



Klasifikace obrazu II – neřízená klasifikace, přesnost klasifikace



Neřízená klasifikace obrazu

Základní pojmy

- Nevyužívá trénovaných dat, nevyžaduje **a priori** informaci o vlastnostech hledaných tříd
- Pracuje obdobně jako řízená klasifikace většinou s jedním pixelem, někdy může být prováděna i pro segmenty obrazů
- Základním předpokladem, ze kterého vychází, je to, že pixely, které patří do jedné třídy, jsou ve vícerozměrném prostoru **přírozeně** blízko sebe (tvoří shluky=clustery) a naopak pixely odlišných skupin, které představují povrchy lišící se svým spektrálním chováním, jsou dobře separované.
- Výsledkem první fáze neřízené klasifikace jsou tzv. **třídy spektrální**. Až jejich interpretací a postupným spojováním vznikají **třídy informační**.



Principy

- V prvním kroku čistě matematický princip definování shluků
- Vhodná volba kritérií = zjištění jemných rozdílů mezi spektrálními třídami, nelze je rozpoznat v trénovacích plochách (poškození stromů, vlhkost, zastínění)
- Velké množství spektrálních tříd, které nelze všechny v řízené klasifikaci natrénovat, v neřízené nalezeny automaticky (některé nemají význam – meziproduct – nutná další úprava do informačních tříd)

Rozdíly

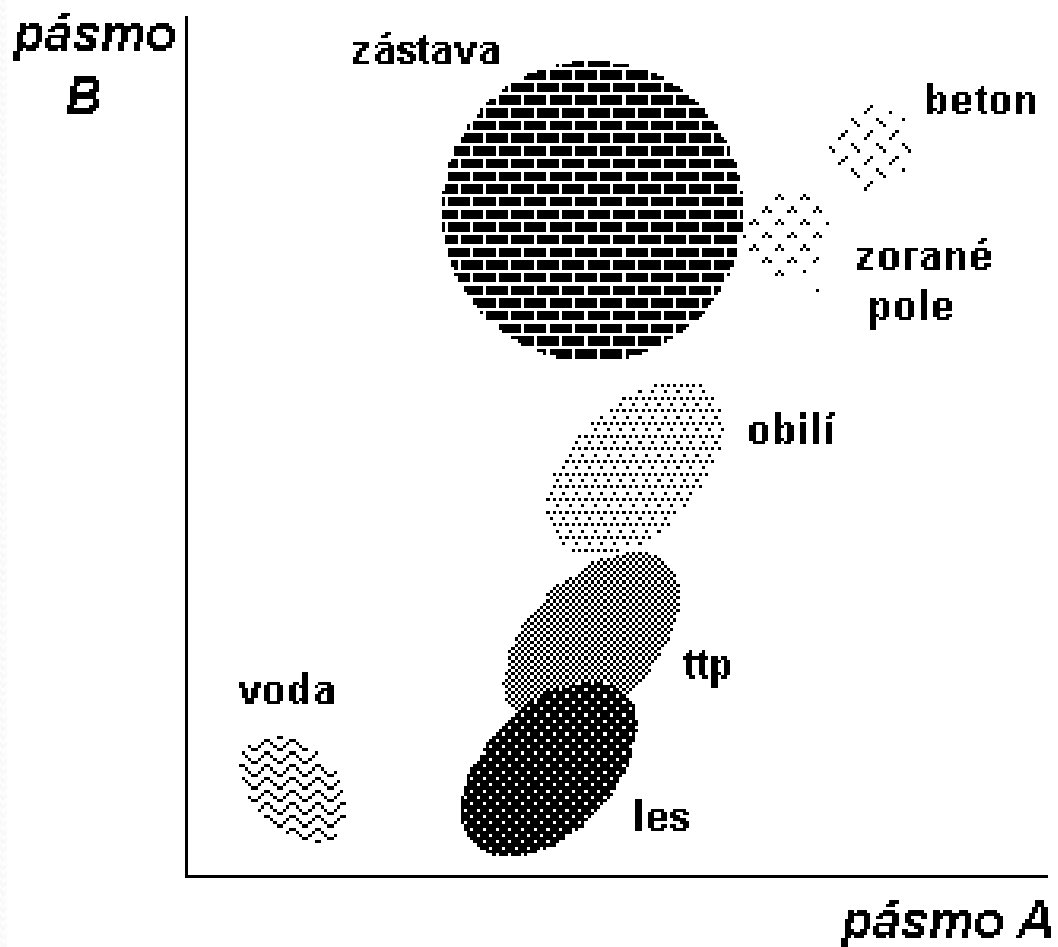
Řízená klasifikace

- používá se trénovací množina (plocha)
- na začátku informační třídy – poté zjišťují jejich spektrální odlišnost
- někdy obtížné zjistit optimální počet výchozích informačních tříd

Neřízená klasifikace

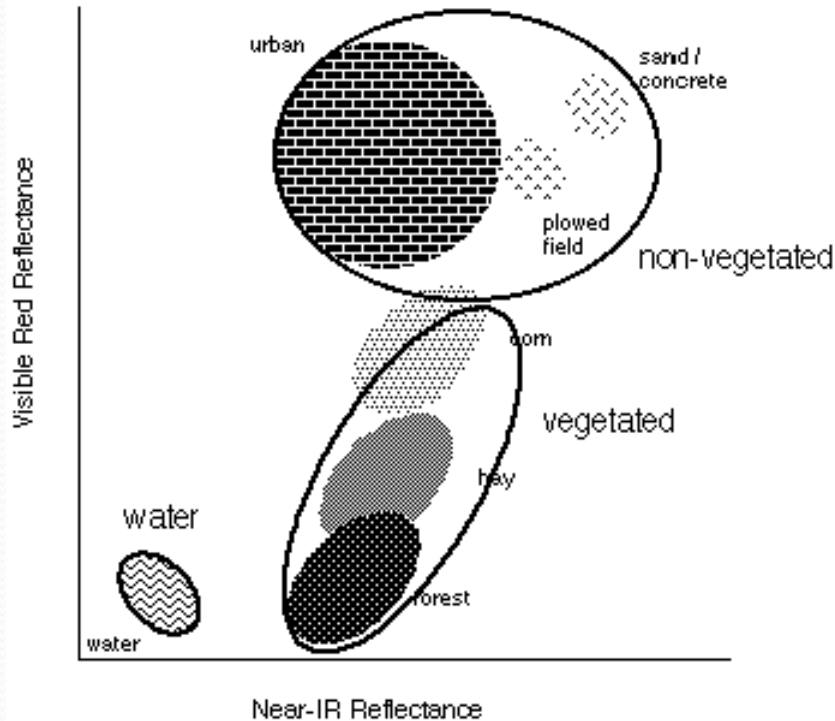
- není trénovací množina
- vytvářejí se spektrální třídy – poté určujeme informační hodnotu (nutná podpůrná data, terénní průzkum)
- vhodný nástroj – rozptylogram (scatter plot) – oddělí např. typy lesa

Příznakový prostor

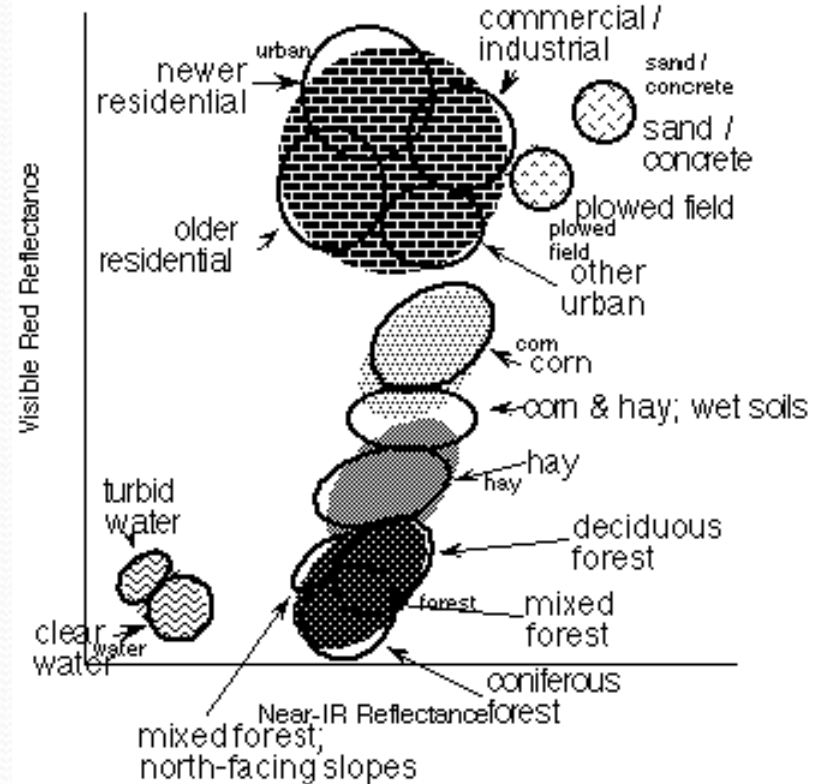


Vztah mezi počtem shluků, spektrálními a informačními třídami

Unsupervised Classification: 3 Clusters



Unsupervised Classification: 15 Clusters



Algoritmy neřízené klasifikace

- K vymezení odlišných skupin (shluků) v multispektrálním příznakovém prostoru lze využít vícerozměrné statistické metody.
- K nejpoužívanější skupině algoritmů patří postupy založené na **shlukové analýze**.
- Algoritmy založené na shlukování využívají iteračního počtu, existují i algoritmy označované jako „**jednoprůchodové**“
- Neřízené algoritmy klasifikace mají i některé postupy založené na využití **neuronových sítí**.

Metody shlukové analýzy

```
graph TD; A[Metody shlukové analýzy] --> B[hierarchické]; A --> C[nehierarchické]; B --> D[aglomerativní]; B --> E[rozkladové]; C --> F[optimalizační]; C --> G[...];
```

hierarchické

nehierarchické



aglomerativní

rozkladové

optimalizační

...

Aglomerativní hierarchické shlukování - jednotky se postupně spojují do shluků



Hierarchické metody rozkladové naopak postupně dělí vstupní soubor do 2, 3, 4, ... skupin.

Nehierarchické metody shlukové analýzy


- **Nehierarchické metody lze charakterizovat jako optimalizační.**
- **Hledají takový rozklad množiny objektů, který je optimální podle vhodně zvoleného kritéria optimality**
- **Mohou být založeny na předem daném (přibližném) počtu shluků a jejich postupném „zlepšování“ převodem vybraných jednotek mezi shluky, na eventuelním spojování či rozdělování shluků.**
- **Výpočty využívají iteračního počtu.**

Obecný postup shlukování

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

Definování počáteční polohy shluků

1. úvodní středy shluků jsou rozmístěny **pravidelně** po diagonále příznakového prostoru.

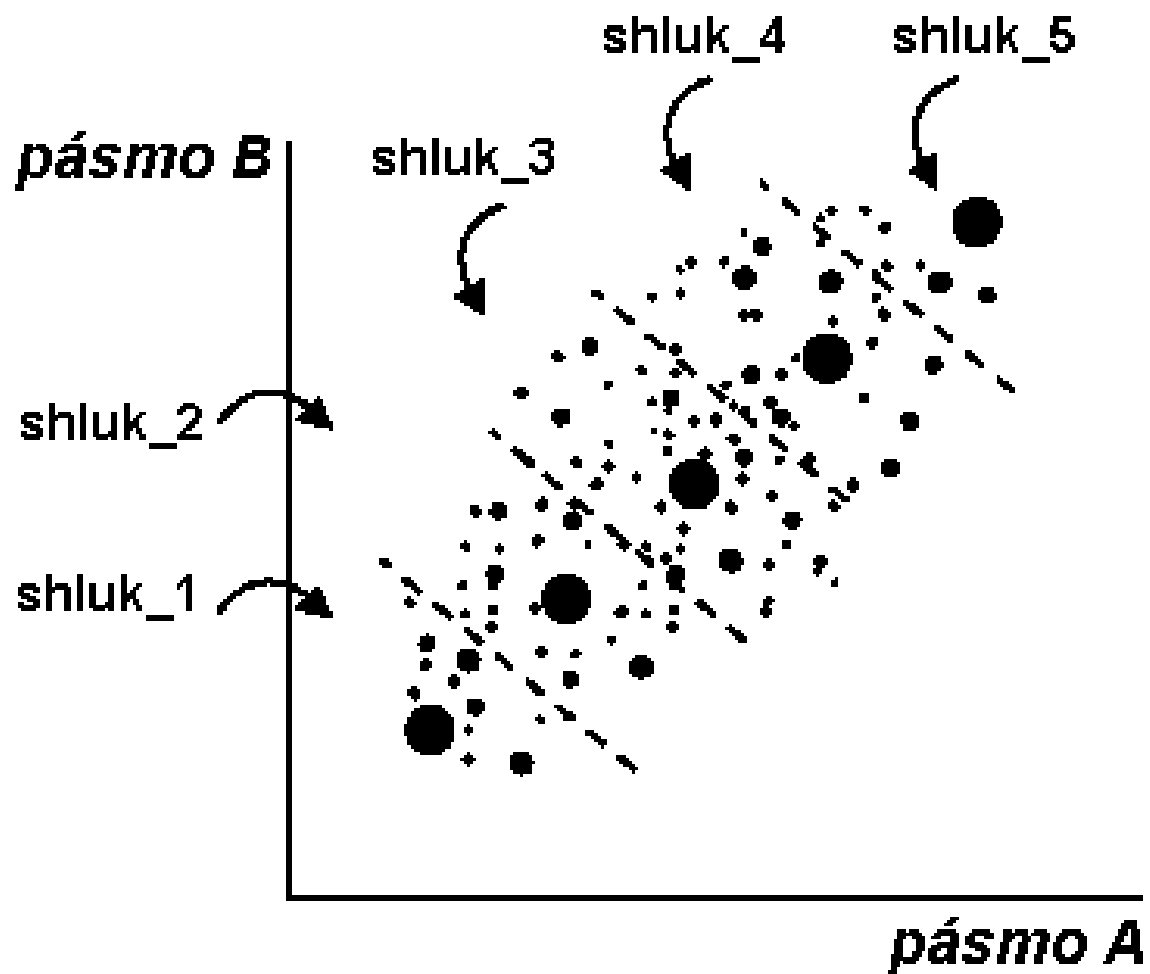


Definování počáteční polohy shluků

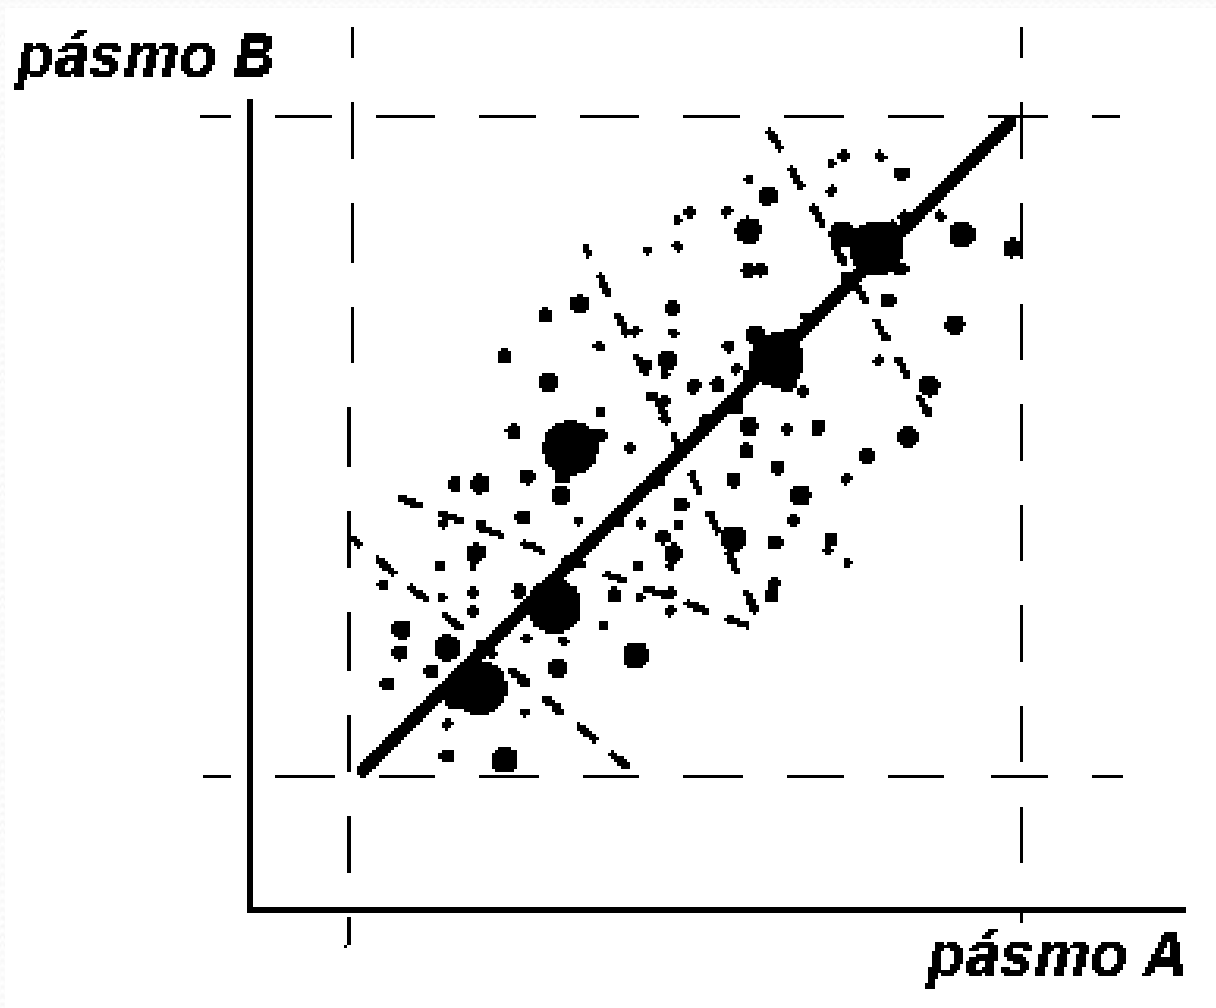
2. při určité znalosti spektrálního chování tříd lze úvodní polohu definovat pomocí tzv. **zakládacího souboru (seed file)** – řádky tvoří **průměrový vektor** pro jednotlivé shluky (v každém pásmu je uvedena úvodní DN hodnota, charakterizující polohu středu hluku)

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


Použití určitého klasifikátoru a přiřazení pixelů k jednotlivým shlukům



Výpočet nových centroidů a přerozdělení pixelů ve slucích



Iterační postup shlukování



- v algoritmech lze proces shlukování hodnotit dalšími kritérii např. minimální vzdáleností centroidů dvou shluků
- během iterace může dojít ke sloučení, rozdělení nebo zániku shluku
- stabilní shluk – poloha centroidu se mezi iteracemi už zásadně nezmění
- lze zadat konečný počet iterací

Algoritmy shlukové analýzy

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

Algoritmy předpokládají, že dopředu známe (alespoň přibližně) počet shluků, do kterého si přejeme rozdělit vstupní soubor.

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


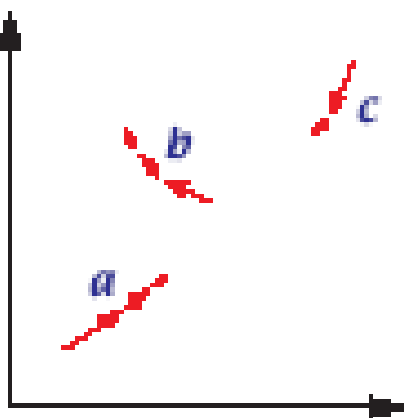
1. minimalizovaly variabilitu mezi jednotkami uvnitř jednoho shluku
2. maximalizovaly variabilitu mezi jednotlivými shluky

Jako rozhodovací pravidlo se většinou používá modifikovaná metoda nejbližšího souseda, kdy vzdálenost mezi středy shluků je hodnocena různými měrami vzdálenosti (nemusí jít vždy o euklidovskou vzdálenost)


Algoritmus K-means

1. Nejjednodušší shlukovací algoritmus.
2. Na počátku je zadán požadovaný počet shluků a pokud je k dispozici, také úvodní poloha jejich středů.
3. Úvodní polohu centroidů lze definovat jejich rovnoměrným rozmístěním ve vícerozměrném prostoru.
4. Každý klasifikovaný pixel je přiřazen do shluku, k jehož **průměrovému vektoru** má v analyzovaném prostoru nejblíže.
5. Jsou vypočteny nové polohy centroidů (nové průměrové vektory každého shluku).
6. Poté se celý výpočet opakuje dalšími iteracemi a to do té doby, než je dosaženo zadaného počtu iterací – méně vhodný výsledek.
7. Celý výpočet by měl být ukončen při splnění jednoho z „**kritérií konvergence**“, v okamžiku, kdy:
 - A. již nedochází k významnému počtu změn v zařazení jednotlivých klasifikovaných pixelů.
 - B. průměrový vektor významně nemění polohu v prostoru

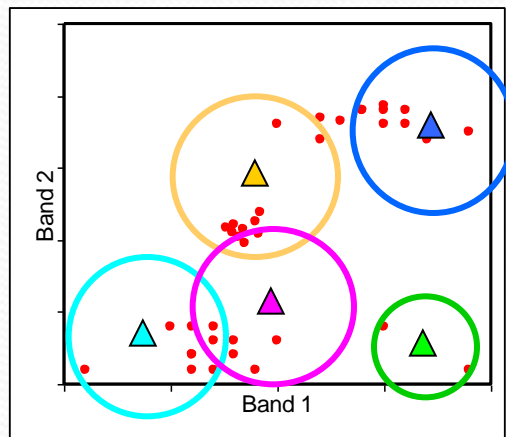
Postupná změna polohy průměrového vektoru v příznakovém prostoru




Příklad K-mean



1. První iterace.
Centra shluků jsou vybrány náhodně. Pixly jsou přiřazeny nejbližšímu centru.



2. Druhá iterace.
Centra se posouvají do centroidů tvořených všemi pixly ve shluku.




3. N-tá iterace –
centra jsou stabilizována.

Algoritmus ISODATA

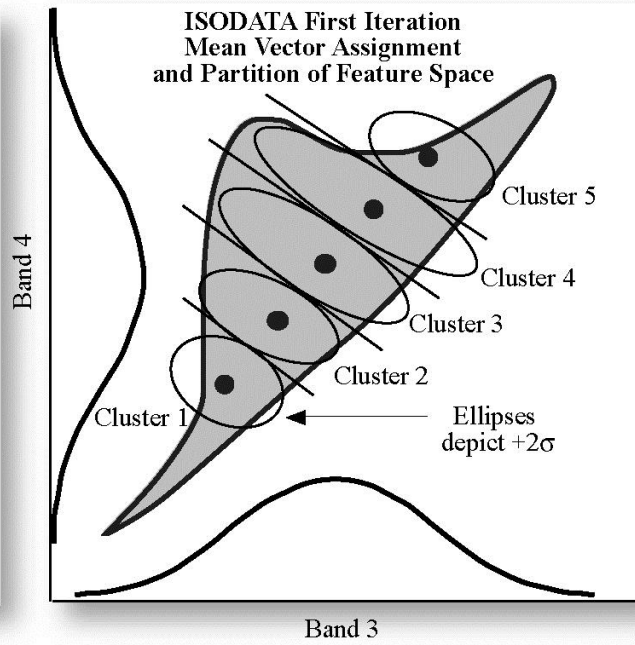
1. Na počátku je definován počet požadovaných shluků a počet iterací.
2. Není-li k dispozici základací soubor středů shluků, tyto jsou umístěny rovnoměrně v analyzovaném prostoru.
3. Vlastní zařazování pixelů do jednotlivých shluků probíhá také v jednotlivých iteracích, přičemž se řídí následujícími parametry:
 - Shluk, který se stane heterogenním - měřeno hodnotou násobku směrodatné odchylky, zadanou na počátku výpočtu - je **rozdělen** na dva nové shluky.
 - Shluky, které jsou svými středy v analyzovaném vícerozměrném prostoru blíže, než je předem zadaná hodnota, jsou **spojeny** v jeden shluk.
 - Shluky, které obsahují méně pixelů, než je předem zadaná hodnota, jsou **zrušeny** a jejich pixely zařazeny ke shlukům okolním

Algoritmus ISODATA


- V důsledku uvedeného spojování a rozdělování jednotlivých shluků v každé iteraci není výsledný počet stabilních shluků často shodný s počtem požadovaným.
- Tento požadovaný konečný počet shluků je často zadáván určitým rozsahem minimálního a maximálního počtu.
- Parametry, řídící spojování a rozdělování shluků, lze v průběhu výpočtu (mezi jednotlivými iteracemi) interaktivně měnit.




a.



b.

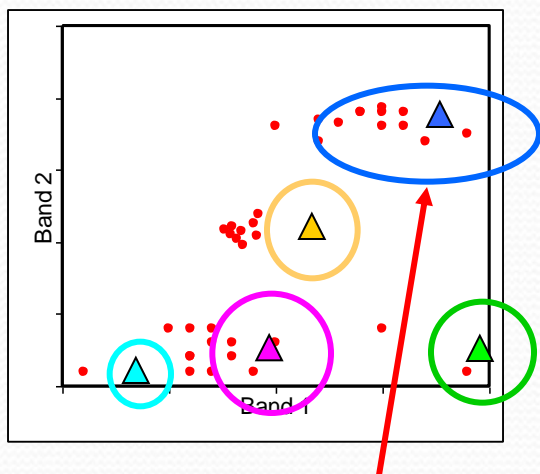


c.




d.


Příklad ISODATA



1. Data jsou rozdělena do jednotlivých shluků, modrý centroid je poměrně roztažen v pásmu 1 a proto je rozdělen.




2. Světle modrý a zelený shluk obsahují pouze 2 a méně pixely, proto jsou odstraněny



3. Následně jsou přiřazeny nejblíže shlukům nebo jsou označeny jako neklasifikované.


Jednoprůchodové algoritmy (Single pass)

- Metody pracují s **histogramy** klasifikovaných pásem obrazu.



- V případě klasifikace dvou pásem vytváří „dvourozměrný“ histogram povrch s množstvím lokálních maxim („vrcholy“) a minim („údolí“).
- Jednotlivé vrcholy na tomto povrchu představují přibližně středy jednotlivých shluků, údolnice pak představují místa, kudy vede hranice mezi jednotlivými shluky.
- Postup neumožňuje zadat požadovaný počet výsledných shluků a výpočet na rozdíl od předcházejících způsobů není iterační.

AMOEBEBA



Algoritmus pracuje také s parametrem vzájemné polohy pixelů.

Je definován způsob posuzování sousedství (4 či 8 pixelů).

Posuzovaný pixel tvoří se svými sousedními pixely jeden shluk:

- pokud nabývá podobné DN hodnoty
- pokud je osamocen v homogenní ploše pixelů

AMOEBA

Maximální možná proměnlivost pixelů v daném shluku je definována hodnotami rozptylu či směrodatné odchylky.

Pixely určité třídy postupně vytvářejí víceméně souvislé části obrazu.

Pokud pixely tvořící jednu třídu (shluk) obklopují dosud nezařazený obrazový prvek a jeho zařazením do dané třídy by nedošlo k překročení jeho předem definovaného rozptylu hodnot, je tento obrazový prvek zařazen do daného shluku.

Tento postup tedy funguje jako speciální filtrace obrazu.

Dává dobré výsledky u snímků s rozsáhlými homogenními plochami a malou variabilitou DN hodnot

Hybridní klasifikace I.

- Využívá výhod obou postupů klasifikace
- Neřízená klasifikace slouží k nalezení homogenních ploch.
- Tyto spektrálně homogenní plochy mohou sloužit přímo jako plochy trénovací
- Mohou však také pouze vymezovat místa ve zpracovávaném obraze, na kterých je následně provedeno trénování pro řízenou klasifikaci.
- Výsledné třídy mají povahu tříd spektrálních a jsou agregovány do výsledných kategorií druhů povrchů

Hybridní klasifikace II.

- Využívá „unsupervised training areas“
- Jsou zvoleny části obrazu, které se na rozdíl od „supervised“ trénovacích ploch vyznačují co největší heterogenitou.
- Cílem je postihnout co nejvíce spektrálních tříd. Ty jsou dále podrobeny shlukování a statistické analýze.
- Podobné shluky jsou spojeny a je jim přiřazen geografický význam
- Následně je klasifikována celá scéna metodou řízené klasifikace
- Hybridní klasifikátory jsou důležité tam, kde je velká variabilita u spektrální odezvy pro jednotlivé typy pokryvů – např. mapování vegetace v horských oblastech (dána různými podmínkami místa – půda, sklon, poloha, oslunění)

Úprava výsledků neřízené klasifikace

Proces „vyladování“ do konečných informačních tříd, důležitá podpůrná data.

Shlukováním vytvořené spektrální třídy jsou **agregovány** do informačních tříd, které odpovídají klasifikačnímu systému výsledné tématické mapy.

Ideální stav: jedná spektrální třída = jedna informační třída

Akceptovatelný stav: více spektrálních tříd = jedna informační třída

Neakceptovatelný stav: pokud jedna spektrální třída obsahuje pixely více než jedné třídy informační je nutné proces shlukování opakovat:

- s větším počtem shluků
- s modifikovanými parametry spojování či rozdělování shluků (ISODATA)
- s jinými vstupními pásmy – například s pásmy transformovanými metodou PCA

Úprava výsledků neřízené klasifikace

Spojování spektrálních tříd do tříd informačních

The image displays the PCI EO Scape V6.0.1 software interface, showing the process of merging spectral classes into information classes. The main window displays a classified map with a complex, multi-colored pattern. A large black arrow points from the 'Colour Selection' panel to the main map window, indicating the application of the selected color scheme to the classification results.

The 'PCT Editing' panel shows the 'Predefined Pseudo-Colour Tables' section, which includes a table of class values and their corresponding colors. The 'Current Pseudo-Colour Table' section shows a list of class values and their corresponding colors. The 'Colour Selection' panel shows a color bar and sliders for Red, Green, and Blue, with a 'Hold Colour' button and a 'Grey Level' slider.

The 'BRNOTMR.PIX' panel shows the 'Cursor' and 'Display' settings, including '257P' and '257L' coordinates, '4:2' resolution, and 'PC' imagery type. The 'Graphics' section includes 'All Off' and 'All On' buttons, and a row of numbered buttons (1-6) for selecting different classes. The 'Vectors' section includes 'All Off' and 'All On' buttons. The 'Enhancements' section includes a 'None' button. The 'Infreq' section includes 'Linear', 'Equal', and 'Root' buttons. The 'Zoom' section includes a 'off' button and zoom in/out arrows.

Class	0	1	2	3
0	0	0	0	0
1	0	230	0	
2	0	0	230	
3	230	230	0	
4	255	193	37	
5	255	210	105	
6	72	110	255	
7	224	255	255	
8	155	40	06	
9	255	140	105	
10	255	161	197	
11	255	64	64	
12	255	165	15	
13	255	222	173	
14	255	110	100	
15	107	255	255	
16	255	239	219	
17	255	160	122	
18	255	250	250	
19	127	255	0	
20	255	193	193	

Úprava výsledků neřízené klasifikace

Spojování (agregování) spektrálních tříd

File: C:\Geomatica\GEO...\golden_horseshoe.pix Input channel: 7 Output channel: 8

View Controls:

- Normal mode
- Unassigned classes
- Input classes
- Aggregate classes
- Current classes
- Current aggregate classes

Highlight color:

Input Classes

Value	Name	Color	Description
28	Class-28	Red	Set to fallow agricultural field/bare soil (
29	Class-29	Yellow	Set to urban (34)
30	Class-30	Blue	Set to urban (34)

Aggregate Classes

Value	Name	Color	Description
31	planted agricultu	Green	7, 8, 9
32	fallow agricultura	Brown	10, 11, 13, 15, 17, 22, 24, 26, 28
33	forest	Dark Green	1, 5, 6
34	urban	Grey	3, 4, 12, 14, 16, 18, 19, 20, 21, 23, 25,

Buttons: Add >>, Remove, Select Class at Cursor, Highlight Classes, PCT ...

Buttons: New, Delete, Class Initialization..., Save ...

Buttons: Apply to Output Channel, Setup ..., Close

Hodnocení výsledků klasifikace

Klasifikace není ukončena, dokud není zhodnocena její přesnost.

Pro chyby v klasifikaci obrazu platí následující:

- 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**

Klasifikační chybová matice

třída	kód	počet pixelů	0	1	2	3	4	5
voda	1	1223	11,45	88,55	0,00	0,00	0,00	0,00
les	2	1089	10,56	0,00	89,44	0,00	0,00	0,00
pole	3	893	7,28	0,00	0,00	92,72	0,00	0,00
ttp	4	666	13,21	0,00	0,00	0,00	86,79	0,00
holá p.	5	1060	9,15	0,00	0,00	0,00	0,00	90,85

Průměrná přesnost = 89,67 %

- Počty mimo hlavní diagonálu představují chyby v klasifikaci.
- Průměrná přesnost = suma na hlavní diagonále / počet posuzovaných pixelů

Hodnocení výsledků klasifikace s využitím testovacích dat

- **chyby z opomenutí** (vynechání) -ve sloupcích mimo hlavní diagonálu (error of omission)
- **chyby z nesprávného zařazení** - v řádcích matice mimo hlavní diagonálu (error of commission)
- **přesnost z hlediska uživatele** – představuje pro každou třídu počet správně klasifikovaných pixelů (hodnota na hlavní diagonále) dělený celkovým počtem pixelů, které do této kategorie byly zařazeny (suma v řádce – user accuracy).
- **přesnost z hlediska zpracovatele** - poměr mezi počtem správně klasifikovaných pixelů (tedy opět hodnota na hlavní diagonále) a počtem pixelů použitých pro testování dané třídy (suma ve sloupci – producer accuracy).

Hodnocení výsledků klasifikace s využitím testovacích dat

		Referenční data						
	třída	Voda	Les	Pole	TTP	Půda	SUMA	PU [%]
klasifikovaná data	Voda	480	0	5	0	0	485	99
	Les	0	52	0	20	0	72	72
	Pole	0	0	313	40	0	353	89
	TTP	0	16	0	126	0	142	89
	Půda	0	0	0	38	342	380	90
	SUMA	480	68	318	224	342	1432	
	CHO [%]	0	23	1	44	0		
	CHZ [%]	1	29	13	7	11		
	PZ [%]	100	76	98	56	100		

Průměrná přesnost: $(480 + 52 + 313 + 126 + 342) / 1432 = 92 \%$

řádek SUMA udává očekávanou přesnost (celkový správný počet pixelů)

sloupec SUMA udává, kolik bylo do jednotlivé třídy zařazeno pixelů

CHO - chyba z opomenutí (sloupce mimo diagonálu, les: $16/68 = 23\%$)

CHZ - chyba z nesprávného zařazení (řádky mimo diag., les: $20/68 = 29\%$)

PU - přesnost z hlediska uživatele (udává pravděpodobnost, s jakou pixel zařazený do této třídy, danou třídu skutečně představuje)

PZ - přesnost z hlediska zpracovatele (poměr mezi počtem správně klasifikovaných pixelů a počtem pixelů použitých pro testování)

Hodnocení výsledků klasifikace - Kappa koeficient:

- Porovnává klasifikaci provedenou podle určitého rozhodovacího pravidla s klasifikací vzniklou čistě náhodným procesem zařazování pixelů do jednotlivých tříd.
- Jeho výpočet je založen na předpokladu, že i při čistě náhodném procesu zařazování pixelů zpracovávaného obrazu do jednotlivých tříd bude určité procento těchto pixelů zařazeno správně.
- Potom hodnotu koeficientu Kappa lze zjednodušeně vyjádřit následujícím způsobem:

$$K = \frac{PP - PO}{1 - PO}$$

kde **PP** - přesnost pozorovaná (určená z chybové matice)

PO - přesnost dosažitelná čistě náhodným zařazením pixelů do jednotlivých tříd

Hodnota koeficientu 0,9 tedy například znamená, že při dané klasifikaci jsme se vyhnuli 90 % chyb, které by vznikly při čistě náhodném zařazování pixelů do jednotlivých tříd.



Úprava výsledků klasifikace

Hlavní metodou post-klasifikačních úprav bodových klasifikátorů jsou **nízkofrekvenční filtrace**.

- Postklasifikační shlazení výsledků – modální filtrace
- Sieve filter – odstranění ploch určité velikosti

Vektorizace a generalizace tvarů

Modální filtrace



„SIEVE“ filtr (sító)

