p_e = \sum_{i=1}^r p_{ir} \cdot p_{ic}$$

p_o - pozorovaná pravdepodobnosť (observed probability)

p_e - očakávaná pravdepodobnosť (expected probability)

p_{ii} - podiel pixlov v i-tom riadku a i-tom stĺpci (na diagonále)

p_{ir} - celkový podiel pixlov v i-tom riadku

p_{ic} - celkový podiel pixlov v i-tom stĺpci

- 0 znamená žiadnu zhodu, 1 dokonalú zhodu

- kappa > 0.8 znamená silnú zhodu, kappa < 0.4 slabú zhodu

F skóre

- kappa index silne koreluje s celkovou správnosťou

F skóre - harmonický priemer používateľskej a producentskej správnosti

$$UA = \frac{1}{r} \sum_{i=1}^r UA_i$$

$$F = \frac{2 \cdot UA \cdot PA}{UA + PA}$$

$$PA = \frac{1}{r} \sum_{i=1}^r PA_i$$

UP_i - používateľská správnosť triedy i

PP_i - producentská správnosť triedy i

r - počet tried
