


A satellite is shown in orbit above the Earth. The satellite has a yellow thermal blanket covering its central body and two large solar panel arrays extending outwards. The Earth's surface is visible below, showing blue oceans and white clouds. The background is the blackness of space.

Dálkový průzkum Země

Ústav geoinformačních technologií
Lesnická a dřevařská fakulta MENDELU

Klasifikace obrazu

- Klasifikaci můžeme obecně definovat jako seskupování vzájemně si podobných prvků (entit) do určitých skupin (tříd, kategorií).
- V počítačových programech jde o operace, umožňující identifikovat v souboru prvků skupiny se společnými vlastnostmi.
- V obrazových záznamech dálkového průzkumu jsou entity na nejnižší úrovni reprezentovány jednotlivými pixely. Klasifikace představuje proces, při kterém se jednotlivé pixely originálního numerického záznamu zařazují do tříd a vzniká tak klasifikovaný snímek. Originální obrazový záznam se tak stává tématickou mapou.
- Cílem digitální klasifikace je získat utříděnou informaci o objektech a jevech na zemském povrchu – např. kategorie půdního krytu, vegetační typy, půdní typy, geologické objekty, apod.



A

B

© CCRS / CCT

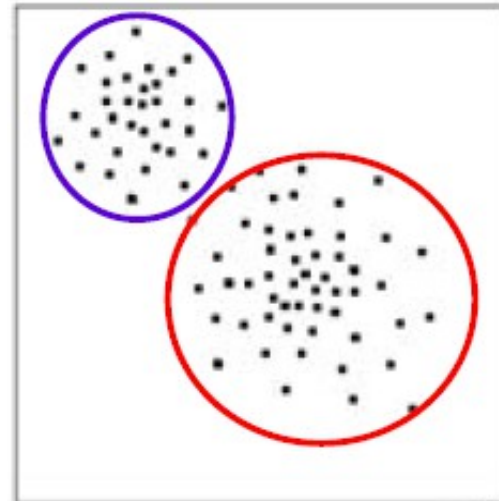
Příznakový prostor

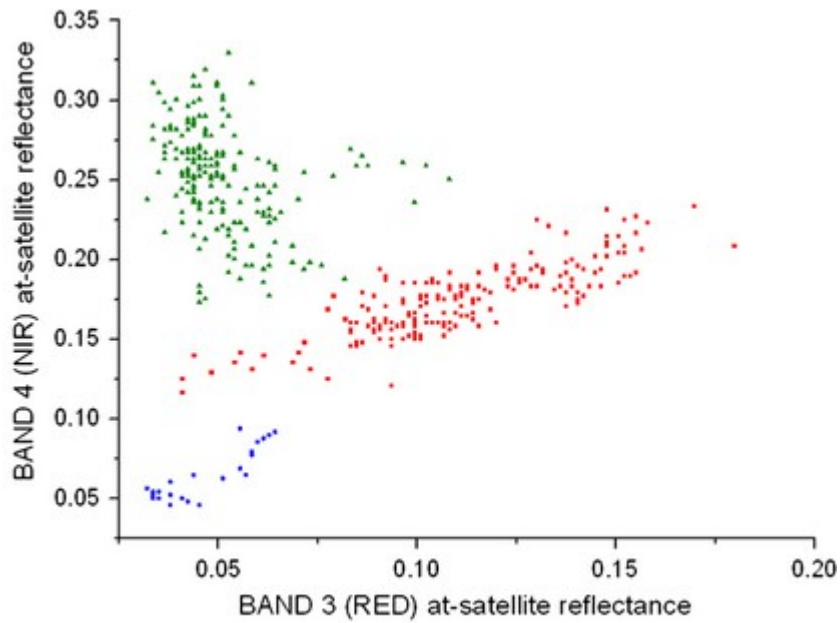
- Příznakový prostor je Euklidovský prostor
- Při klasifikacích se používá Euklidovská vzdálenost – jde zde o vzdálenost (Pythagorova věta) mezi klasifikovaným pixelem a centrem uvažovaného shluku
- Vzdálenost je pojem, který náš mozek používá při rozpoznávání obrazců. Čím blíže se nacházejí body v p-rozměrném prostoru, tím jsou si podobnější

$$d_{ab} = \sqrt{(a_x - b_x)^2 + (a_y - b_y)^2}$$

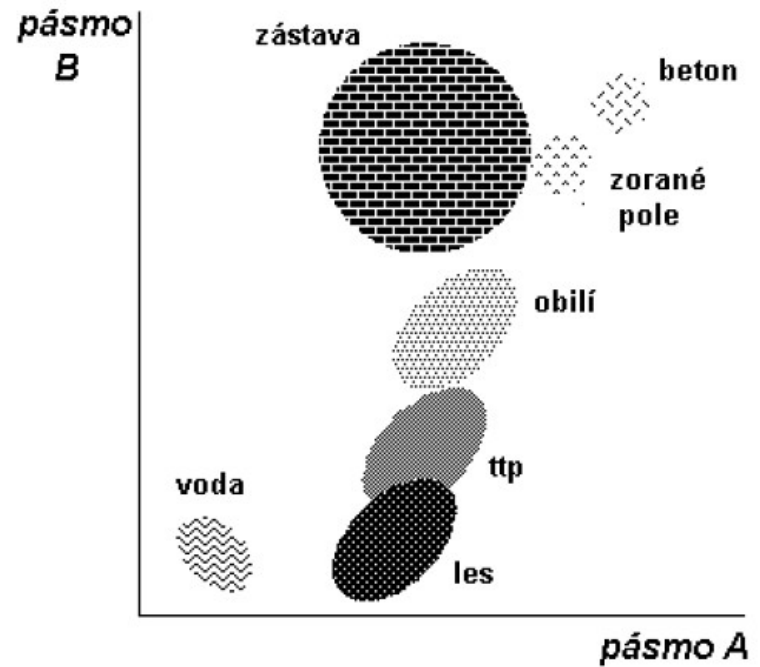
$$d_{ab} = \sqrt{\sum_{i=1}^p (x_{ia} - x_{ib})^2}$$

- 2-rozměrný prostor
- p-rozměrný prostor






(b)



Příklad objektů v dvojrozměrném příznakovém prostoru

RGB Space for the Training Data of Image 4




Příklad objektů v trojrozměrném příznakovém prostoru

Automatizované klasifikační operace se obvykle rozdělují do tří skupin:

- Spektrální rozpoznávání obrazců (spectral pattern recognition) - spektrální klasifikace „**per pixel**“, **klasifikace bodová**.
Vztahuje se k souboru hodnot odrazivosti zaznamenaných v různých spektrálních pásmech.
- Prostorové rozpoznávání obrazců (spatial pattern recognition) - **kontextuální klasifikace**.
Zahrnuje kategorizaci pixelů na základě prostorových vztahů k pixelům sousedním.
- **Časové** rozpoznávání obrazců (temporal pattern recognition).
K identifikaci objektů se využívá časových změn.

Spektrální rozpoznávání obrazců (spectral pattern recognition)

- Každý pixel je zpracováván samostatně na základě svých specifických vlastností metodami diskriminační analýzy.
- Hlavními vlastnostmi pixelu jsou v tomto případě poloha (v systému řádků a sloupců), velikost a hodnota spektrální odrazivosti



Prostorové rozpoznávání obrazců (spatial pattern recognition)

- Tento typ klasifikace se snaží postihnout mechanismy prostorové syntézy kterou realizuje člověk v průběhu vizuální interpretace.
- Lze přitom pracovat nejen se spektrálními charakteristikami, ale také se vzdáleností pixelů, jejich **okolím**, **tvarem** a **velikostí** objektů, **texturou** obrazu, směrovostí, opakováním vzorů apod.
- Operace spojené s kontextuální klasifikací jsou však komplexnější a tedy mnohem náročnější na výpočetní techniku.

Časové rozpoznávání obrazců (temporal pattern recognition)

- Multitemporální snímky, pořízené ve vhodných údobích, umožňují využít při rozpoznávání rostlinných porostů charakteristických spektrálních a prostorových změn, ke kterým dochází v průběhu vegetačního cyklu.
- V lesnictví lze např. tímto způsobem spolehlivě odlišit jehličnany od listnáčů nebo modřín od ostatních jehličnanů.

BODOVÁ – PER PIXEL – KLASIFIKACE

- Bodová („per pixel“) spektrální klasifikace je nejpodrobněji rozpracovanou a nejčastěji používanou klasifikační technikou.
- V průběhu této klasifikace se převádějí **spektrální třídy** pixelů, tj. skupiny pixelů, které v multispektrálním prostoru vykazují dostatečně vysokou míru podobnosti, do menšího počtu **tříd informačních**, kterých lze využít k tématické charakterizaci reálných objektů na zemském povrchu.
- Hlavní metody
 - Neřízená klasifikace (Unsupervised classification),
 - Řízená klasifikace (Supervised classification).
 - Hybridní klasifikace (Hybrid classification)
Ta kombinuje obě uvedená pojetí s cílem omezit jejich nevýhody a dosáhnout tak lepších výsledků.

Neřízená klasifikace

- Neřízená klasifikace je metoda, která identifikuje přirozené skupiny nebo struktury, obsažené v zaznamenaných multispektrálních datech (Campbell 1996).
- Při tomto způsobu klasifikace se metodami shlukové analýzy automatizovaně extrahují dominantní obrazce spektrální odrazivosti (tzv. **spektrální třídy**).
- Teprve dodatečně, ex post, se zjišťuje reálný význam vzniklých tříd (**informační třídy**).
K tomuto účelu se používají mapy, letecké snímky, terénní pochůzky a jiné materiály, které se týkají zájmového území.
- Na začátku klasifikace se **nevytvářejí trénovací množiny**.
- Nejdříve se určí spektrální třídy a teprve následně se jim přiřazuje informace.
- K vymezení odlišných skupin (shluků) se používá **shluková analýza**.
- **Informační třídy** vznikají v průběhu **interpretační fáze** neřízené klasifikace.

Metody shlukové analýzy

- Hierarchické
 - aglomerační metody: jednotlivé pixely (segmenty) se postupně spojují do shluků
 - rozkladové metody: vstupní soubor se postupně dělí do více skupin
- Nehierarchické (optimalizační)
 - hledají takový rozklad množiny objektů, který je optimální podle zvoleného kritéria. Využívají iterační algoritmy.





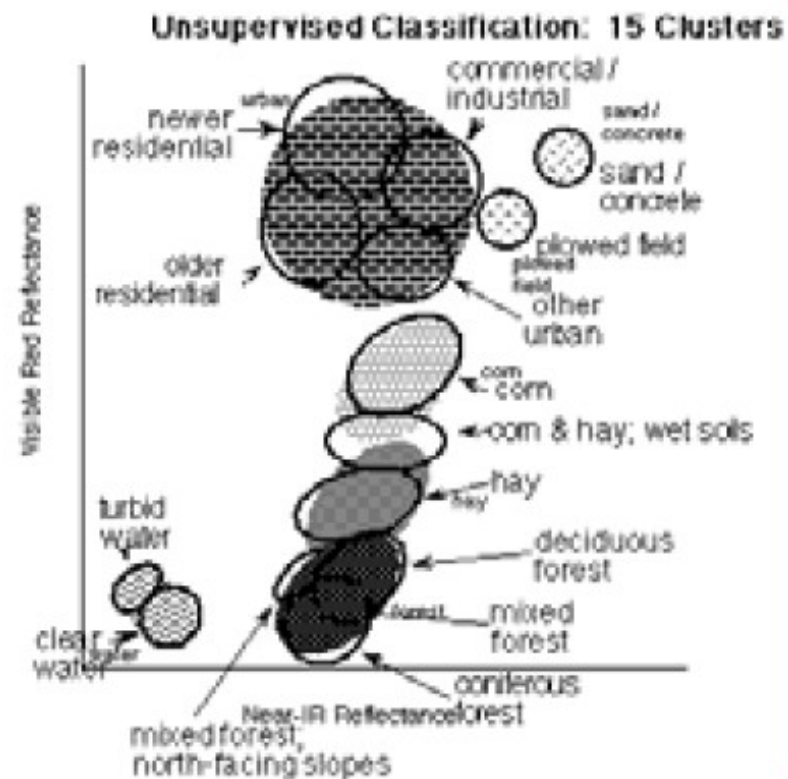

Schéma aglomerační a rozkladové metody

Obecné kroky shlukové analýzy

- Určení spektrálních pásem snímku, se kterými má algoritmus pracovat
- Definování (přibližného) počtu výsledných shluků
- Určení počáteční polohy centroidu pro každý shluk
- Postupné přiřazení všech pixelů k tomu shluku, k němuž mají v příznakovém prostoru nejbližší
- Výpočet nové polohy centroidu pro každý shluk na základě přiřazených pixelů
- Opakování kroku 3 a 4 do té doby, dokud se poloha shluku či počet pixelů zařazených do shluku výrazně nemění
- Přiřazení konkrétního významu každému tzv. stabilnímu shluku
- Vytváření informačních tříd spojováním (agregací) tříd spektrálních



Ilustrace iteračního postupu shlukování

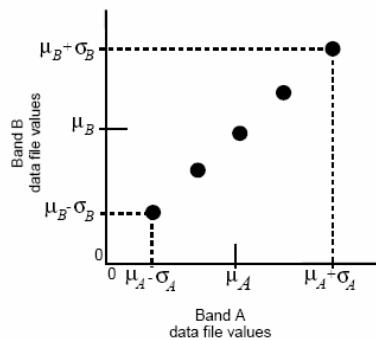


Vztah mezi počtem shluků a spektrálními / informačními třídami

Stanovení počáteční polohy centroidu, možnosti:

- Úvodní středy shluků jsou pravidelně rozmístěny po diagonále příznakového prostoru (algoritmus ISODATA)

5 arbitrary cluster means in two-dimensional spectral space



ISODATA Arbitrary Clusters

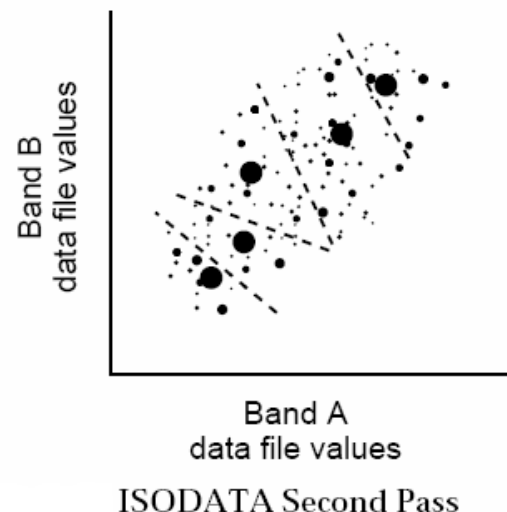
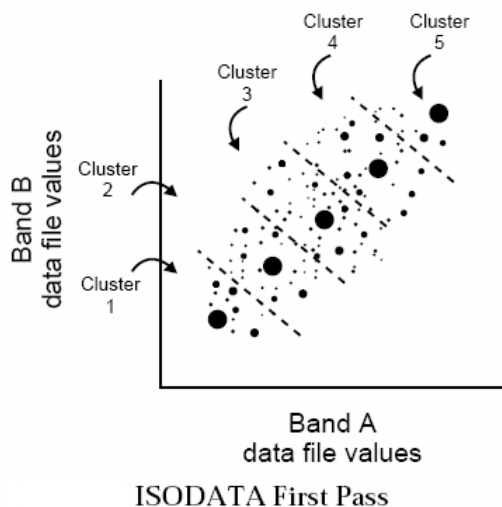
- Úvodní polohu středu lze ručně definovat ze základacího souboru (seed file), ve kterém je uvedena DN hodnota reprezentující střed shluku – řádky tvoří průměrový vektor pro jednotlivé shluky.

pásmo	1	2	3	4
1. shluk	5	3	5	9
2. shluk	40	45	44	20
3. shluk	57	60	47	49

Proces shlukování lze hodnotit např. podle minimální vzdálenosti dvou shluků (spojení – rozdělení shluků)

Výpočet středů shluků (konec iterací) je ukončen pokud:

- je shluk stabilní, tzn. že se poloha centroidu výrazně neliší mezi dvěma iteracemi.
- byl dosažen celkový počet opakování



Shlukování metodou ISODATA



Algoritmy shlukové analýzy

- **metoda K-means** (K-průměrů)
- **ISODATA** (Iterative Self-Organising Data Analysis Technique)

Tyto algoritmy předpokládají, že dopředu známe (alespoň přibližně) počet shluků, do kterého chceme rozdělit vstupní soubor.


Výpočet začne s k náhodnými shluky. Jednotky se poté postupně přesouvají mezi jednotlivými shluky a to tak, aby:

1. minimalizovaly variabilitu mezi jednotkami uvnitř jednoho shluku
2. maximalizovaly variabilitu mezi jednotlivými shluky




Postupná změna polohy průměrového vektoru v příznakovém prostoru při iteracích u metody K-means


Výsledky klasifikace se od sebe často liší v případě odlišných iniciačních podmínek (určených v základacím souboru - seed file)



ISODATA klasifikace,
13 tříd, 1 iniciální centroid (seed)

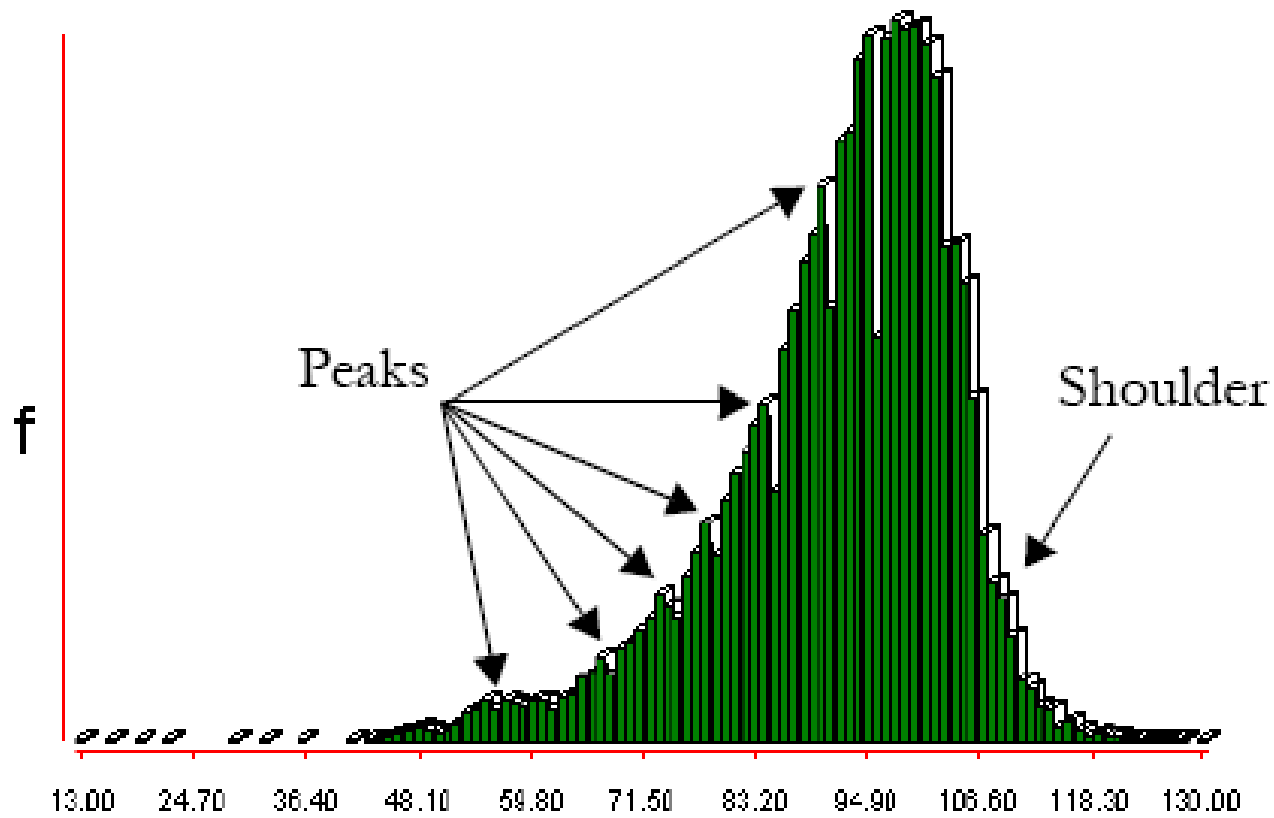


ISODATA klasifikace,
13 tříd, 13 iniciálních centroidů



Odhad počtu shluků je možný selekcí vrcholů z histogramu

(např. modul CLUSTER v Idrisi)



Neřízená klasifikace: výhody a nevýhody

Nevýhody


- časově náročný proces (mnoho iterací)
- výsledkem nejsou informační třídy

Výhody

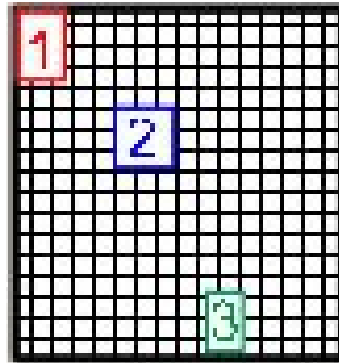

- nalezne i malé spektrální rozdíly v chování různých objektů
- při dostatečném počtu iterací není důležitá počáteční poloha shluků
- poskytuje předběžnou tématickou mapu (např. pro využití při řízené klasifikaci)

ŘÍZENÁ KLASIFIKACE

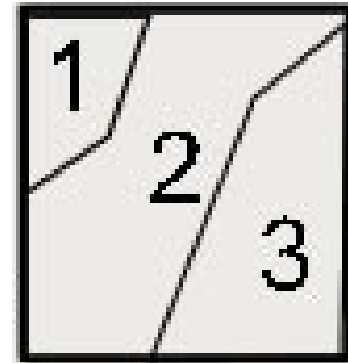

- Řízená klasifikace kategorizuje obrazový soubor do apriorně stanovených tématických tříd.
- Tyto třídy mohou přímo odpovídat tématickým třídám požadovaným ve výsledku, nebo mohou být specifikovány úžeji a teprve později do požadovaných tříd sloučeny.
- Při zpracování se využívají informace získané z reprezentativních vzorků, které se v zájmovém území typicky vyskytují a které lze v obrazovém souboru spolehlivě identifikovat. Tyto vzorky o známé identitě, sloužící k popisu jednotlivých informačních tříd, se obvykle nazývají trénovací plochy, respektive **trénovací množiny**.
- Odlišnost trénovacích množin v daných spektrálních pásmech umožňuje rozpoznání tématických tříd na základě jejich spektrálních příznaků.
- Na základě statistických charakteristik odvozených z trénovacích množin (obvykle se označují jako **spektrální signatury**) se pak vyhodnocuje příslušnost (někdy též jen stupeň příslušnosti) jednotlivých pixelů k tématickým třídám.
- K tomuto účelu jsou v počítačích implementovány speciální soubory operací, tzv. klasifikátory.




Snímek





Trénovací množiny



Klasifikace




A = water
B = agriculture
C = rock



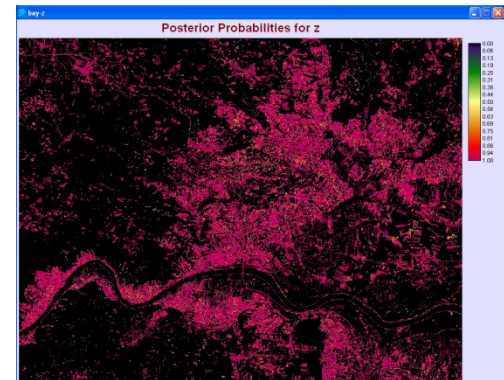
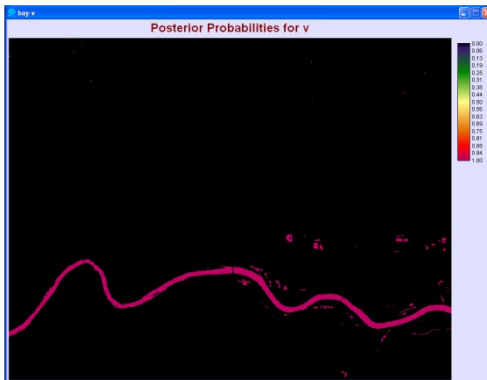


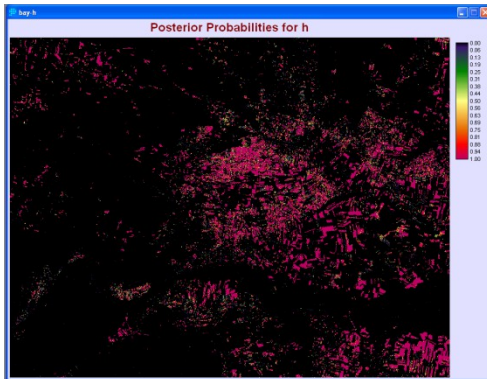
Tvrdé a měkké klasifikátory

- **Tvrdé klasifikátory** poskytují jednoznačné rozhodnutí o přiřazení pixelu do některé z výstupních tříd.
- **Měkké klasifikátory** vyjadřují úroveň pravděpodobnosti, se kterou pixel do každé z těchto tříd náleží. Měkké klasifikátory se s výhodou využívají ke zjištění tzv. smíšených pixelů, které mohou obsahovat směs dvou nebo více tříd a které by tvrdý klasifikátor zařadil jednoznačně do některé z nich.
- Výstupem není jeden výsledný klasifikovaný obraz, ale skupina rastrových souborů, vyjadřujících pomocí vypočtených hodnot jednotlivých pixelů – pravděpodobnost jejich příslušnosti k uvažované třídě. Jednotlivé třídy se v těchto případech zpracovávají odděleně a získané výstupy mohou vstupovat spolu s jinými záznamy do dalších procesů vyhodnocení.

Výsledek tvrdé klasifikace



Výsledek měkké klasifikace



Pracovní kroky řízené klasifikace

- Definování tzv. trénovacích ploch / trénovacích množin
- Výpočet statistických charakteristik (tzv. spektrálních signatur) pro trénovací plochy charakterizující jednotlivé třídy a jejich editace
- Výběr vhodných pásem pro vlastní klasifikaci
- Volba vhodného rozhodovacího pravidla (tzv. klasifikátoru) pro zařazení všech prvků obrazu do jednotlivých tříd, zatřídění všech obrazových prvků do vymezených tříd
- Úprava, hodnocení a prezentace výsledků klasifikace

1. Definice trénovacích množin

- **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.
- **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 – spektrálních signatur tříd

- Statistickou analýzou trénovacích množin daných klasifikačních tříd se určují typické charakteristiky spektrální odrazivosti těchto tříd. Pro takový soubor spektrálních příznaků se často používá termín **(spektrální) signatura**.
- V multispektrálním prostoru představuje soubor těchto charakteristik jakýsi spektrální klíč, který umožňuje od sebe odlišit jednotlivé klasifikační třídy



Hodnocení spektrálních signatur

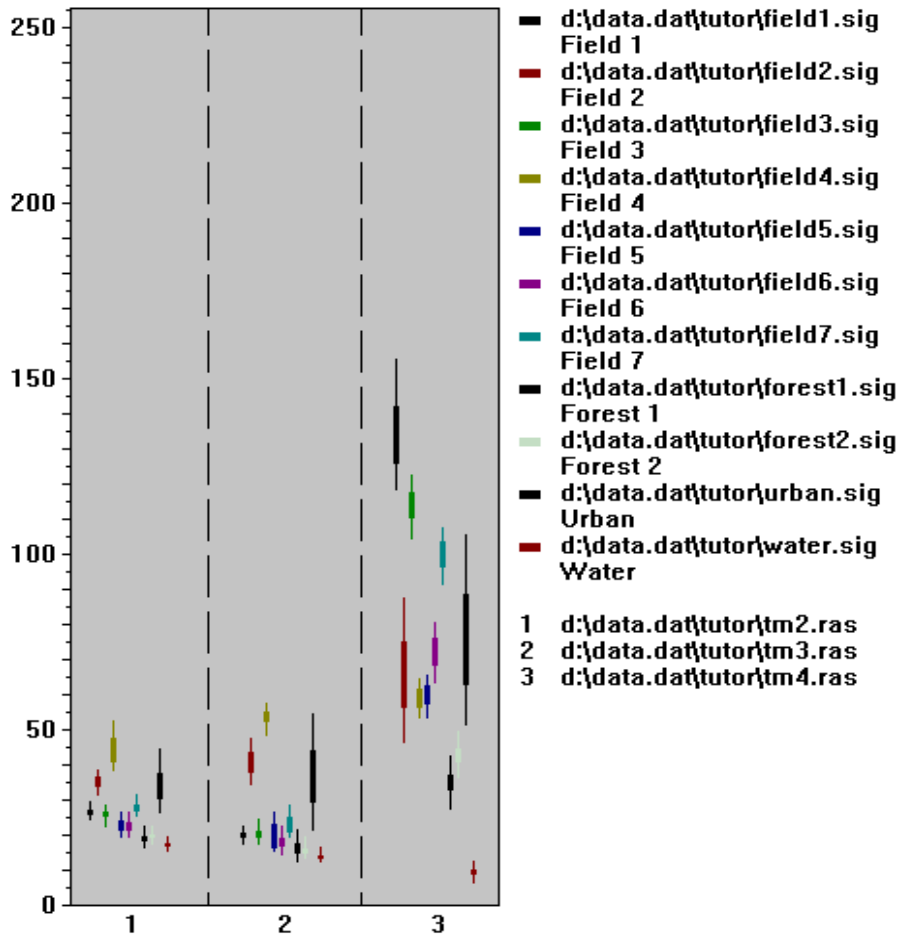
- Spektrální signatury umožňují posoudit nejen kvalitu zvolených trénovacích množin a jejich reprezentativnost, ale také míru jejich vzájemné odlišitelnosti, tzv. separabilitu.
- Možnosti hodnocení:
 - grafické
 - kvantitativní
 - ostatní

Grafické hodnocení

- pomocí **histogramů** pro jednotlivé třídy - ověření kvality dat pro jednu třídu v různých spektrálních pásmech
- pomocí tzv. **spektrogramu** – znázorňuje pro jednotlivé třídy průměr, rozptyl hodnot pixelů z trénovacích ploch pro každé pásmo. Možnost zjistit překryv jednotlivých tříd.
- **graf korelačního pole** DN hodnot mezi dvěma pásmy multispektrálního obrazu použitými pro klasifikaci.

Histogramy signatur

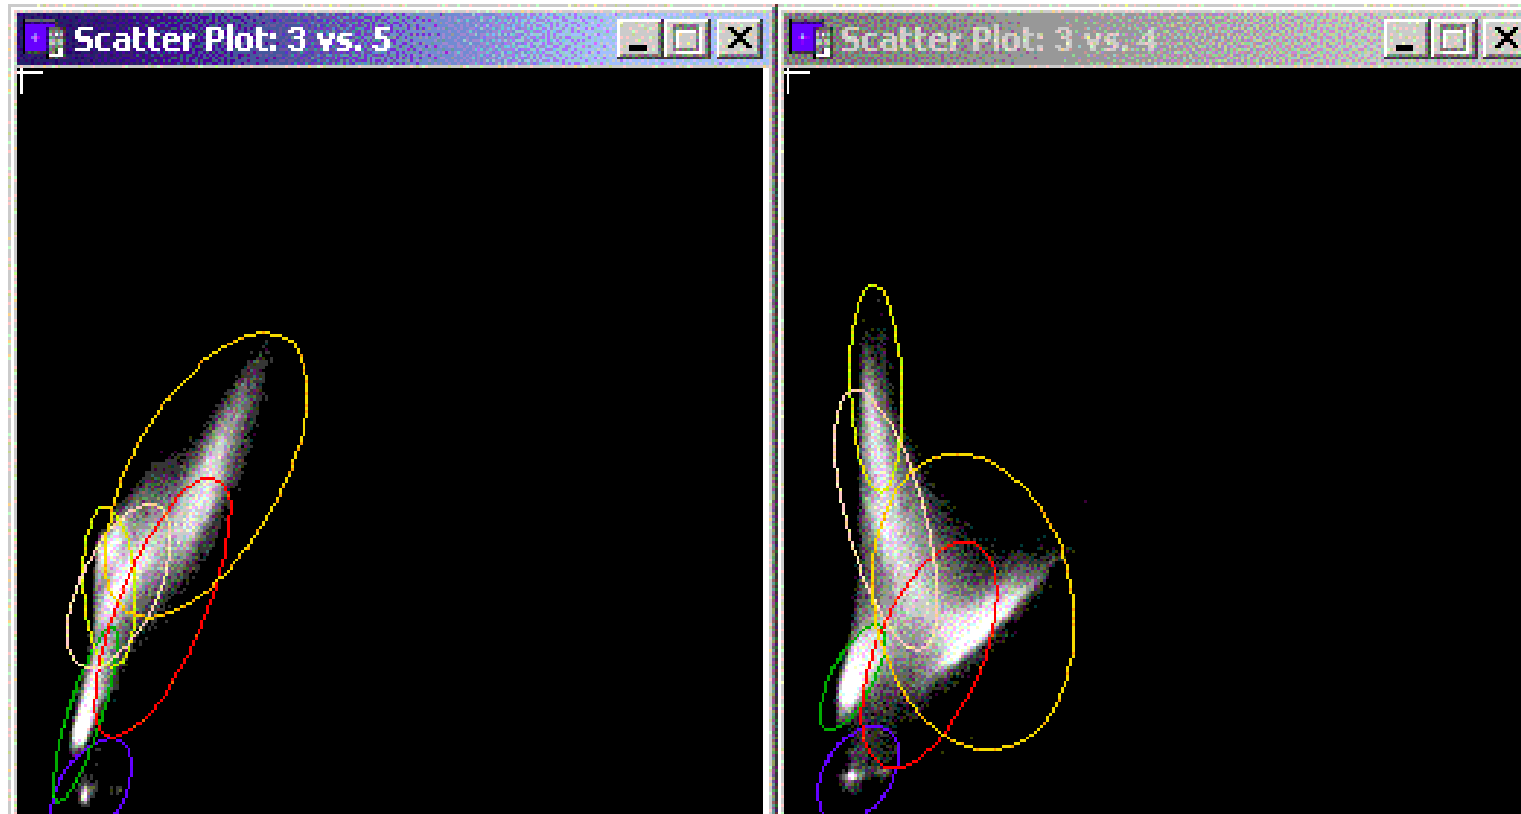




Spektrogram

- silnější čára – průměr \pm směrodatná odchylka,
- tenčí čára – interval minimálních a maximálních hodnot pixelů v trénovacích třídách.

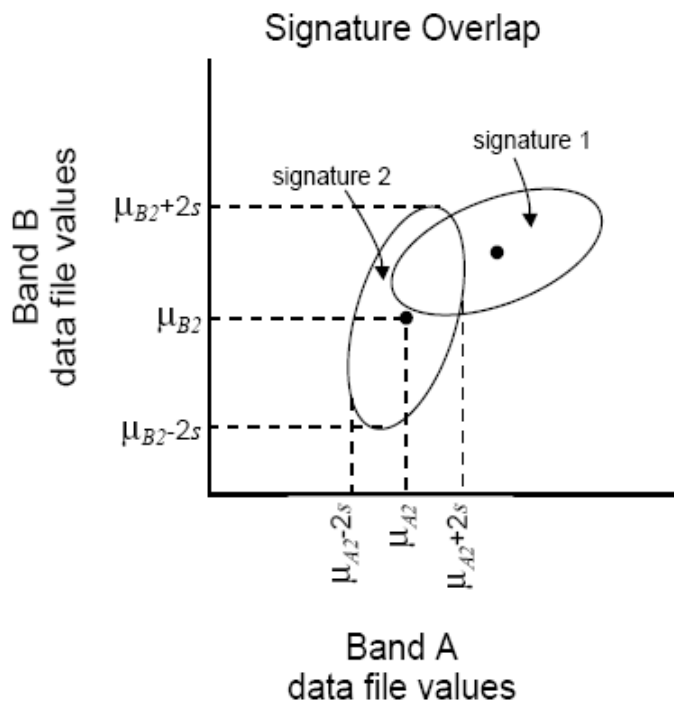
Korelační pole



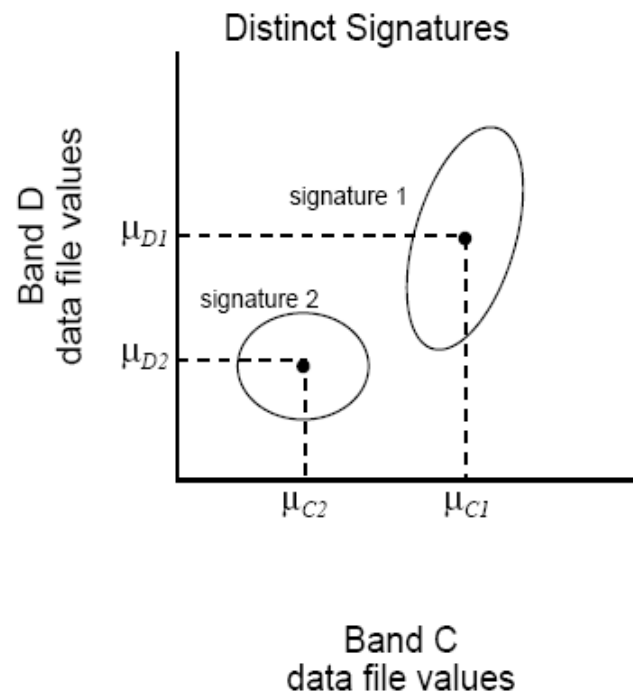
Hodnocení vzájemné separace tříd pomocí korelačního pole dvou pásem a elipsy charakterizující trénovací množinu každé třídy

Dvourozměrné znázornění signatur

Překrývající se signatury



Jednoznačné signatury



Kvantitativní hodnocení

- Divergence – vážená statistická vzdálenost (rozdílnost) mezi průměrovými vektory (průměrné hodnoty všech pásem) uvažovaných tříd.
- Čím je větší divergence, tím je větší statistická vzdálenost mezi trénovacími plochami a tím je větší pravděpodobnost správné klasifikace 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 půda	2,000	1,990	2,000	1,999

Problémy tříd s podobnými spektrálními vlastnostmi

- Pokud existují dvě třídy, které mají velmi podobné vlastnosti ve všech pásmech - jediná možnost zvolit jiný postup vyhodnocování, např. vizuální interpretaci.
- V této etapě se vybírají rovněž vhodná pásma pro klasifikaci.
- Pro odstranění vysoké korelace mezi pásmy se používají transformace původních pásem (spektrální zvýraznění), např. **analýza hlavních komponent (Principal Component Analysis – PCA)**, aritmetické operace aj.


3. Výběr pásem vhodných pro klasifikaci

- Statistický popis spektrálních příznaků je možno v prvním kroku vygenerovat pro větší počet původních i transformovaných pásem zpracovávaného obrazu.
- Jako objektivní kritérium k výběru nejvhodnějších pásem, která budou vstupovat do klasifikace mohou sloužit hodnoty divergence
- Z hodnot divergencí lze určit nejvhodnější pásma (téměř vždy se používají R a NIR pásma) a pro tato vhodná pásma se znovu mohou vypočítat statistické charakteristiky spektrálních příznaků jednotlivých trénovacích tříd.

4. Použití vhodného rozhodovacího pravidla


- Výsledkem předchozích dvou etap je statistický popis hledaných tříd, vytvořený na základě trénovacích ploch.
- V klasifikační etapě jsou prostřednictvím vhodného rozhodovacího pravidla - klasifikátoru postupně zařazovány jednotlivé prvky obrazu do některé z tříd.
- Nejužívanější metody řízené klasifikace (bodové (per-pixel) klasifikátory)
 - Klasifikátor minimální vzdálenosti pixelu od středů shluků
 - Klasifikátor „K“ nejbližších sousedů
 - Klasifikátor pravoúhelníků
 - Klasifikátor maximální pravděpodobnosti
 - Bayesův klasifikátor (měkká klasifikace)

- **Klasifikátor minimální vzdálenosti pixelu od středů shluků.**
- Nejdříve se pro každý shluk vypočítá průměrná spektrální hodnota pro každé pásmo
- Průměrné hodnoty definují střed shluku, tzv. centroid (= průměr signatury) ve vícerozměrném prostoru
- Každý pixel je následně do jednotlivých shluků zařazován podle jeho vzdálenosti od centroidu. (Nejkratší vzdálenost k určitému shluku – přiřazen pixel).
- Klasifikátor se nepoužívá pokud spektrální středy jsou v prostoru blízko velký rozptyl hodnot
- Nevýhoda: klasifikátor pracuje pouze s průměrnou hodnotou odrazivosti signatury a nebere v úvahu variabilitu (rozptyl) jejich hodnot kolem průměru.



Klasifikátor „K“ nejblížešších sousedů

- Jde o modifikaci klasifikátoru minimální vzdálenosti.
- Příslušnost pixelu k určité třídě se hodnotí také na základě početního zastoupení pixelů určité třídy v okolí.
- Algoritmus vyhledá ke klasifikovanému pixelu určitý předem stanovený počet (K) nejblížešších 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.
- Většinou se klasifikují všechny pixely a výpočet je rychlý
- Nebere v úvahu variabilitu třídy, třídy s nízkou variabilitou jsou preferovány
- Chybně zařazené 'neklasifikovatelné pixely' (Lze definovat mezní vzdálenost od středu shluku. Pokud je větší než zadaná hodnota pixel není zařazen.)



Klasifikátor pravoúhelníků


- Pixel je porovnáván s horními a dolními limity / hranicemi (např. min. a max. DN hodnoty signatury v každém kanálu)
- průměr DN hodnoty plus směrodatná odchylka signatury
- uživatelsky specifikované limity, dle znalosti signatur
- Dle definovaných hranic se vymezení pravoúhelníky, uvnitř kterých pixely patří k dané třídě.
- Ve vícerozměrném prostoru jsou oblasti definovány jako hyperkvádry, pravoúhelníky.

Překrývající se oblasti

- U sporných pixelů (ty, které spadají do více tříd) se používá:
 - dvoustupňová klasifikace (využití parametrických signatur sporných tříd),
 - nebo se stanoví priorita jednotlivých tříd,
 - nebo se pixel ponechá jako neklasifikovaný


Pixely nespádající do žádné oblasti

- Pixely mimo oblast uvažovaných tříd nejsou klasifikovány



Klasifikátor maximální pravděpodobnosti

- Maximum likelihood
- Pracuje s kvantitativními charakteristikami, tj. s rozptylem hodnot, korelací a kovariancemi každé třídy při zařazování pixelů
- Vychází z předpokladu normálního rozdělení shluků pixelů v trénovacích plochách.
- Na základě těchto charakteristik se počítá pravděpodobnost, s jakou pixel náleží do stanovených kategorií; pixel se přiřadí do té kategorie, pro kterou je vypočtená hodnota pravděpodobnosti nejvyšší.



Měkké klasifikátory

Bayesův klasifikátor

- Bayesův klasifikátor rozšiřuje klasifikátor maximální pravděpodobnosti o váhu pravděpodobnosti příslušnosti určitého pixelu k dané třídě použitím tzv. apriorní pravděpodobnosti.
- Pravděpodobnosti příslušnosti pixelu k určité třídě je vážena jeho pravděpodobností výskytu. Ta může být např. přímo úměrná předpokládanému plošnému zastoupení třídy v obraze.
- Jeho použití je efektivní v případě, že dochází k překrytům 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.

Hybridní klasifikátory

- Hybridní klasifikátory představují přechod mezi neřízenou a řízenou klasifikací.
- Jejich představitelem je např. klasifikátor MAXSET v systému Idrisi. Ten vyžaduje definování trénovacích množin, ale na výstupu se chová jako neřízený klasifikátor, protože přiřazuje pixely i do tříd, které nebyly trénovacími množinami definovány.
- Vystihuje tak i možnost existence tříd smíšených. Výsledkem je obraz, na kterém se nacházejí i předem nedefinované třídy objektů/shluky. Tak lze zjistit chybějící signatury a potřebu definovat nové trénovací množiny.


Objektová klasifikace (OBIA – Object-Based Image Analysis)

- Objektově orientované klasifikátory využívají kromě spektrální informace také **prostorové uspořádání prvků** v obraze – snaží se tedy určit strukturu a kontext.
- V Idrisi Taiga poskytují podobnou funkcionalitu moduly SEGMENTATION, SEGTRAIN a SECLASS.
- V současné době nejpokročilejší systém na trhu, programový balík eCognition Definiens pracuje s několikaúrovňovou sémantickou sítí objektů organizovanou ve znalostní databázi.






- **Objektová klasifikace**

- Při zpracování dat se nejprve pomocí segmentace obrazu vytvářejí tzv. **objektová primitiva (objekty, segmenty)**– malé souvislé skupiny pixelů, relativně homogenní ve své spektrální odrazivosti a s relativně vysokým kontrastem vůči pixelům které nepřísluší dané skupině.
- Segmenty jsou tvořeny souvislými skupinami pixelů, které jsou ve svých multispektrálních attributech relativně homogenní a vyznačují se i jinými vlastnostmi (**tvar, velikost, textura**, apod.).
- Uživatel může ovlivňovat stupeň homogenity, a tvar i velikost základních objektových primitiv. Každé primitivum má nejen určité spektrální vlastnosti, ale také velké množství atributů (tvar, velikost, topologické vztahy apod.).



- Objektová klasifikace



5. Úprava, hodnocení a prezentace výsledků klasifikace

- Hlavní metodou post-klasifikačních úprav bodových klasifikátorů jsou **nízkofrekvenční filtrace**.
 - Postklasifikační shlazení výsledků – modální filtrace (modus - nejčetnější hodnota)
 - Sieve filter – odstranění ploch určité velikosti (sieve - síto)
- Využívá se také možností vektorizace a generalizace tvarů (matematická morfologie).

Post-klasifikační úprava



Výsledek klasifikace

Modální filtr

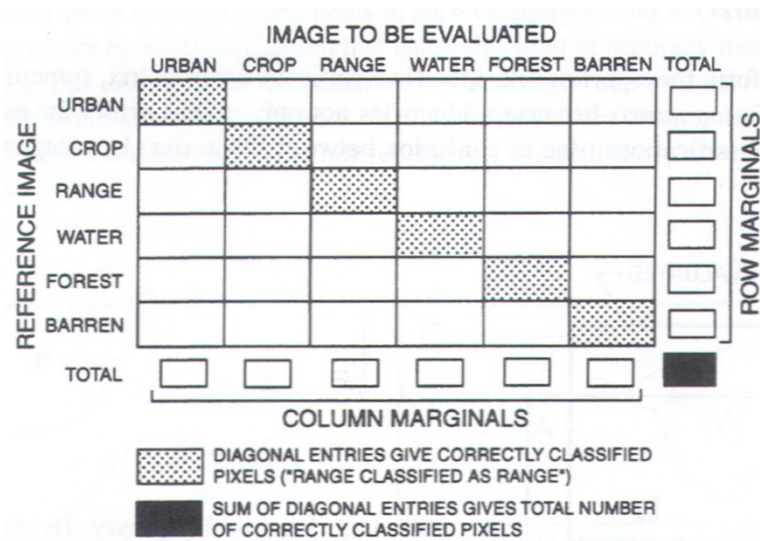


Sieve filtr



PŘESNOST KLASIFIKACE

- Přesnost klasifikace se standardně hodnotí prostřednictvím tzv. klasifikační **chybové matice** (error matrix, confusion matrix), která vyjadřuje vztah mezi výsledky klasifikace a referenčními daty, obvykle terénními.
- Matice je čtvercová; znázorňuje se polem o rozměrech $n \times n$, kde n vyjadřuje počet kategorií.
- Hodnoty v matici reprezentují počet pixelů nebo jejich procentickou část.
- Každý sloupec matice reprezentuje hodnoty získané klasifikací.
- Každý řádek matice reprezentuje hodnoty získané terénním průzkumem. (Některé systémy používají alternativní variantu přiřazení smyslu řádků a sloupců)



- Chybová matice poskytuje informaci o tom, jak odpovídají klasifikované hodnoty hodnotám skutečně zjištěným.
- Vizualizovaná chybová matice je nástrojem, který umožňuje posoudit, jak systém data zpracovává – např. jestli chybně neklasifikuje jednu třídu jako jinou.
- **Počty pixelů mimo hlavní diagonálu chybové matice představují chyby v klasifikaci.**
- Chybová matice se obvykle počítá z dat trénovacích množin. Ty se k tomuto účelu dělí na dvě skupiny. Jedna slouží k trénování klasifikátoru, druhá k verifikaci dat.
- Podle některých autorů (např. Bonn and Rochon 1992) lze pro obě tyto etapy použít stejné datové soubory. Výsledky budou zešikmené (biased), ale to neznamená, že nejsou použitelné.

Příklad chybové matice

Klasifikátor – výsledek klasifikace (ks)

Skutečnost – terénní verifikace (ks)

	Les	Voda	Pole	Celkem řádky
Les	5	3	0	8
Voda	2	3	1	6
Pole	0	2	11	13
Celkem sloupce	7	8	12	17

V chybové matici je **8** pixelů **lesa**; klasifikátor **3** z nich zařadil jako **vodu**.

V matici je **6** pixelů **vody**; klasifikátor zařadil **2** z nich jako **les** a **1** jako **pole**.

Z této chybové matice jasně vidíme, že:

- klasifikátor nedokáže dobře rozlišit **les** od **vody**,
- klasifikátor vcelku dobře rozlišuje mezi **polem** a ostatními plochami.

Charakteristiky přesnosti

- Chybová matice poskytuje informaci o tom, jak odpovídají klasifikované hodnoty hodnotám skutečně zjištěným.
- Hlavní diagonála (z levého horního do pravého spodního rohu) vyjadřuje množství pixelů klasifikovaných správně.
- Používají se obvykle tyto charakteristiky přesnosti:
 - omyl z opomenutí *OO*, (omyl z odloučení)
 - omyl z nesprávného přiřazení *OP*,
 - přesnost zpracovatele *PZ*,
 - přesnost uživatele *PU* a
 - celková přesnost klasifikace *PK*.
- Za předpokladu, že řádky představují referenční data a sloupce reprezentují data získaná klasifikací, lze vyjádřit tyto charakteristiky dále uvedenými matematickými vztahy.

Omyl z opomenutí (odloučení)

- Omyl z opomenutí OO (anglicky **omission error**) se vztahuje k pixelům, které byly klasifikovány chybně do jiných tříd mimo uvažovanou referenční třídu; v příslušném **řádku** je reprezentován políčky mimo hlavní diagonálu.
- Počítá se (v %) na základě vztahu
- $OO = (SŘ - KS) / KS$
- kde $SŘ$ (suma řádku) vyjadřuje počet všech pixelů v řádku, a KS počet pixelů klasifikovaných správně, tj. správně přiřazených do uvažované třídy.
- Rozdíl $SŘ - KS$ představuje úhrn nediagonálních hodnot v řádku, tj. součet nesprávně klasifikovaných pixelů.

		Klasifikátor			
		Les	Voda	Pole	Celkem řádky
Skutečnost	Les	5	3	0	8
	Voda	2	3	1	6
	Pole	0	2	11	13
	Celkem sloupce	7	8	12	27

V kontextu našeho příkladu to znamená, že z **8 skutečných** pixelů **lesa** byly klasifikátorem **3** zařazeny **chybně** do třídy **voda**

a ze **6** pixelů **vody** byly **2** klasifikovány jako **les** a **1** jako **pole**.

$$OO \text{ pole} = (13 - 11) / 11 = 0,18 = \mathbf{18\%}$$

Omyl z nesprávného zařazení

- Omyl z nesprávného přiřazení *OP* (anglicky commission error) se vztahuje k pixelům, které byly nesprávně přiřazeny do uvažované třídy, a ve skutečnosti patří do jiných tříd; v příslušném **sloupci** je reprezentován políčky mimo hlavní diagonálu.
- Počítá se (v %) na základě vztahu
- $OP = (SS - KS) / SS$,
- kde *SS* (suma sloupce) vyjadřuje počet všech pixelů ve sloupci, *KS* počet pixelů klasifikovaných správně, tj. těch, které do dané třídy skutečně patří.
- Rozdíl *SS*– *KS* představuje úhrn nediagonálních hodnot ve sloupci, tj. součet nesprávně klasifikovaných pixelů.

		Klasifikátor			
		Les	Voda	Pole	Celkem řádky
Skutečnost	Les	5	3	0	8
	Voda	2	3	1	6
	Pole	0	2	11	13
	Celkem sloupce	7	8	12	27

V kontextu našeho příkladu to znamená, že do třídy **les** klasifikátor **chybně** zařadil **2** pixely **vody**,

a do třídy **voda** byly **chybně** zařazeny **3** pixely **lesa** a **2** pixely **pole**.

$$OP \text{ pole} = (12 - 11) / 12 = 0,08 = 8 \%$$

Přesnost zpracovatele

- Přesnost zpracovatele *PZ* (anglicky **producer's accuracy**), vyjadřuje pravděpodobnost, že referenční třída je klasifikována správně.
- Je to poměr mezi počtem pixelů klasifikovaných správně (hodnota na hlavní diagonále) a počtem pixelů ve všech referenčních třídách uvažovaného řádku (suma řádku).
- Přesnost zpracovatele je založena na omylu z vynechání a má tvar
- $PZ = KS / SŘ$

		Klasifikátor			
		Les	Voda	Pole	Celkem řádky
Skutečnost	Les	5	3	0	8
	Voda	2	3	1	6
	Pole	0	2	11	13
	Celkem sloupce	7	8	12	27

V kontextu našeho příkladu to vyjadřuje **pravděpodobnost**, že objekty, které **ve skutečnosti** patří např. třídě **les**, byly klasifikátorem **do třídy les** také zařazeny.

$$PZ \text{ pole} = 11 / 13 = 0,85 = 85 \%$$

Přesnost uživatele

- Přesnost uživatele PU (anglicky user's accuracy) vyjadřuje pravděpodobnost, že pixel v klasifikaci skutečně reprezentuje tuto referenční (terénní) třídu.
- Je to poměr mezi počtem pixelů klasifikovaných správně (hodnota na hlavní diagonále) a počtem referenčních pixelů v uvažované třídě (suma sloupce).
- Přesnost uživatele je založena na omylu z přiřazení a má tvar
- $PU = KS / SS$

Klasifikátor

	Les	Voda	Pole	Celkem řádky
Les	5	3	0	8
Voda	2	3	1	6
Pole	0	2	11	13
Celkem sloupce	7	8	12	27

V kontextu našeho příkladu to vyjadřuje **pravděpodobnost**, že objekty, které **klasifikátor** zařadil do třídy **les**, **skutečně** do třídy **les** také patří.

$$PU_{\text{pole}} = 11 / 12 = 0,91 = 91 \%$$

Celková přesnost klasifikace

- Celková přesnost klasifikace PK (overall classification accuracy) se vyjadřuje jako podíl úhrnu všech pixelů klasifikovaných správně (SKS) a celkového úhrnu všech pixelů (CS).
- Vyjadřuje se vztahem
- $PK = SKS / CS$,
- kde SKS je suma pixelů klasifikovaných správně a CS celková suma pixelů.

Klasifikátor

	Les	Voda	Pole	Celkem řádky
Les	5	3	0	8
Voda	2	3	1	6
Pole	0	2	11	13
Celkem sloupce	7	8	12	27

$$PK = (5 + 3 + 11) / 27 = 0,70 = 70 \%$$

No. of Pixels	Classification Data							
	Reference Data	Water	Bare Ground	Deciduous Forest	Coniferous Forest	Urban	Row Total	Producer's Accuracy
Water	367	2	4	3	6	382	367/382	15/382
Bare Ground	2	418	8	9	17	454	418/454	36/454
Deciduous Forest	3	14	329	24	25	395	329/395	66/395
Coniferous Forest	12	5	26	294	23	360	294/360	66/360
Urban	16	26	29	43	422	536	422/536	114/536
Column Total	400	465	396	373	493	2127		
User's Accuracy	367/400	418/465	329/396	294/373	422/493			
Errors of Commission	33/400	47/465	67/396	74/373	71/493			

Příklad chybové matice vyjádřené počtem pixelů

Percentages	Classification Data							
Reference Data	Water	Bare Ground	Deciduous Forest	Coniferous Forest	Urban	Row Total	Producer's Accuracy	Errors of Omission
Water	17.3	0.1	0.2	0.1	0.3	18.0	96.1%	3.9%
Bare Ground	0.1	19.7	0.4	0.4	0.8	21.3	92.1%	7.9%
Deciduous Forest	0.1	0.7	15.5	1.1	1.2	18.6	83.3	16.7
Coniferous Forest	0.6	0.2	1.2	13.8	1.1	16.9	81.7%	18.3%
Urban	0.8	1.2	1.4	2.0	19.8	25.2	78.7%	21.3%
Column Total	18.8	21.9	18.6	17.5	23.2	100.0		
User's Accuracy	91.8%	89.9%	83.1%	78.8%	85.6%			
Errors of Commission	8.3%	10.1%	16.9%	21.2%	14.4%			

Příklad chybové matice vyjádřené v procentech

- Počty pixelů mimo hlavní diagonálu chybové matice představují chyby v klasifikaci. U chybových matic s údaji v pixelech úhrny pixelů v řádcích a ve sloupcích nemusí být stejné.
- Obvykle je to dáno tím, že některé pixely nelze zařadit do uvažovaných tříd a zůstávají neklasifikovány. Celkové úhrny referenčních a klasifikovaných pixelů si však musí odpovídat.
- Při hodnocení klasifikace by se neměla brát v úvahu jen celková přesnost klasifikace, ale také přesnost zpracovatele a přesnost uživatele. Tímto způsobem je možno předejít nevhodnému použití výsledků klasifikace.
- Pro objektivní posouzení přesnosti klasifikace se doporučuje použít pro zpracování chybové matice referenční údaje, které nejsou totožné s trénovacími množinami (tzv. testovací množiny).

Kappa koeficient (KIA – Kappa Index of Agreement)

- Jiným indexem, reprezentujícím kvantitativní vyjádření přesnosti klasifikace, je koeficient Kappa (Kappa Index of Agreement, KIA).
- Ten porovnává výsledek klasifikace s klasifikací vznikou čistě náhodným procesem zařazování pixelů do jednotlivých tříd. Výpočet je založen na předpokladu, že i při náhodném procesu zařazování pixelů obrazu do jednotlivých tříd bude určité procento pixelů zařazeno správně. Interval výsledných hodnot indexu má obvykle rozmezí 0..1, kdy 1 znamená perfektní shodu a 0 představuje čistě náhodný výsledek. Možné jsou i negativní hodnoty indexu, ke kterým dochází, když podíl shodných pixelů je nízký.

- Index Kappa má tvar
$$\kappa = \frac{O - E}{1 - E}$$
, kde

O je přesnost pozorovaná, tj. zjištěný podíl správných výsledků (hlavní diagonála matice)

E je přesnost dosažitelná náhodným zařazením pixelů do jednotlivých tříd.
(E se počítá podobně jako statistický test dobré shody – chí kvadrát.)

Pro chyby v klasifikaci obrazu platí:

- chybně klasifikované pixely se ve výsledném obrazu nevyskytují náhodně, ale mají určité **prostorové uspořádání**
- chybně klasifikované pixely jsou více méně asociovány pouze s **určitými třídami**
- chybně klasifikované pixely se většinou nevyskytují izolovaně, ale v určitých **skupinách**
- chybně klasifikované pixely jsou svým výskytem vázány na **typické části** klasifikovaných **ploch**

- V případě, že datový soubor trénovacích množin je nevyvážený, tj. když se počet vzorků (nebo pixelů) v jednotlivých třídách významně liší, zjištěná chybovost nevyjadřuje správně skutečný výkon klasifikátoru.
- Budeme-li např. mít 990 vzorků pro třídu **1** a pouze 10 vzorků pro třídu **2**, dosažený výsledek bude zešikmený směrem ke třídě 1. I kdyby klasifikátor zařadil všechny vzorky do třídy 1, výsledná přesnost bude 99%.
- *A to evidentně není dobrý indikátor posouzení skutečné práce klasifikátoru, protože ten rozpoznal třídu 1 ve 100% případů, ale třídu 2 v 0% případů.*

Existující limity klasifikace obrazových dat

- K interpretaci snímků klasifikovaných metodami neřízené i řízené klasifikace je třeba přistupovat s jistou opatrností.
Jedná se totiž o komplexní proces s řadou předpokladů.
- Neřízená klasifikace ve většině případů vyžaduje **terénní kontrolu** aby se zjistilo, jak dalece odpovídají zjištěné spektrální třídy požadovaným informačním třídám.
- U řízené klasifikace hrozí nebezpečí, že trénovací množiny nemají homogenní a jednoznačné spektrální charakteristiky.
Důsledkem může být nesprávná klasifikace.