

# SPAMIA: filtrovanie spamu pomocou kvantitatívnych profilov a adaptívneho klastrovania

Marián Grendár, Jana Škutová, Vladimír Špitalský

Slovanet a.s., Záhradnícka 151, 821 08 Bratislava

Bez(a)Dis, PF UPJŠ, 9. 5. 2012

Dosiahnuté výsledky vznikli v rámci riešenia projektu Výskum efektivity algoritmov pre inteligentné rozpoznanie nevyžiadanej elektronickej komunikácie, návrh teoretických modelov nových algoritmov a posúdenie ich účinnosti, ktorý je podporovaný Ministerstvom školstva, vedy, výskumu a športu SR v rámci poskytnutých stimulov pre výskum a vývoj zo štátneho rozpočtu v zmysle zákona č. 185/2009 Z.z. o stimuloch pre výskum a vývoj.

# Obsah

## SPAMIA

Existujúce riešenia na filtrovanie spamu

Návrh nového algoritmu

Predbežné merania efektívnosti

## Algoritmy

Klastrovacie algoritmy

Klasifikačné algoritmy

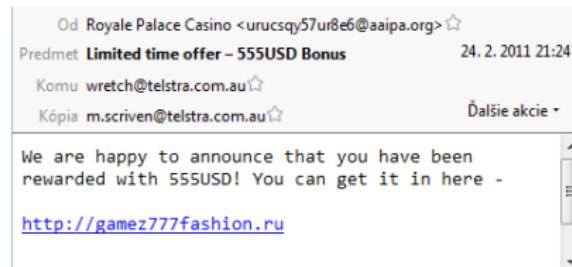
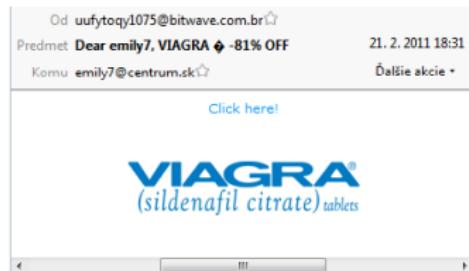
# Problematika spamu

## Spam

- ▶ je nevyžiadaná emailová správa často rozposielaná hromadne

## Účel

- ▶ reklama, phishing, scam, vírusy, verifikácia emailu, . . .



# Existujúce riešenia na filtrovanie spamu

## Open-source produkty

SpamAssassin



Bogofilter



DSPAM



...

## Komerčné produkty

### Metódy

- ▶ blacklisty, whitelisty, greylisty, SPF, ...
- ▶ heuristické pravidlá
- ▶ textmining

# Efektívnosť existujúcich riešení

Udávaná úspešnosť > 99%

- ▶ Virus Bulletin, TREC, CEAS

G. Hulten, J. Goodman (Microsoft Research, 2004):

Junk e-mail filtering

“Why you won’t get 99% in real life”

- ▶ testovacie korpusy sú nerealisticky jednoduché, ...

Výsledky Bogofiltru

- ▶ verejný korpus — viac ako 99.5% (1 chyba z 200)
- ▶ privátny korpus — cca. 95% (1 chyba z 20)

### Nevýhody existujúcich riešení

- ▶ vysoká vulnerabilita

Odkaz Jarred Smiley <funninessibn7@rocknlearn.com>  
Predmet Re [2]: 21.2.2011 10:45  
Odpověd na LinkedIn <support-845184313809513782521417509504922933068201742348905  
Kому cafinforcecek@inforce.sk Údaje akcie +

V C L  
I I E  
G A V  
R L I  
A I T  
S R  
A

\$1.29/pill    \$1.58/pill    \$2.81/pill

+ many other positions!

Visit Us at:  
<http://drugszone.com> [delete spaces before visiting]

# Nevýhody existujúcich riešení

- ▶ fixovanosť heuristických pravidiel



- ▶ závislosť na jazyku
- ▶ viazanosť na binárnu klasifikáciu
- ▶ rigidnosť výsledného hodnotenia spamovosti

# Návrh nového algoritmu

## SPAMIA

Existujúce riešenia na filtrovanie spamu

**Návrh nového algoritmu**

Predbežné merania efektívnosti

## Algoritmy

Klastrovacie algoritmy

Klasifikačné algoritmy

# Východiská návrhu nového algoritmu

## Kvantitatívne profily

- ▶ vektor reálnych/celých čísel pevnej dimenzie
- ▶ zachytenie doposiaľ nevyužívaných charakteristík emailov

## Adaptívne klastrovanie

- ▶ hierarchické rozčlenenie emailov na homogénne skupiny a zvyšok
- ▶ rozpoznanie emailových kampaní

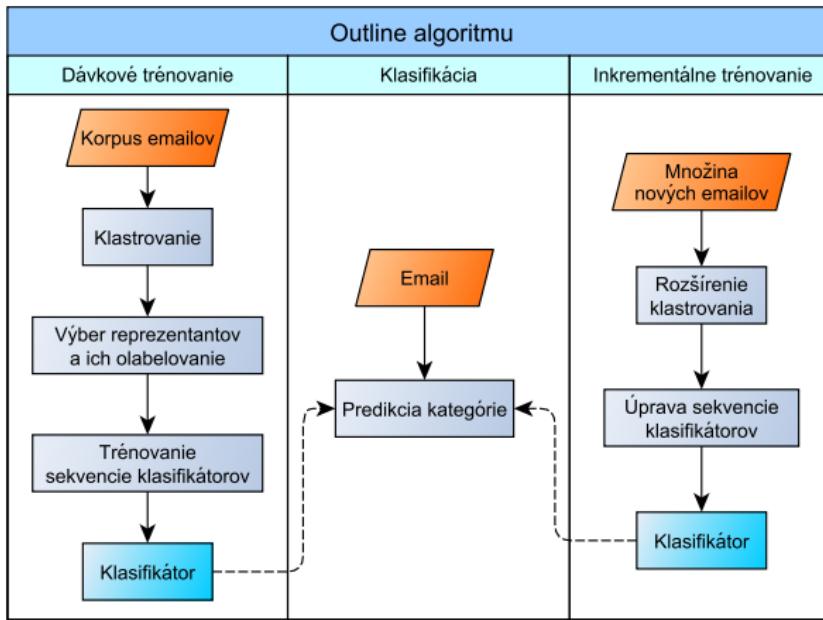
## Sekvenčné klasifikovanie

- ▶ viacstupňová predikcia

## Inkrementálne trénovanie

- ▶ rýchla a efektívna aktualizácia klastrovania a klasifikátorov

# Outline algoritmu



# Základné kvantitatívne profily

**Binárny** profil: vzdialenosť medzi výskytmi daného znaku/znakov

- ▶ **LP** riadkový: dĺžky riadkov
- ▶ **SNP** vettový: dĺžky viet
- ▶ **WP** slovný: dĺžky slov
- ▶ **UP** upper-case: vzdialenosť medzi veľkými písmenami
- ▶ **STAP**: vzdialenosť medzi výskytmi \*, ~, >
- ▶ ...

**Histogramový binárny** profil:

- ▶ **HWP**: histogram dĺžok slov
- ▶ **HUP**: histogram vzdialenosťí medzi veľkými písmenami
- ▶ ...

# Základné kvantitatívne profily

**Znakový profil:** početnosti znakov

- ▶ **CP:** ASCII profil

**Zoskupený znakový profil:** početnosti skupín znakov

- ▶ **CPG9:** čísla, medzery, zátvorky, operátory, separátory, veľké/malé písmená, nedovolené znaky, ostatné
- ▶ **CPG11:** z ostatných — samostatne ! a \$

*d*-gramový zoskupený znakový profil:

- ▶ **2CPG9:** dvojice skupín znakov
- ▶ **3CPG9:** trojice skupín znakov
- ▶ ...

# Základné kvantitatívne profily

Moving window profil: CPG za jednotlivé “časti” emailu

- ▶ MWP-CPG9
- ▶ MWP-CPG11

Veľkostný profil:

- ▶ veľkosť emailu
- ▶ veľkosti vybraných hlavičiek
- ▶ veľkosti častí mailu podľa content-type
- ▶ (voliteľne) CPG hlavičiek / častí
- ▶ SP
- ▶ SP-CPG9
- ▶ SP-CPG11

# Základné kvantitatívne profily

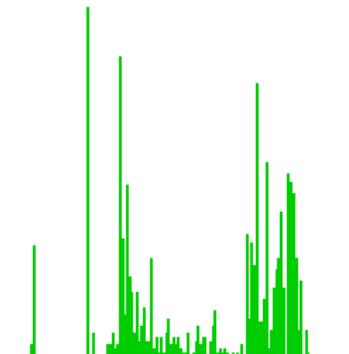
```
From vba_lowlevelparameters.on.uk Tue Apr 17 04:44:26 2007
Return-Path: vba_lowlevelparameters.on.uk
Received: from esmtp200.technet.microsoft.com ([192.1.103.45])
by spmdy.onexchange.ms (8.12.8/R.12.5) with SMTP id 13561021326448
for chevarevaldopedy.onexchange.ms; Tue, 17 Apr 2007 04:44:24 -0400
Received: from mail.purple.surefire by esmtp200 with Microsoft's SMTPSVC(8.0.0.0)
Tue, 17 Apr 2007 04:44:24 -0400
From: "The Insider" <vba_lowlevelparameters.on.uk>
To: "chevarevaldopedy.onexchange.ms"
Subject: "The Insider" - New Bulletin
Date: Tue, 17 Apr 2007 11:04:12 +0100
X-SmtpCL: Draftmail by Microsoft ESMTP 10.0.2.3780.3838
Message-ID: <00000000000000000000000000000000@esmtp200.technet.microsoft.com>
X-SignatureVerification: 17 Apr 2007 10:44:10.034714 (000)
From: 0
Content-Length: 334
Lines: 10
*** READING HERE ***
Dearborn, former members, students and staff at American university
http://www.theinsider.org/news/article.asp?id=2476

-----
Do not respond from this mailing list please use the form provided:
http://www.theinsider.org/news/contact.usamain.htm
```

(a) Email



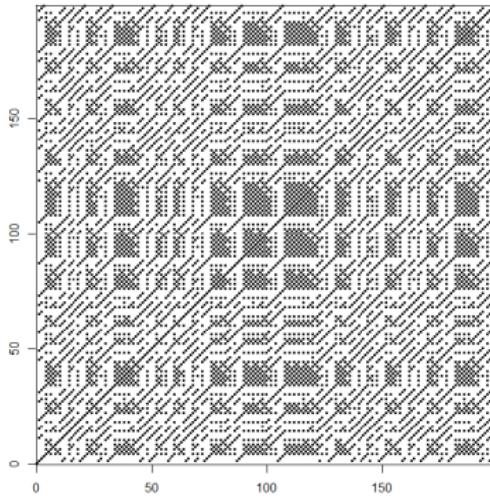
(b) Riadkový profil



(c) Znakový profil

# Rekurenčné kvantitatívne profily

- ▶ založené na symbolicko-dynamickom prístupe k emailu
- ▶ charakteristiky získané z rekurenčnej kvantifikačnej analýzy



# Adaptívne klastrovanie

## Motivácia

- ▶ nutnosť tvorby a aktualizácie trénovacieho korpusu emailov
- ▶ permanentná potreba nových olabelovaných emailov

## Adaptívne klastrovanie

- ▶ hierarchické rozčlenenie emailov na homogénne skupiny a zvyšok

## Výhody

- ▶ redukcia korpusu emailov s minimálnou stratou informácie
- ▶ detekovanie hromadných kampaní (spamových, reklamných a iných)
- ▶ zohľadnenie informácie aj z nelabelovaných emailov
- ▶ efektívne využitie späťnej väzby o labeli emailu

# Sekvenčné klasifikovanie

## Účel

- ▶ zníženie časovej náročnosti klasifikovania nového emailu

## Prostriedok

- ▶ najskôr jednoducho získateľné a nízko-dimenzionálne profile
- ▶ zložitejšie profile iba v prípade nejednoznačnej klasifikácie



# Inkrementálne trénovanie

## Účel

- ▶ aktualizácia klastrovania/klasifikátorov
- ▶ s nízkymi výpočtovými nárokmi

# Predbežné meranie efektívnosti

## SPAMIA

Existujúce riešenia na filtrovanie spamu

Návrh nového algoritmu

**Predbežné merania efektívnosti**

## Algoritmy

Klastrovacie algoritmy

Klasifikačné algoritmy

# Efektívnosť profilov

Privátny multilingválny korpus:

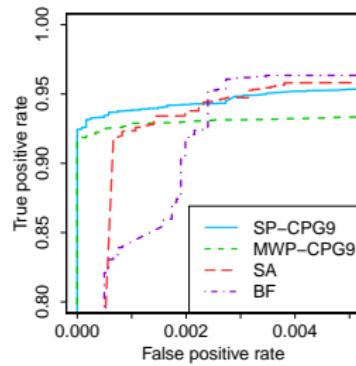
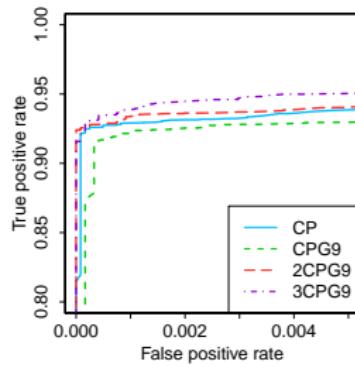
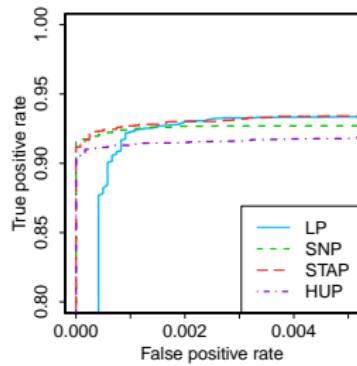
- ▶ train: Sep 2010 (11 050, 12% spam)
- ▶ test: Feb 2011 (17 248, 30% spam)

Chyba  $fnr$  (%) pri fixnom  $fpr = 0.1\%$

filter	$fnr$	filter	$fnr$
LP	7.7	CP	7.1
SNP	7.5	CPG9	7.8
STAP	7.3	2CPG9	6.6
HUP	8.7	3CPG9	6.1
SP-CPG9	6.2	MWP-CPG9	7.1
<i>SpamAssassin</i>	7.6	<i>Bogofilter</i>	15.6

# Efektívnosť profilov

## ROC krivky



# Efektívnosť klastrovania

## Korpus

- ▶ privátny (172 650, 30% spam)

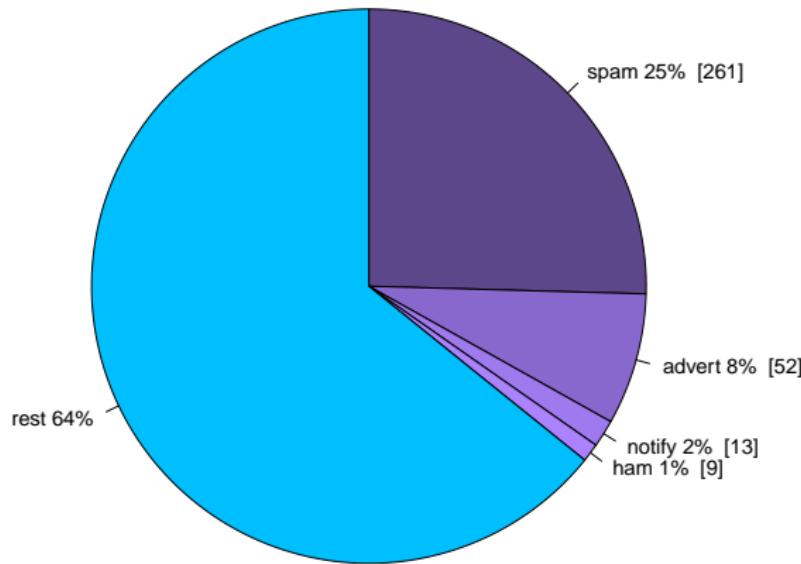
## Adaptívne klastrovanie

- ▶ úroveň 1: entropia dĺžok riadkov (dim = 1)
- ▶ úroveň 2: riadkový profil (dim = 20)

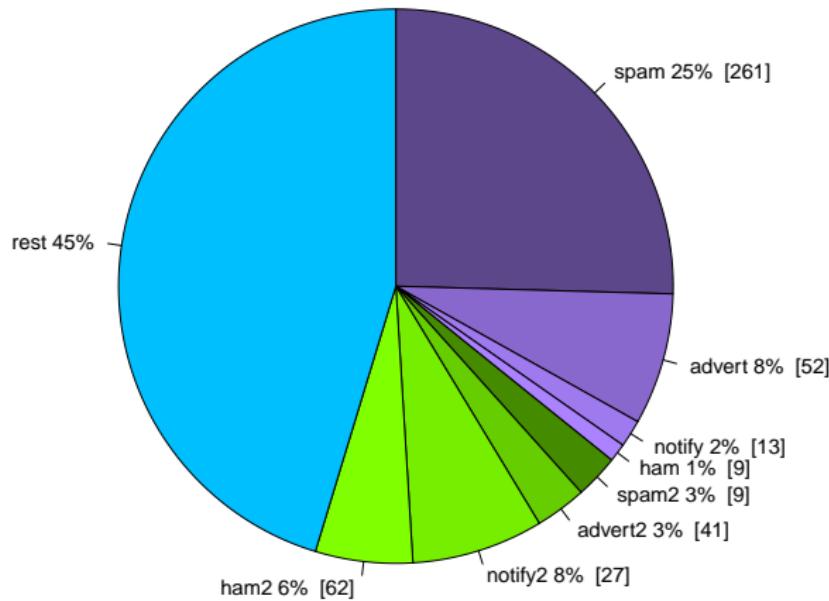
Chyba  $fpr$ ,  $fnr$  (%) pri zaradení zvyšku do hamu

	Chyba		Klastre			
	fpr	fnr	spam	advert	notify	ham
úroveň 1	0.12	14.2	261	52	13	9
úroveň 2	0.26	5.7	270	93	40	71

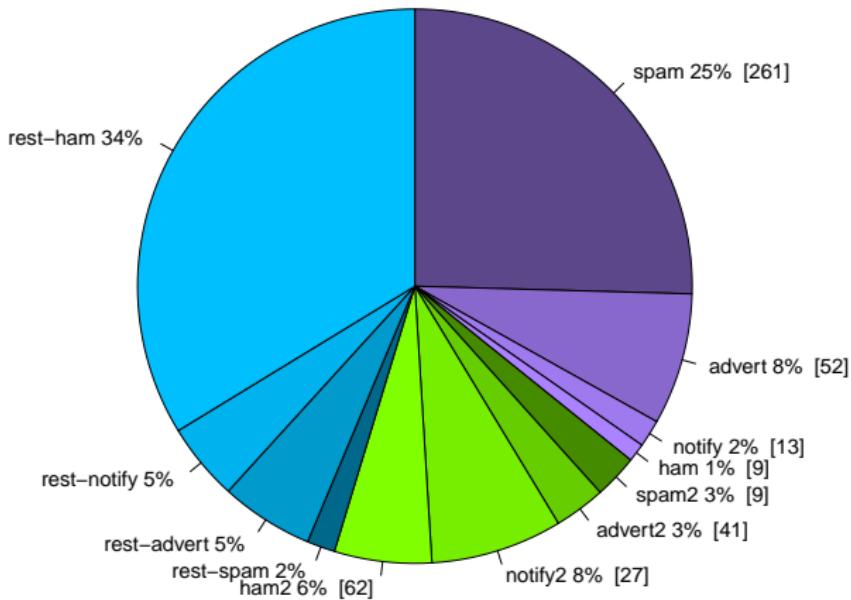
## Efektívnosť klastrovania — úroveň 1



## Efektívnosť klastrovania — úroveň 2



## Efektívnosť klastrovania — úroveň 2



# Zhrnutie

## Hlavné charakteristiky nového algoritmu na filtrovanie spamu

- ▶ email je charakterizovaný **kvantitatívnymi profilmi**
- ▶ elementárne profily sa z hľadiska výkonnosti vyrovnajú alebo predčia heuristické pravidlá a Bayesov filter
- ▶ ďalšie výhody
  - ▶ škálovateľnosť, nízka výpočtová zložitosť, parallelizovateľnosť, robustnosť
  - ▶ nízka vulnerabilita
  - ▶ kombinovateľnosť s existujúcimi riešeniami
  - ▶ flexibilnosť a rozšíriteľnosť algoritmu
  - ▶ možnosť kategorizácie emailov
  - ▶ nezávislosť na jazyku
- ▶ efektívna tvorba a aktualizácia korpusu prostredníctvom **adaptívneho klastrovania**

# Klastrovacie algoritmy

## SPAMIA

Existujúce riešenia na filtrovanie spamu

Návrh nového algoritmu

Predbežné merania efektívnosti

## Algoritmy

Klastrovacie algoritmy

Klasifikačné algoritmy

# Klastrovacie algoritmy

Zmes normálnych rozdelení/EM-algoritmus

Hierarchické klastrovanie

- ▶ AGNES, DIANA, ...

Deliace klastrovanie

- ▶ K-Means, PAM, CLARA, ...

Klastrovanie založené na hustote

- ▶ DBSCAN, OPTICS, ...

a mnoho ďalších ...

# Klastrovacie algoritmy

## K-Means

- ▶ Forgy (1965), MacQueen (1967)

## DBSCAN (Density-Based Spatial Clustering of Apps. with Noise)

- ▶ Ester, Kriegel, Sander, Xu (1996)

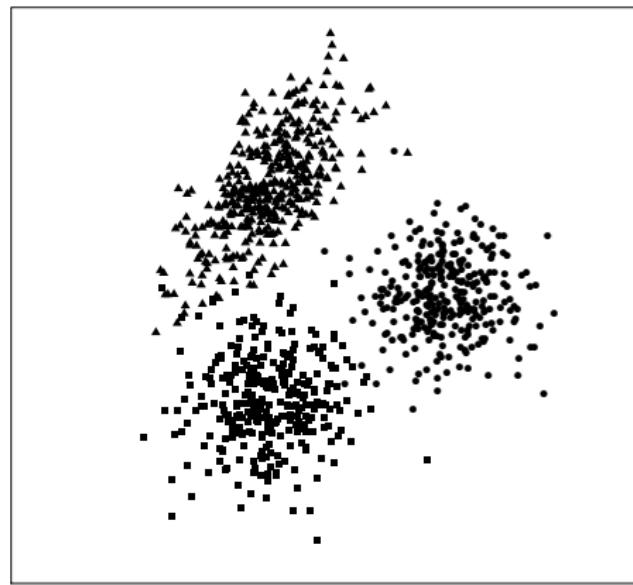
## OPTICS (Ordering Points To Identify the Clustering Structure)

- ▶ Ankerst, Breuning, Kriegel, Sander (1999)

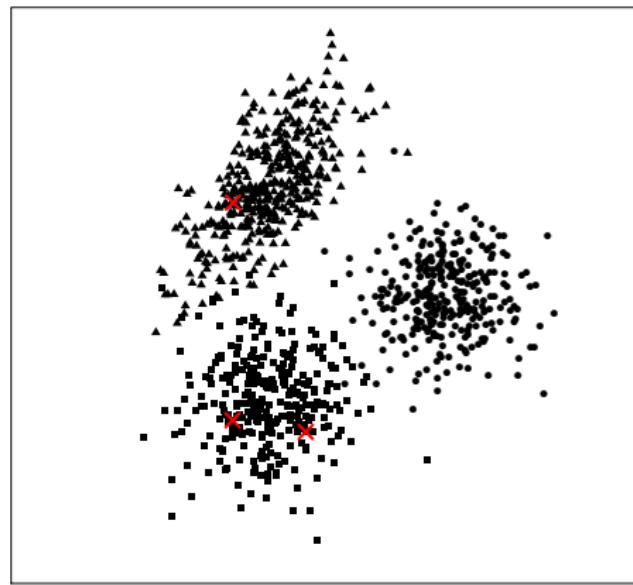
# K-Means: algoritmus

1. určenie počtu hľadaných **klastrov  $k$**
2. výber  **$k$  náhodných objektov** z množiny klastrovaných objektov — reprezentantov klastrov
3. priradenie všetkých objektov k najbližšiemu z vybraných  $k$  reprezentantov
4. určenie nových **reprezentantov** klastrov — sú nimi priemerné objekty (means) v jednotlivých klastroch
5. ak sa reprezentanti klastrov **zmenia** (vzhľadom k zvolenému kritériu), algoritmus **pokračuje bodom 3.**; ak sa reprezentanti **nezmenia**, algoritmus **končí**

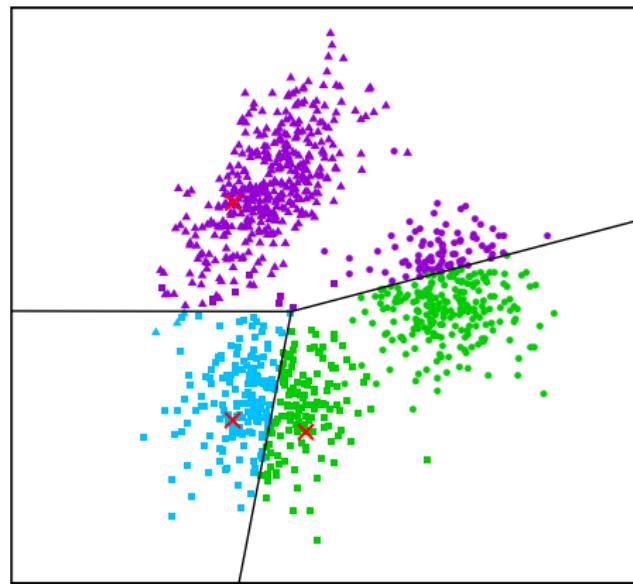
# K-Means: množina objektov 1



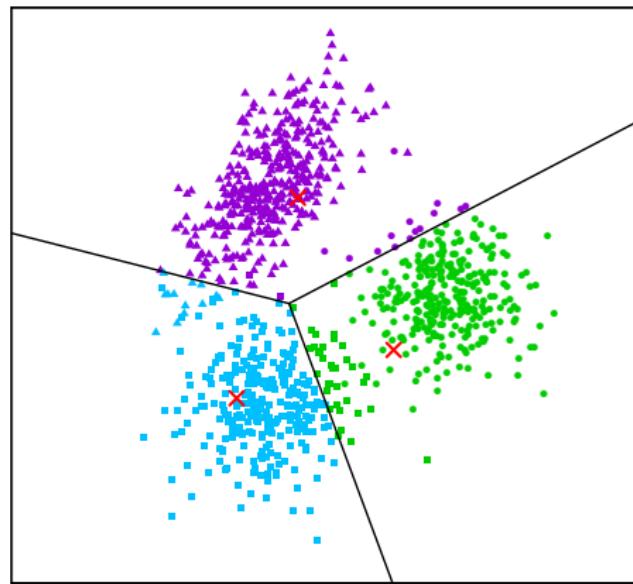
# K-Means: prvý výber reprezentantov (náhodný)



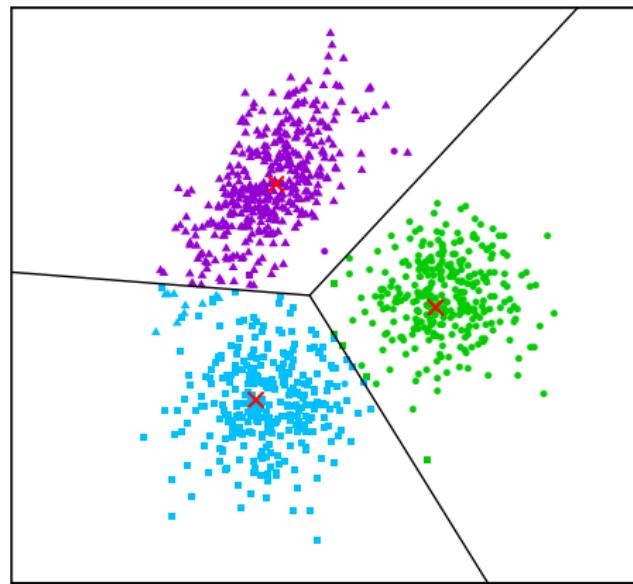
# K-Means: priradenie objektov k reprezentantom



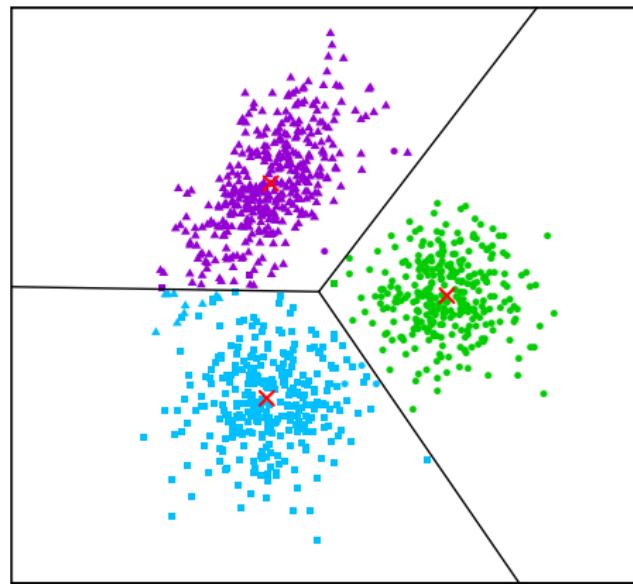
## K-Means: druhá iterácia



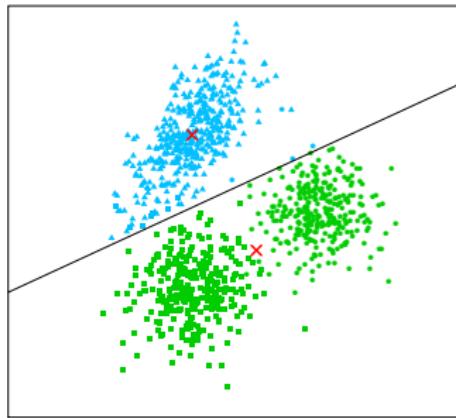
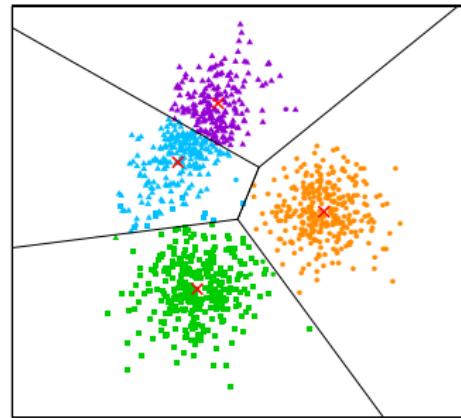
## K-Means: tretia iterácia



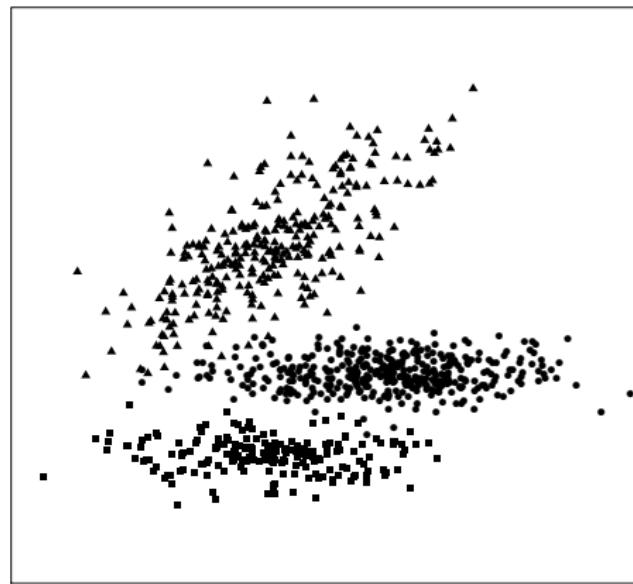
## K-Means: výsledné klastrovanie



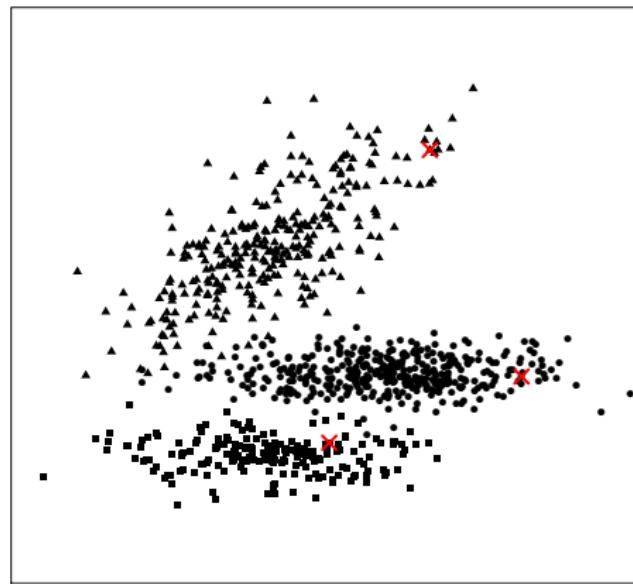
## K-Means: nesprávne určený počet klastrov

(a)  $k = 2$ (b)  $k = 4$

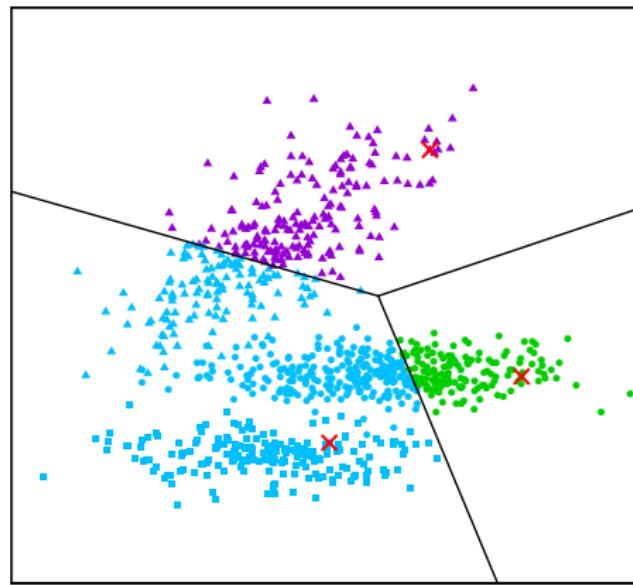
## K-Means: množina objektov 2



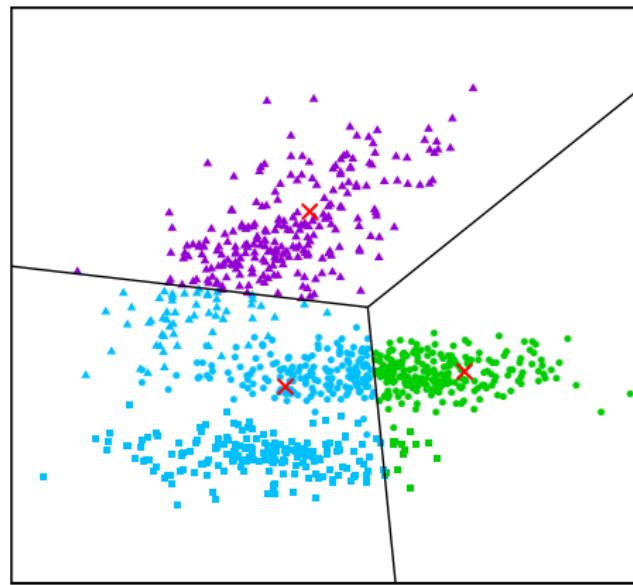
# K-Means: prvý výber reprezentantov (náhodný)



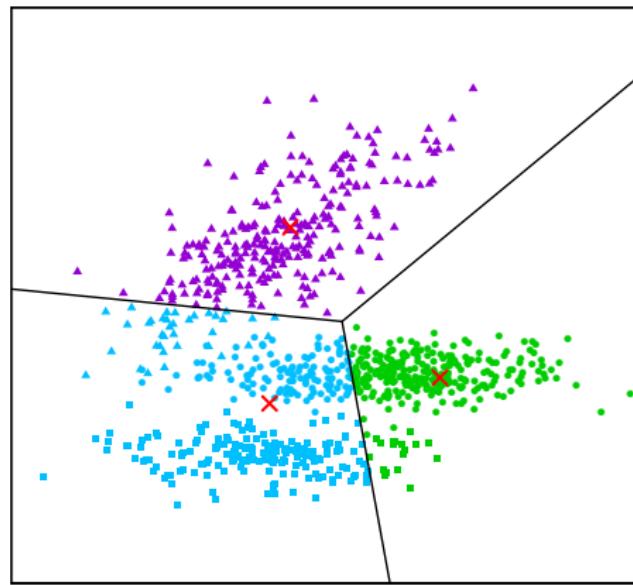
# K-Means: priradenie objektov k reprezentantom



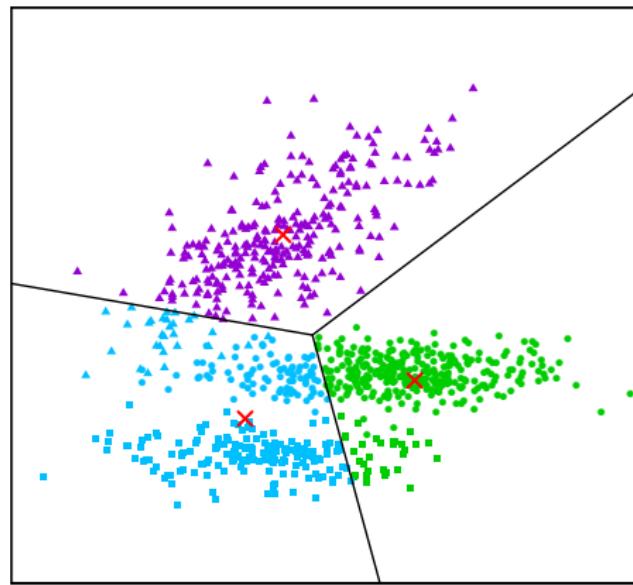
# K-Means: druhá iterácia



## K-Means: tretia iterácia



## K-Means: výsledné klastrovanie



# K-Means: výhody a nevýhody

- + jednoduchosť
- + schopnosť určiť klastre, ktoré od seba nie sú jednoznačne oddelené
- + rozklastrovanie všetkých objektov (diskutabilné)
- potreba vopred určiť počet klastrov  $k$
- závislosť výsledného klastrovania na náhodnej voľbe prvých reprezentantov
- nerobustnosť voči odľahlým objektom
- neschopnosť určiť klastre rôznych tvarov

# DBSCAN

## Density-Based Spatial Clustering of Apps. with Noise

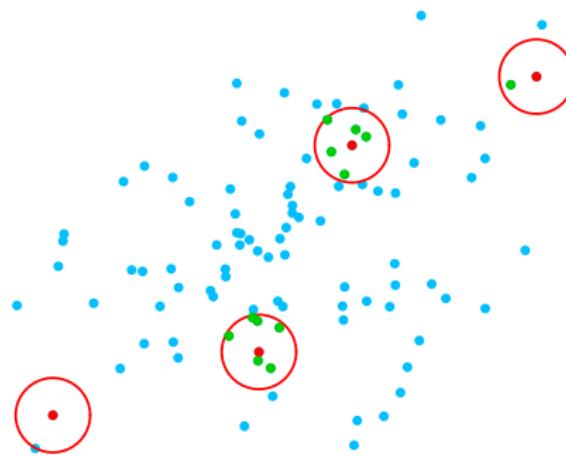
- ▶ klastrovanie založené na hustote objektov
- ▶ nutnosť voľby dvoch parametrov:
  - ▶ vzdialenosť  $\varepsilon$  a
  - ▶ minimálneho počtu objektov  $N_{min}$

# DBSCAN: $\varepsilon$ -okolie objektu

## Definícia

Nech  $\mathcal{O}$  je množina objektov. Množina

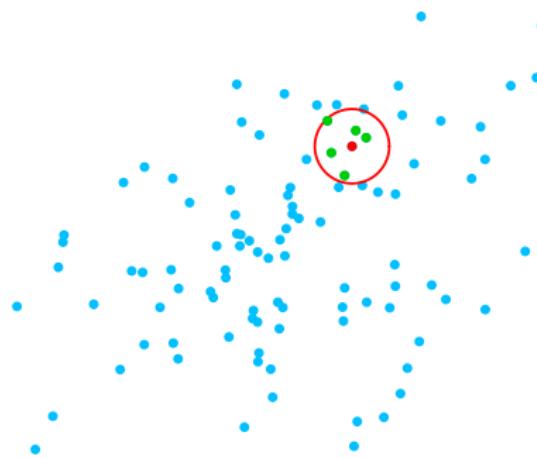
$N_\varepsilon(O) = \{O_i \in \mathcal{O} : d(O, O_i) \leq \varepsilon\}$  sa nazýva  **$\varepsilon$ -okolie objektu**  
 $O \in \mathcal{O}, \forall i = 1, 2, \dots, n.$



# DBSCAN: vnútorný objekt

## Definícia

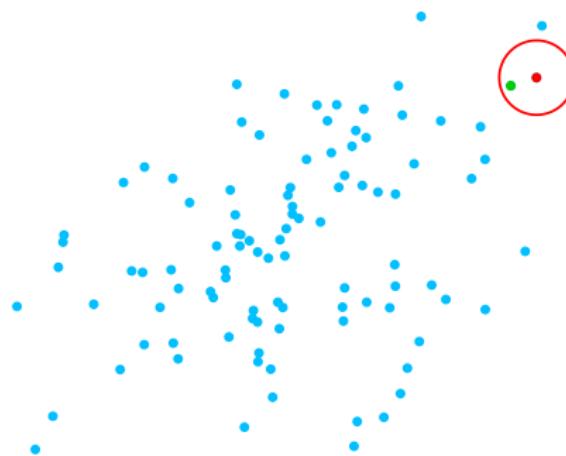
Objekt  $O$  sa nazýva **vnútorný objekt** (core point), ak počet objektov v jeho  $\varepsilon$ -okolí  $N_\varepsilon(O)$  je aspoň  $N_{min}$ , teda  $|N_\varepsilon(O)| \geq N_{min}$ .



# DBSCAN: vonkajší objekt

## Definícia

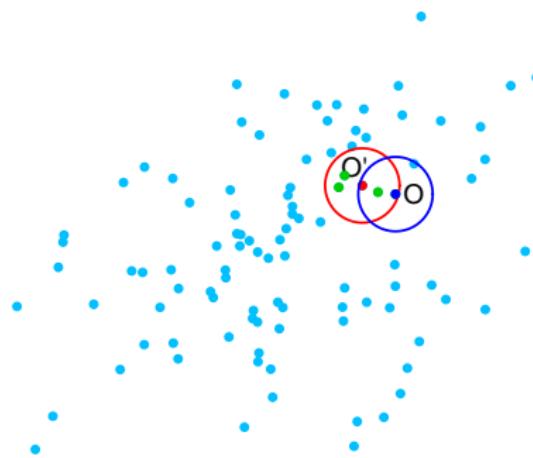
Objekt  $O$  sa nazýva **vonkajší objekt**, ak počet objektov v jeho  $\varepsilon$ -okolí  $N_\varepsilon(O)$  je menej ako  $N_{min}$ , teda  $|N_\varepsilon(O)| < N_{min}$ .



# DBSCAN: priamo dostupný objekt

## Definícia

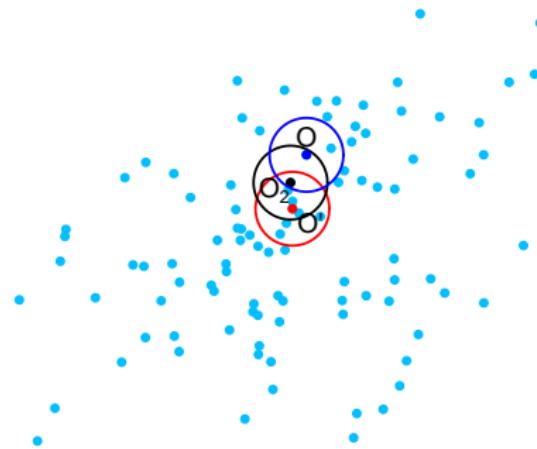
Objekt  $O$  je priamo dostupný z objektu  $O'$  vzhľadom k danému  $\varepsilon$  a  $N_{min}$ , ak  $O \in N_\varepsilon(O')$  a zároveň  $|N_\varepsilon(O')| \geq N_{min}$ .



# DBSCAN: dostupný objekt

## Definícia

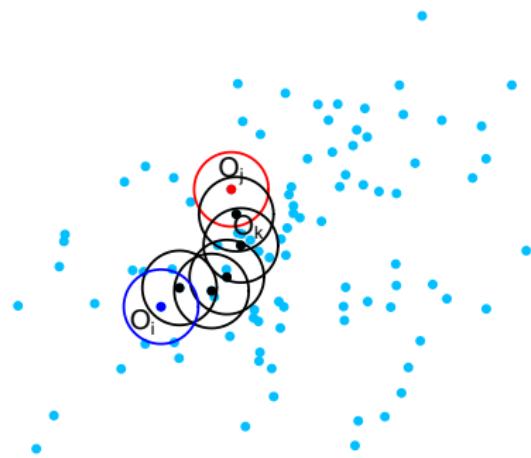
Objekt  $O$  je dostupný z objektu  $O'$  vzhľadom k danému  $\varepsilon$  a  $N_{min}$ , ak pre danú postupnosť objektov  $O_1, \dots, O_n$ , pričom  $O_1 = O'$  a  $O_n = O$ , platí, že objekt  $O_{k+1}$  je priamo dostupný z objektu  $O_k$ .



# DBSCAN: spojené objekty

## Definícia

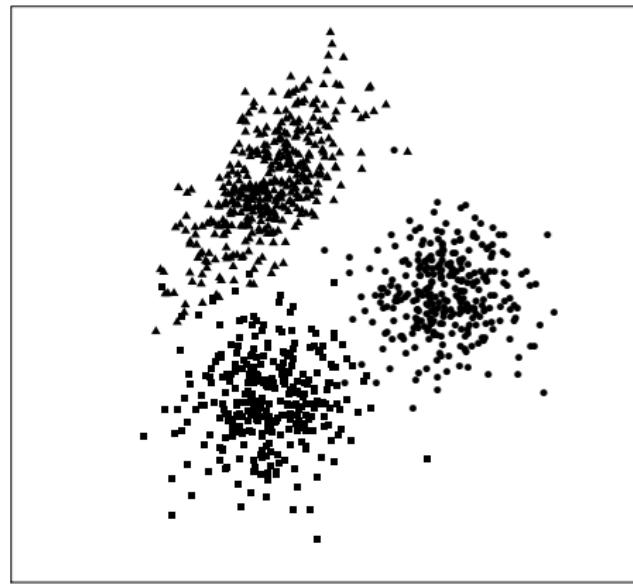
Objekt  $O_i$  je spojený s objektom  $O_j$  vzhľadom k danému  $\varepsilon$  a  $N_{min}$ , ak existuje objekt  $O_k$  taký, že objekty  $O_i$  a  $O_j$  sú dostupné z  $O_k$  vzhľadom k danému  $\varepsilon$  a  $N_{min}$ .



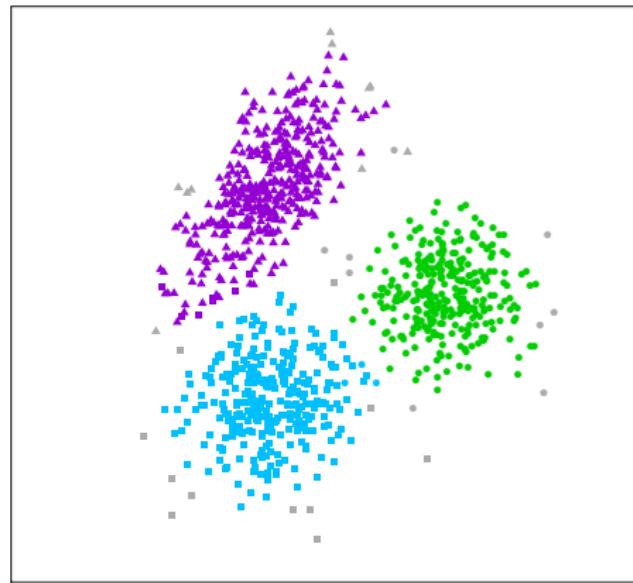
# DBSCAN: algoritmus

1. náhodný výber jedného objektu  $O$  z množiny nezaradených objektov (na začiatku je to množina všetkých objektov)
2. určenie počtu objektov v  $\varepsilon$ -okolí vybraného objektu  $O$  a
  - ▶ ak  $|N_\varepsilon(O)| < N_{min}$ , tak je daný objekt zaradený do šumu;
  - ▶ ak  $|N_\varepsilon(O)| \geq N_{min}$ , tak je vytvorený nový klaster, do ktorého patria všetky objekty, ktoré sú dostupné z daného objektu;
3. algoritmus končí v prípade, že sú všetky objekty zaradené do niektorého z klastrov alebo do šumu;  
ak ešte ostali nezaradené objekty, algoritmus pokračuje bodom 1.

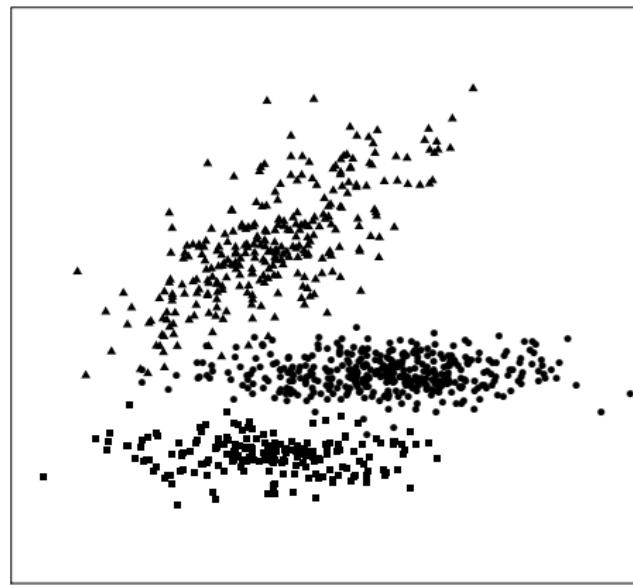
# DBSCAN: množina objektov 1



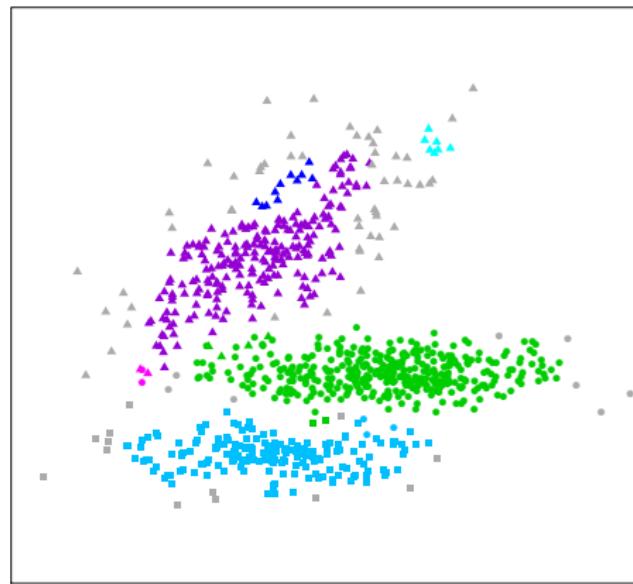
## DBSCAN: výsledné klastrovanie



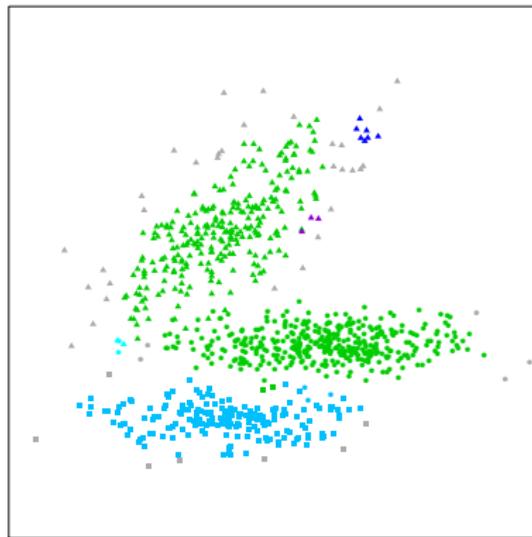
## DBSCAN: množina objektov 2



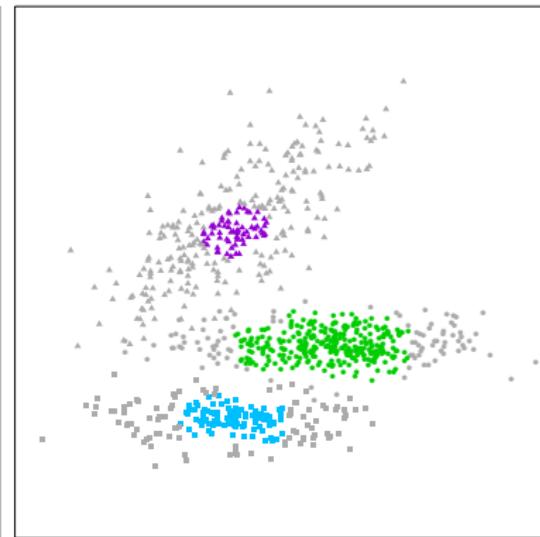
## DBSCAN: výsledné klastrovanie



# DBSCAN: nevhodne zvolené parametre

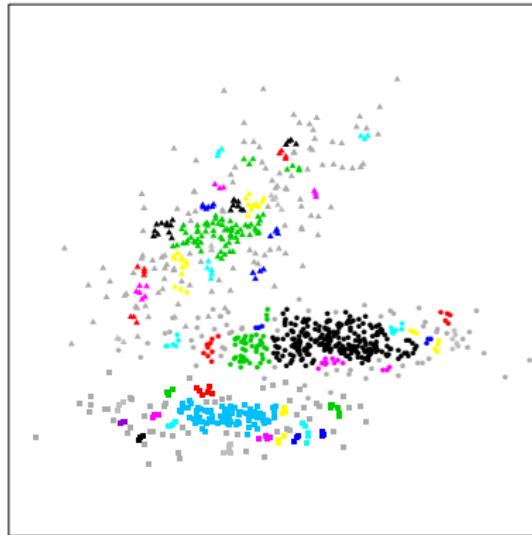
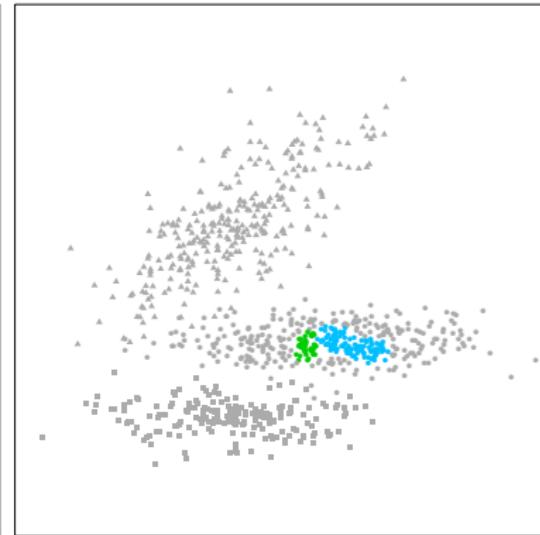


(a) príliš veľké  $\varepsilon$  a nízke  $N_{min}$



(b) príliš veľké  $\varepsilon$  a vysoké  $N_{min}$

## DBSCAN: nevhodne zvolené parametre

(c) príliš malé  $\epsilon$  a nízke  $N_{min}$ (d) príliš malé  $\epsilon$  a vysoké  $N_{min}$

# DBSCAN - výhody a nevýhody

- + určenie klastrov rôznych tvarov
- + robustnosť voči odľahlým objektom; algoritmus vyčlenení objekty, ktoré nepatria do žiadneho klastra - označí ich za šum
- + nie je potrebné vopred určiť počet klastrov
- volba parametrov  $\varepsilon$  a  $N_{min}$
- viazanosť na fixné  $\varepsilon$  a  $N_{min}$ , teda neschopnosť zachytiť klastre rôznej hustoty
- neschopnosť určiť klastre, ktoré od seba nie sú jednoznačne oddelené

# OPTICS

## Ordering Points To Identify the Clustering Structure

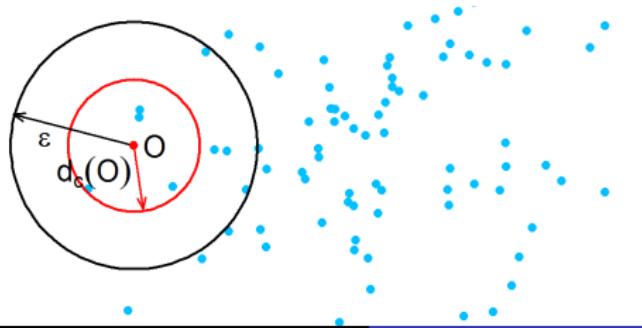
- ▶ usporiadanie objektov založené na ich hustote s následnou možnosťou určiť z tohto usporiadania klastrovanie
- ▶ nutná voľba maximálneho  $\varepsilon$  a minimálneho počtu objektov  $N_{min}$

# OPTICS: core vzdialenosť objektu

## Definícia

Nech  $N_{min}$ -vzdialenosť  $d_m(O)$  objektu  $O$  je vzdialenosť objektu  $O$  od jeho  $N_{min}$ -tého najbližšieho suseda. Potom **core vzdialenosť**  $d_c(O)$  objektu  $O$  je pri danom  $\varepsilon$  a  $N_{min}$  definovaná rovnosťou

$$d_c(O) = \begin{cases} \text{nedefinovaná}, & \text{ak } |N_\varepsilon(O)| < N_{min} \\ d_m(O), & \text{inak.} \end{cases}$$

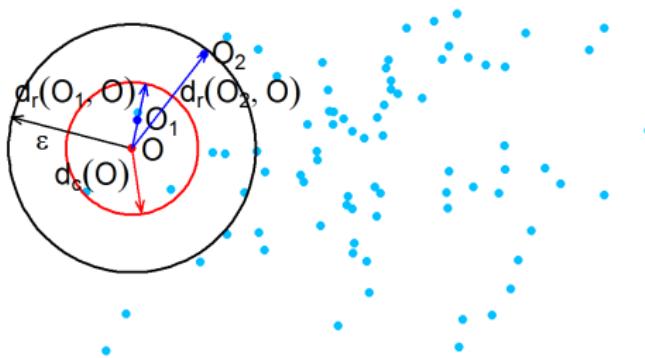


# OPTICS: dostupnosťná (reachability) vzdialenosť objektu

## Definícia

Dostupnosťná vzdialenosť  $d_r(O_i, O)$  objektu  $O_i$  od objektu  $O$  je pri danom  $\varepsilon$  a  $N_{min}$  definovaná rovnosťou

$$d_r(O_i, O) = \begin{cases} \text{nedefinovaná}, & \text{ak } |N_\varepsilon(O)| < N_{min} \\ \max(d_c(O), d(O_i, O)), & \text{inak.} \end{cases}$$



# OPTICS: algoritmus 1/3

1. **výber objektu  $O$**  z množiny neusporiadaných objektov (na začiatku je to množina všetkých objektov)
2. **určenie** objektov v  $\varepsilon$ -okolí objektu  $O$  - **susedov**
3. priradenie core-vzdialenosťi a nedefinovanej dostupnosťnej vzdialenosťi objektu  $O$
4. **zápis** objektu  $O$  do finálneho usporiadania a jeho vylúčenie z množiny neusporiadaných objektov
5.
  - ▶ ak má **objekt  $O$  nedefinovanú core vzdialenosť**, algoritmus **pokračuje bodom 1.**;
  - ▶ ak objekt  $O$  má svoju core vzdialenosť, ...

# OPTICS: algoritmus 2/3

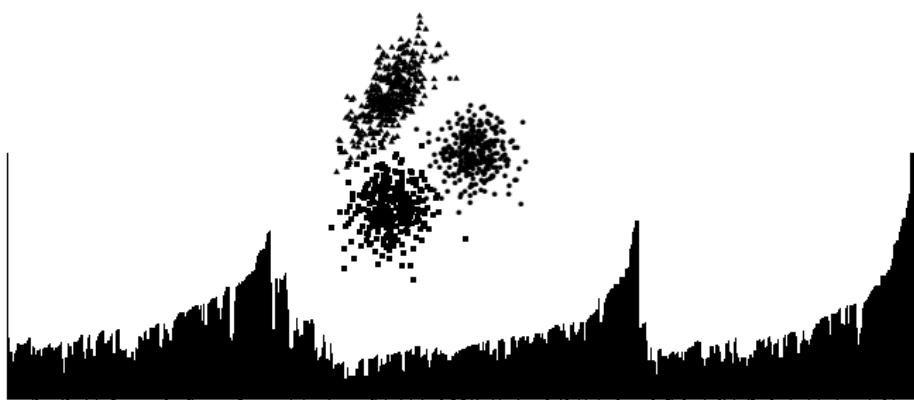
5.
  - ▶ ...
  - ▶ ak objekt  $O$  má svoju core-vzdialenosť,
  - a preusporiadanie susedov
    - ▶ všetkým susedom určíme dostupnosnú vzdialenosť od objektu  $O$
    - ▶ novým objektom v množine susedov ju rovno priradíme
    - ▶ v prípade, že niektoré objekty už boli v množine susedov (teda majú priradenú svoju dostupnosnú vzdialenosť od predtým spracovávaného objektu), priradíme im menšiu z týchto dvoch vzdialenosťí
    - ▶ susedov usporiadame podľa ich dostupnosnej vzdialnosti vzostupne
  - b ...

# OPTICS: algoritmus 3/3

5.
  - ▶ ...
  - ▶ ak objekt  $O$  má svoju core-vzdialenosť,
  - a preusporiadanie susedov ...
  - b určenie core-vzdialenosťi susedovi s najnižšou dostupnosťou vzdialenosťou, teda prvému v poradí
  - c zápis spracovávaného suseda do finálneho usporiadania a jeho vylúčenie z množiny susedov a z neusporiadaných objektov
  - d určenie objektov v  $\varepsilon$ -okolí spracovávaného suseda - t.j. nových susedov
  - e ak má tento sused svoju core-vzdialenosť, opäťovne sa preusporiada množina susedov (bod 5.a)
  - f algoritmus pokračuje bodom 5.b až pokým nie sú spracovaní všetci susedia
6. algoritmus končí v prípade, že usporiadal všetky objekty; ak ešte sú neusporiadané objekty, algoritmus pokračuje bodom 1.

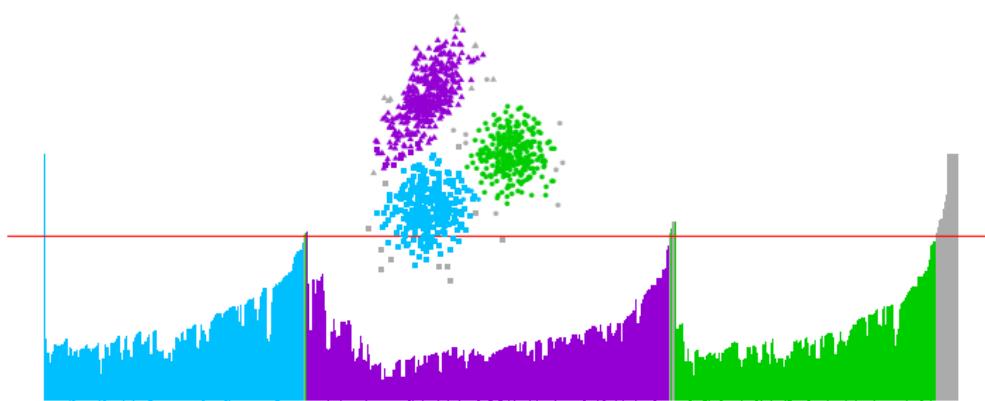
# OPTICS: usporiadanie množiny objektov 1

- ▶ graf dostupnosti vzdialosti objektov, ktoré sú usporiadané algoritmom OPTICS



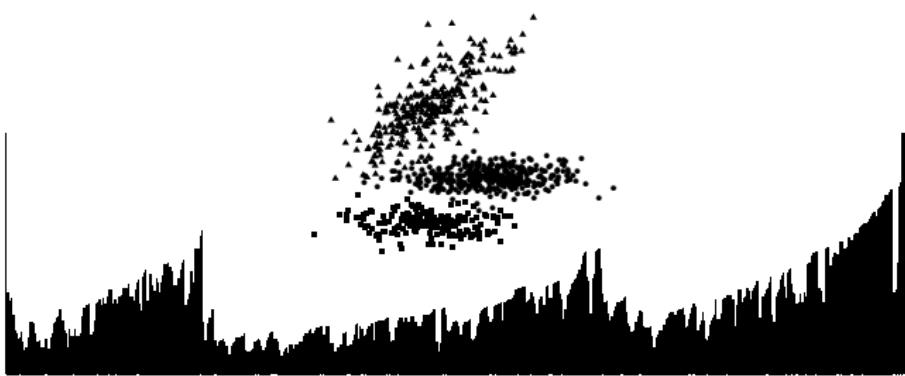
# OPTICS: DBSCAN klastrovanie

- ▶ preložením čiary vo výške zvoleného  $\varepsilon$  získavame klastrovanie algoritmom DBSCAN pri danom  $N_{min}$



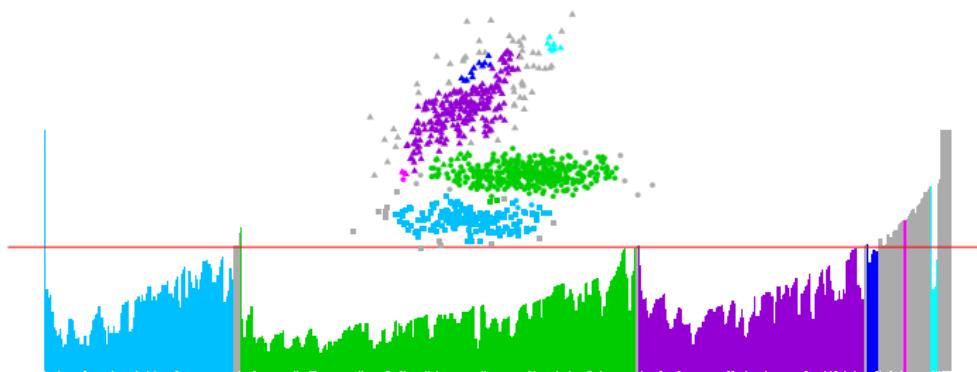
# OPTICS: usporiadanie množiny objektov 2

- ▶ graf dostupnosti vzdialosti objektov, ktoré sú usporiadané algoritmom OPTICS



# OPTICS: DBSCAN klastrovanie

- ▶ preložením čiary vo výške zvoleného  $\varepsilon$  získavame klastrovanie algoritmom DBSCAN pri danom  $N_{min}$



# OPTICS: výhody a nevýhody

- + rovnaké ako pri DBSCANe plus
- + nie je potrebné voliť fixné, ale iba maximálne  $\varepsilon$ , čím je možné identifikovať aj klastre rozličnej hustoty
- + poskytuje celkový pohľad na štruktúru dát - je možné vytvoriť hierarchické klastrovanie
- voľba parametrov  $\varepsilon$  a  $N_{min}$
- neschopnosť určiť klastre, ktoré od seba nie sú jednoznačne oddelené
- otázny spôsob ako z usporiadania určiť najvhodnejšie rozklastrovanie objektov

# Klasifikačné algoritmy

## SPAMIA

Existujúce riešenia na filtrovanie spamu

Návrh nového algoritmu

Predbežné merania efektívnosti

## Algoritmy

Klastrovacie algoritmy

Klasifikačné algoritmy

# Klasifikačné algoritmy

**LDA** (Lineárna diskriminačná analýza)

- ▶ Fisher (1936)

**Logistická regresia**

**Neurónové siete**

**SVM** (Support Vector Machines)

- ▶ Cortes, Vapnik (1995)

**KNN** ( $k$ -nearest neighbors;  $k$  najbližších susedov)

- ▶ Royall (1966)

**Klasifikačný strom**

- ▶ Breiman, Friedman, Olshen, Stone (1984)

**Náhodný les**

- ▶ Breiman (2001)

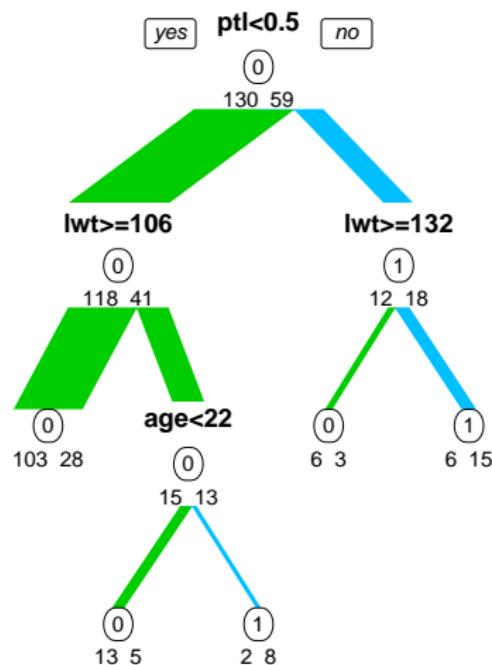
## Ilustračný príklad

Dáta birthwt, v R-kovej knižnici MASS.

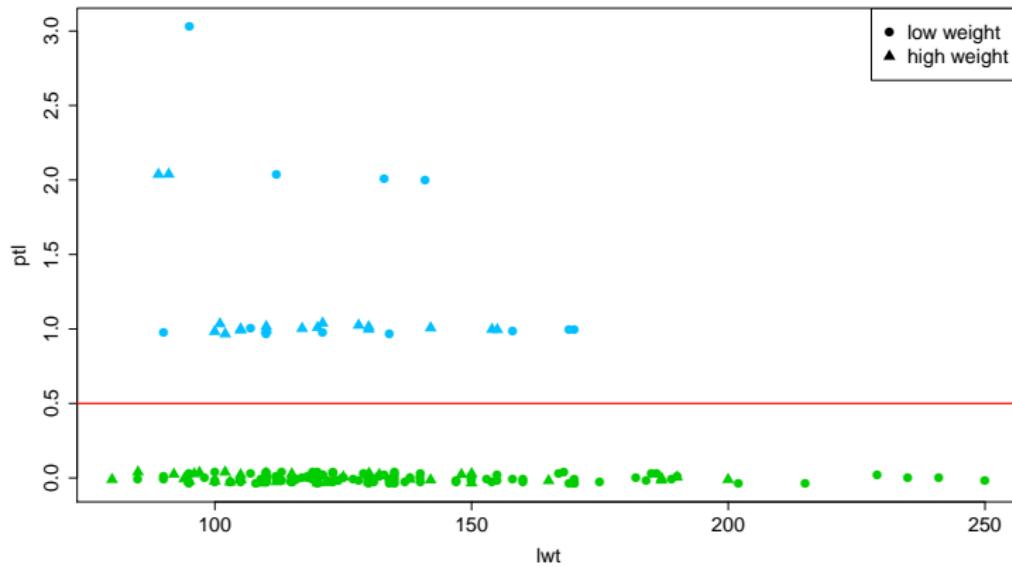
Medicínske dáta. 189 pacientiek - rodičiek. O každej sa vie 8 ukazovateľov (vek, rasa, počet predchádzajúcich predčasných pôrodov, atď.). Vie sa aj to, či sa dotyčnej rodičke narodilo dieťa s nízkou váhou (< 2.5 kg) alebo nie.

Úloha: na základe týchto dát zaradiť budúcu rodičku so známymi hodnotami uvedených ukazovateľov do jednej z tried: riziková (low), neriziková (high).

## Klasifikačný strom: rekurzívne binárne delenie



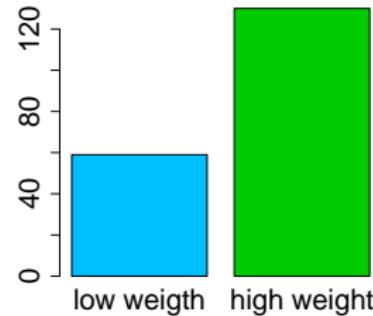
## Klasifikačný strom: prvý 'split'



# Miera nečistoty: Entropia

Entropia dát:

$$i(\tau) = -\frac{59}{189} \log \frac{59}{189} - \frac{130}{189} \log \frac{130}{189}$$



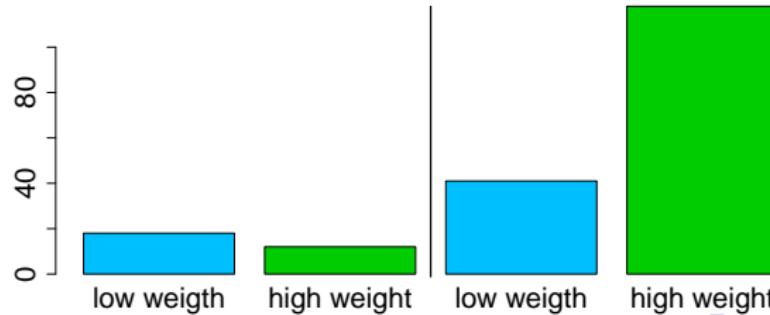
# Entropia rozdelených dát (prvý 'split')

Entropia hornej polovice dát:

$$i(\tau_u) = -\frac{18}{30} \log \frac{18}{30} - \frac{12}{30} \log \frac{12}{30}$$

Entropia dolnej polovice dát:

$$i(\tau_l) = -\frac{41}{159} \log \frac{41}{159} - \frac{118}{159} \log \frac{118}{159}$$



# Optimalizačné kritérium

Deliaca nadrovina  $s$  sa volí tak, aby sa rozdiel medzi nečistotou  $i(\tau)$  v materskom uzle  $\tau$  (t.j. pred delením) a (váženou) sumárhou nečistotou  $i(s_u) + i(s_l)$  dcérskejch uzlov  $s_u, s_l$  (t.j., po delení) bol maximálny:

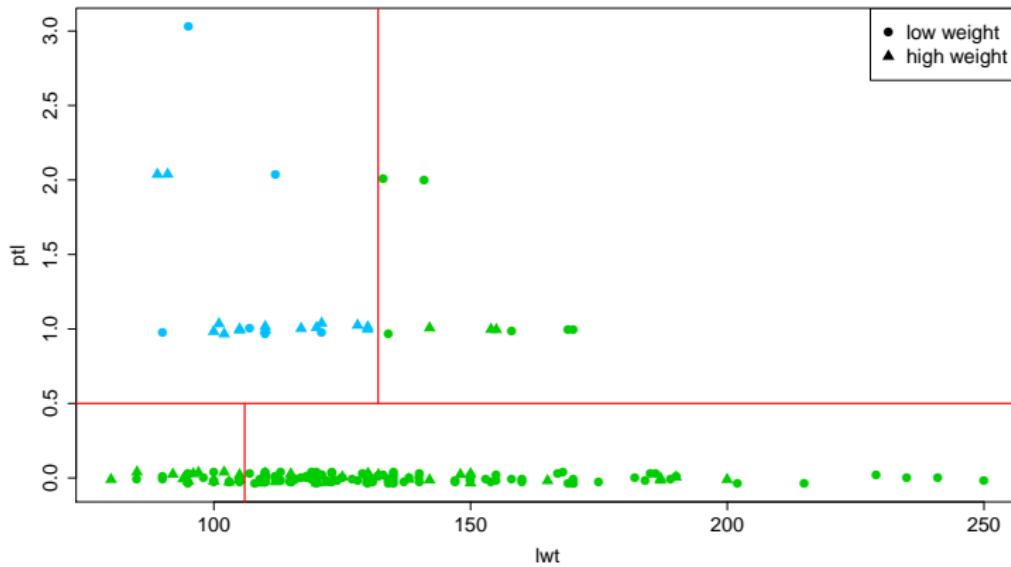
$$\hat{s} = \arg \max_s \Delta(s, \tau)$$

kde

$$\Delta(s, \tau) = i(\tau) - (p(s_u)i(s_u) + p(s_l)i(s_l))$$

a  $p(\tau_d)$  je relatívna početnosť pozorovaní v dcérskom uzle  $d \in \{u, l\}$ .

## Klasifikačný strom: druhý 'split'



# Klasifikačná tabuľka

## Klasifikačná tabuľka

	0	1
0	122	8
1	36	23

# Klasifikačný strom: +/-

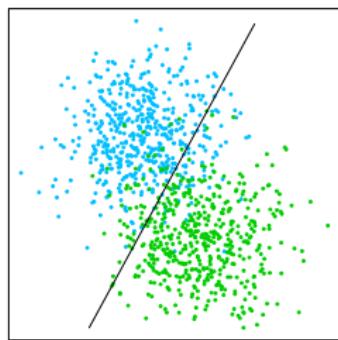
## Výhody:

- ▶ ľahká interpretovateľnosť,
- ▶ ľahko získateľná dôležitosť prediktorov,
- ▶ rýchly algoritmus,
- ▶ použitelné aj na dátá kde  $n \ll p$ .

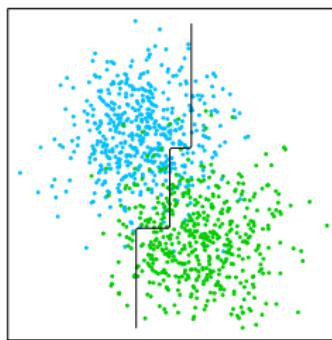
## Nevýhody:

- ▶ existujú aj lepšie zatriedovacie algoritmy,
- ▶ nestabilita.

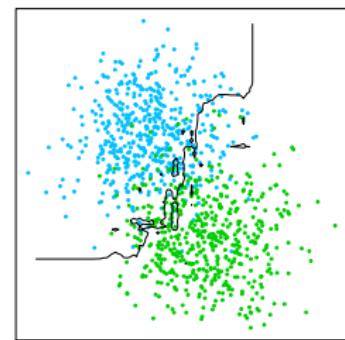
# Porovnanie niektorých klasifikačných algoritmov



(a) LDA



(b) klasifikačný strom



(c) náhodný les

# Náhodný les: algoritmus

Algoritmus:

1. Zvoľ  $T$ , počet stromov v lese.
2. Zvoľ  $m$ , počet prediktorov.
3. Nechaj narásť  $T$  stromov, a to nasledovným spôsobom:
  - ▶ urob bootstrapový výber z dát, na nich nechaj narásť strom;
  - ▶ pri raste stromu, v každom uzle náhodne vyber  $m$  prediktorov a pre nich nájdi najlepšie delenie;
  - ▶ takto nechaj narásť strom až po spodok.
4. Nový objekt je zatriedený do tej triedy, kam ho zaradí väčšina stromov lesa.

# Náhodný les: +/-

## Výhody:

- ▶ prirodzene zvláda dátu zmiešaného typu
- ▶ vie si poradiť s chýbajúcimi pozorovaniami
- ▶ robustný voči odlahlým pozorovaniam
- ▶ invariantný na monotónnu transformáciu prediktorov
- ▶ škálovateľný
- ▶ vie si poradiť s irelevantnými prediktormi
- ▶ vynikajúci výkon

## Nevýhody:

- ▶ slabá interpretovateľnosť,

Ďakujeme za pozornosť.