


Klasifikace obrazu I



Tvorba tématických map

Klasifikace je vedle analogové interpretace snímků základním krokem tématického mapování s využitím obrazových materiálů DPZ




Kvantitativní charakteristiky jsou transformovány na kvalitativní

Klasifikace obrazu - základní pojmy

- Proces, při kterém je jednotlivým obrazovým prvkům přiřazován určitý informační význam.
- Cílem je nahradit hodnoty radiometrických charakteristik původního obrazu, které vyjadřují spektrální vlastnosti objektů a jevů na něm zobrazených, hodnotami vyjadřujícími tzv. **informační třídy** (např. land cover)
- Typ a obsah nové informace (např. tématické mapy) závisí na zaměření celého projektu. Hledané informační třídy jsou definovány na počátku procesu klasifikace ve formě tzv. **klasifikačního schématu**.
- Klasifikace není procesem jednosměrným, je procesem iteračním

Geometrické základy klasifikace




Jev je charakterizován dvěma znaky - T, S


Nejpoužívanějším kritériem podobnosti je VZDÁLENOST.

Obecně - čím blíže se nacházejí body v m-rozměrném prostoru, tím jsou si podobnější.

Euklidovská vzdálenost ve 2D



Euklidovská vzdálenost ve 3D



Vzdálenost v m- rozměrném prostoru

Pomocí vlastností Euklidovského metrického prostoru lze tento typ vzdálenosti bodů definovat obecně pro m-rozměrný prostor:

$$d_{ij} = \sqrt{\sum_{k=1}^m (x_{ki} - x_{kj})^2}$$

Euklidovská vzdálenost předpokládá ortogonalitu os definovaného prostoru – to znamená vzájemnou nezávislost použitých znaků.

Klasifikátor – rozhodovací pravidlo


- Klasifikace je založena na použití určitých rozhodovacích pravidel (tzv. **klasifikátorů**), podle nichž lze všechny prvky obrazu zařadit do určité třídy.
- Klasifikátory mohou být obecně založeny na nejrůznějších vlastnostech objektů a jevů v obraze. Podmínkou je, že jevy či objekty v obraze se v hodnotách porovnávaných vlastností vzájemně dostatečně odlišují.
- Nejčastěji se využívá klasifikátorů založených na **spektrálním chování**.
- Klasifikátory tzv. **prostorového chování** - zahrnují rozpoznávací příznaky jako texturu, vzájemnou vzdálenost (proximitu), velikost, tvar, opakovatelnost či kontext. Tyto klasifikátory se snaží simulovat proces vizuální klasifikace.
- Klasifikátory **časového chování** využívají časových změn objektů jako prostředku k jejich třídění (např. u zemědělských plodin se některé jejich spektrální a prostorové parametry mění typicky s časem).

Klasifikátory spektrálního chování


- K zařazení všech prvků obrazu do určité třídy používají multispektrálních dat a znalosti spektrálního chování objektů
- Vychází z předpokladu, že různé objekty vykazují odlišné spektrální chování na základě svých odrazových nebo vyzařovacích vlastností.
- Za nejjednodušší způsob automatické klasifikace založený na znalosti odrazových a vyzařovacích vlastností využívající pouze jednoho pásma multispektrálního obrazu lze považovat např. techniky prahování
- V důsledku mnoha vnějších i vnitřních vlivů jsou spektrální vlastnosti různých objektů v určitém intervalu spektra podobné.
- Celý koncept lze tedy zobecnit a použít pro charakterizování objektů a jevů více charakteristik - více pásem, která potom definují osy tzv. **multispektrálního prostoru**.

Spektrální příznaky a příznakový prostor


Pokud naměřená či vypočtená charakteristika každého objektu v určitém pásmu (intervalu spektra) bude zároveň představovat charakteristiku, podle které bude možné objekt rozpoznat - tzv. **příznak** - potom lze každé pásmo označit jako jeden rozměr tzv. **příznakového prostoru**.




Obrazový prostor (Image space)



Spektrální prostor (Spectral space)



Příznakový prostor (Feature space)



Klasifikace založená na teorii spektrálního chování je tedy obecně procesem hledání všech **spektrálních tříd**, které tvoří **třidu informační**.

Bodové klasifikátory

Klasifikátory založené na spektrálních vlastnostech se označují také jako **bodové („per-pixel“) klasifikátory**,

K zařazení obrazových prvků do jednotlivých tříd nepoužívají vlastnosti a příznaků okolních pixelů, ale pouze pixelu klasifikovaného.

Vzhledem k charakteru běžně dostupných obrazových dat vychází celý koncept automatické klasifikace založené na spektrálním chování povrchů z určitých zjednodušení:

- **citlivost** snímáčního zařízení je **konstantní** pro všechna pásma multispektrálního obrazu
- každý obrazový prvek odpovídá **přesně definované ploše** na zemském povrchu
- každý obrazový prvek představuje **homogenní povrch** ve smyslu jeho spektrálního chování
- naměřená data v každém pásmu mají **normální rozdělení**
- každý obrazový prvek může náležet pouze k **jedné** klasifikované **třídě**


Základní druhy klasifikace

- klasifikace řízená, neřízená, hybridní
- klasifikace per pixel a per-object
- klasifikátory parametrické a neparametrické
- klasifikátory „tvrdé“ a „měkké“ (fuzzy)
- sub-pixelové klasifikace
- klasifikace založené na strojovém učení (rozhodovací stromy a neuronové sítě)
- expertní systémy (knowledge-based, rule-based classification)

Řízená klasifikace obrazu – obecný postup

1. definování tzv. **trénovacích ploch**
2. výpočet statistických charakteristik (tzv. **spektrálních příznaků**) pro trénovací plochy charakterizující jednotlivé třídy, jejich editace a **výběr vhodných pásem** pro vlastní klasifikaci
3. **volba** vhodného rozhodovacího pravidla (tzv. **klasifikátoru**) pro zařazení všech prvků obrazu do jednotlivých tříd
4. **zatrídění** všech obrazových prvků do vymezených tříd
5. **úprava, hodnocení a prezentace** výsledků klasifikace

1. Vytvoření trénovacích ploch - vzorů



Trénovací (učicí) etapa

- Trénovací etapa musí být **kompletní** a **reprezentativní**.
- Měla by zahrnovat též podpůrná data.
- Trénovány jsou spektrální třídy.

Definování vhodných trénovacích ploch závisí na těchto faktorech:

- **Dostatečný počet pixelů v každé trénovací ploše:** pro výpočet reprezentativních statistických charakteristik je potřeba, aby trénovací plochy pro každou třídu byly tvořeny minimálně 100 pixely.
- **Vhodná velikost trénovacích ploch:** Značně velké trénovací plochy budou zvyšovat míru nehomogenity pro danou třídu, naopak malé trénovací plochy bude obtížné lokalizovat jak v obraze, tak i při verifikaci v terénu.
- **Vhodná poloha trénovacích ploch:** Pro účely testování výsledků klasifikace by měly být trénovací plochy umístovány tak, aby bylo možné je přesně vymezit v terénu.

Definování vhodných trénovacích ploch závisí na těchto faktorech:

- **Umístění trénovacích ploch:** trénovací plochy by neměly zabírat okrajové pixely daného povrchu, který mají reprezentovat, protože ty většinou obsahují smíšenou spektrální informaci.
- **Rozmístění trénovacích ploch pro danou třídu:** v důsledku vnějších (např. osvětlení scény), ale i vnitřních vlivů (např. různý vodní obsah), mohou být stejné povrchy reprezentovány poněkud odlišnými hodnotami radiometrických charakteristik.
- **Míra homogenity trénovacích ploch z hlediska jejich spektrálního chování:** Bez ohledu na následně použité rozhodovací pravidlo k zařazení pixelů do tříd, míry variability pixelů v trénovací ploše jako rozptyl či směrodatná odchylka jsou základním ukazatelem jejich vhodnosti. Nutnou podmínkou použití řady klasifikátorů je také normalita rozdělení pixelů v trénovacích plochách.

2. Výpočet statistických charakteristik jednotlivých tříd


Pixely trénovacích ploch tvoří vzorek (**masku**), pro který jsou vypočteny statistické charakteristiky, každé třídy.

Statistické charakteristiky jednotlivých kategorií popisují tzv. **spektrální příznaky**.

Spektrální příznaky (**signatury**) jsou charakterizovány měrami úrovně a měrami variability, nejčastěji:

- průměrovým vektorem
- rozptylem (směrodatnou odchylkou)
- kovarianční maticí

Průměr a rozptyl hodnot pixelů pro jedno pásmo



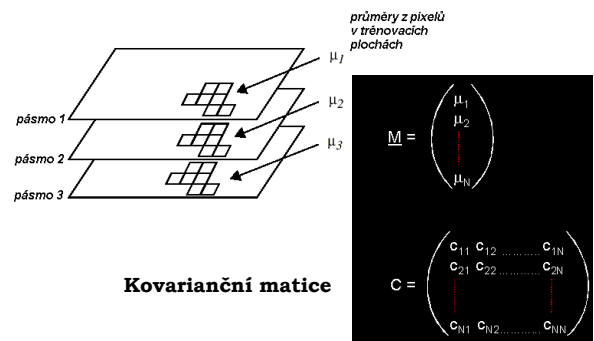
Rozptyl (variance) dvou pásem = kovariance

$$c_{kl} = \frac{\sum_{j=1}^n (x_{ij} - \mu_k)(x_{ij} - \mu_l)}{(n-1)}$$


korelace

$$\rho_{kl} = \frac{c_{kl}}{\sigma_k \sigma_l}$$


Průměrový vektor




Hodnocení trénovacích ploch



Histogramy znázorňující rozdělení hodnot v jednotlivých pásmech TM-2, TM-4 a TM-5 pro trénovací plochy jedné vybrané třídy



Spektrogram pro vybrané třídy A, B, C a jednotlivá klasifikovaná pásma TM-2, TM-4 a TM-5 multispektrálního obrazu



Hodnocení vzájemné separace tříd pomocí korelačního pole dvou pásem a elipsy charakterizující trénovací množinu každé třídy

Hodnocení kvality trénovací etapy

- Hodnocení míry odlišnosti (separability) mezi jakýmkoliv dvěma třídami může být vyjádřena také ve kvantitativní formě.
- Statistickou charakteristikou, která vyjadřuje míru separace může být tzv. **divergence** - vážená vzdálenost mezi průměrovými vektory uvažovaných tříd

$$D_{ij} = \frac{1}{2} \text{tr}((C_i - C_j)(C_i^{-1} - C_j^{-1})) + \frac{1}{2} \text{tr}((C_i^{-1} - C_j^{-1})(\mu_i - \mu_j)(\mu_i - \mu_j)^T)$$

- i a j = **porovnávané třídy (signatury)**
- C_i = **kovarianční matice třídy i**
- μ_i = **průměrový vektor třídy i**
- tr = „**trace**“ funkce - suma prvků na hlavní diagonále
- T = **funkce transpozice**

Matice divergencí

- Divergence nabývá hodnot v intervalu 0 až 2.
- Hodnota 0 znamená dokonalou shodu mezi charakteristikami spektrálních příznaků porovnávaných tříd - tedy nejméně vhodný výsledek.
- Hodnota 2 znamená ideální výsledek - tedy dostatečné odlišení zkoumané dvojice tříd.
- Za dobrou míru separability tříd jsou považovány hodnoty divergence v intervalu 1,9 až 2,0.

třída	voda	les	pole	ttp
les	2,000			
pole	2,000	2,000		
ttp	2,000	1,993	1,879	
holá páda	2,000	1,990	2,000	1,999

Průměrná Separabilita: 1.879
 Minimální Separabilita: 1.999
 Maximální Separabilita: 2.000


Výběr vhodných pásem pro klasifikaci

- Jako objektivního kritéria k výběru nevhodnějších pásem, která budou následně vstupovat do klasifikace lze využít také hodnot divergence.
- Statistický popis spektrálních příznaků je možno v prvním kroku vygenerovat pro větší počet původních i transformovaných pásem zpracovávaného obrazu.
- Z hodnot **divergencí** jsou určena pásma nevhodnější (většinou 3 či 4 pásma) a pro takto označená pásma jsou poté znovu vypočteny statistické charakteristiky spektrálních příznaků jednotlivých natrénovaných tříd.

3. Použití vhodného rozhodovacího pravidla

Výsledkem předchozích dvou etap je tedy **statistický popis** hledaných tříd, vytvořený na základě trénovacích ploch.


V klasifikační etapě jsou prostřednictvím vhodného **rozhodovacího pravidla - klasifikátoru** postupně zařazovány jednotlivé prvky obrazu do jedné z tříd.




Nejužívanější per-pixel (bodové) klasifikátory

- Klasifikátor minimální vzdálenosti středů shluků
- Klasifikátor pravouhelníků
- Klasifikátor „K“ nejbližších sousedů
- Klasifikátor maximální pravděpodobnosti

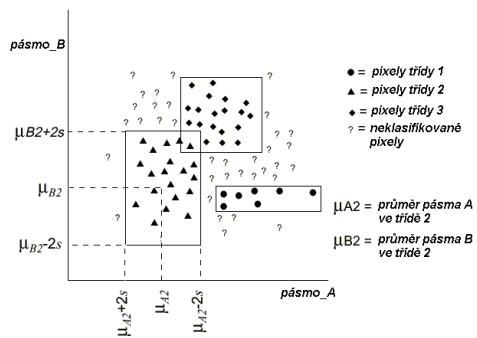
Klasifikátor minimální vzdálenosti středů shluků




Klasifikátor pravoúhelníků



Modifikovaný klasifikátor pravoúhelníků




Klasifikátor nejbližšího souseda



Klasifikátor „K“ nejbližších sousedů


- Modifikace klasifikátoru minimální vzdálenosti.
- Hodnotí příslušnost pixelu k určité třídě také na základě **početního zastoupení pixelů** určité třídy v okolí
- Algoritmus vyhledá ke klasifikovanému pixelu určitý předem stanovený počet (**K**) nejbližších pixelů v analyzovaném příznakovém prostoru bez ohledu na trénovací množiny.
- Pixel je potom zařazen do třídy, která v množině **K** sousedů převažuje.
- Parametr **K** nabývá hodnot 1-10, při vyšším počtu obsahuje výsledek velký podíl šumu.
- V algoritmu je možné také omezit počet hodnocených sousedů určitou mezní vzdáleností.



Klasifikátor maximální pravděpodobnosti


Příklad pro 1D

- Parametrický klasifikátor
- Z pixelů v trénovacích plochách počítá míry úrovně i proměnlivosti
- Ty definují frekvenční funkci normálního rozdělení




- Každé hodnotě přísluší určitá pravděpodobnost výskytu v každé třídě


Klasifikátor maximální pravděpodobnosti – 2D



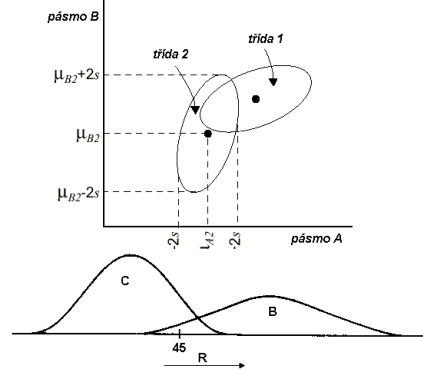
Klasifikátor maximální pravděpodobnosti – 2D



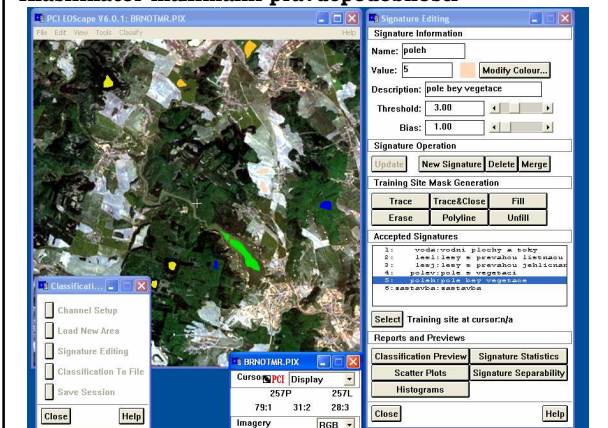
Klasifikátor maximální pravděpodobnosti - nepřekrývající se třídy v příznakovém prostoru



Klasifikátor maximální pravděpodobnosti - překrývající se třídy



Klasifikátor maximální pravděpodobnosti



Bayesův klasifikátor

- Je rozšířením klasifikátoru maximální pravděpodobnosti, který modifikuje použitím tzv. **a priori** pravděpodobnosti.
- Pravděpodobnosti příslušnosti pixelu k určité třídě je vážena jeho pravděpodobnosti výskytu. Ta může být např. přímo úměrná předpokládanému plošnému zastoupení třídy v obraze.
- P1 - Zjišťujeme pravděpodobnost, že daný pixel náleží k určité třídě, nabývá-li tento pixel například hodnoty 45.
- P2 - Z trénovacích dat lze určit pravděpodobnost, s jakou bude mít pixel hodnotu 45, za předpokladu, že se jedná o danou třídu.
- Podle tzv. bayesova zákona lze hledanou pravděpodobnost (P1) vypočítat za předpokladu, že dopředu (a priori) stanovíme pravděpodobnost (P2).

Podmíněné pravděpodobnosti


Potřebujeme zjistit:

$P(F | 45)$ – pravděpodobnost výskytu třídy les za předpokladu výskytu pixelu s hodnotu 45

$P(C | 45)$ – pravděpodobnost výskytu třídy pole za předpokladu výskytu pixelu s hodnotu 45

Pravděpodobnost výskytu jedné ze dvou tříd:

$$P(F) = 0,5 \quad P(C) = 0,5$$




Z trénovacích dat lze zjistit:

$P(45 | F)$ – pravděpodobnost výskytu hodnoty 45 za předpokladu výskytu třídy les

$P(45 | C)$ – pravděpodobnost výskytu hodnoty 45 za předpokladu výskytu třídy pole

Podmíněné pravděpodobnosti

Příklad: $P(45 | F) = 0,75$
 $P(45 | C) = 0,25$



Hledáme $P(F | 45)$ a $P(C | 45)$ abychom je porovnali a zjistili max P

Bayesův zákon

Thomas Bayes (1702-1761) definoval vztah mezi neznámými $P(F | 45)$, $P(C | 45)$ a známými $P(45 | F)$, $P(45 | C)$, $P(F)$ a $P(C)$

$$P(F | 45) = \frac{P(F) P(45 | F)}{P(F) P(45 | F) + P(C) P(45 | C)}$$

$$P(45 | F) = 0,75 \quad P(45 | C) = 0,25$$

Obecné vyjádření Bayesova zákona

$$P(b_i | a_i) = \frac{P(b_i) P(a_i | b_i)}{P(b_1) P(a_i | b_1) + P(b_2) P(a_i | b_2) + \dots}$$

Přednosti a nedostatky Bayesova klasifikátoru


- Jeho použití je efektivní v případě, že dochází k překryvům tříd v příznakovém prostoru.
- Nabízí vhodný nástroj pro zahrnutí jiných než obrazových dat do klasifikace.
- Nabízí prostředek k hodnocení „ceny“ za nesprávně klasifikované pixely.
- Umožňuje kombinovat různé klasifikátory.
- Slabou stránkou je výběr vhodných trénovacích ploch a určení a priori pravděpodobností.

4. Zařazení každého obrazového prvku ve výsledném obraze do jedné ze tříd základních druhů povrchů

A	A	A	B	B	A	O
A	A	B	B	B	O	O
A	A	A	B	B	O	O
A	A	A	A	B	B	B
A	C	C	C	C	B	B
O	C	C	C	C	B	B

A – voda
 B – les
 C – zastavěná plocha
 O – nezařazeno

5. Sestavení výsledné mapy základních druhů povrchů



Kovarianční matice

	band A	band B	band C	band D
band A	Var_A	Cov_{BA}	Cov_{CA}	Cov_{DA}
band B	Cov_{AB}	Var_B	Cov_{CB}	Cov_{DB}
band C	Cov_{AC}	Cov_{BC}	Var_C	Cov_{DC}
band D	Cov_{AD}	Cov_{BD}	Cov_{CD}	Var_D

$$Cov_{AB} = Cov_{BA}$$

- Matice je čtvercová, symetrická
- Je základem pro definování měr podobnosti, pro transformace (PCA) i pro definování většiny parametrických klasifikátorů