

# Rozpoznávanie obrazcov šk.r. 2019-20

Úvodná prednáška

Doc. RNDr. Milan Ftáčnik, CSc.

# Sylabus prednášky

- Príznamy, extrakcia (v prednáške z PV)
- Klasické prístupy vs. neurónové siete
- Štatistika a pravdepodobnosť
- Príznamy, selekcia a príznakový vektor
- Klasifikátory a ich hodnotenie
- Neurónové siete
- Aplikácie

# Rozšírený sylabus prednášky

- Úloha klasifikácie, klasický prístup cez príznaky a klasifikátor vs. neurónové siete
- Výber a selekcia príznakov
- Klasifikátory, klasický prístup
  - Bayesovská teória rozhodovania, diskriminačné funkcie a rozdeľujúce nadplochy, kritérium minimálnej chyby
  - Rozhodovacie stromy

# Rozšírený sylabus prednášky II

- Diskriminačná analýza, lineárny klasifikátor
- Mechanizmy podporných vektorov (SVM) a kernelový trik na nelineárny prípad
- Riadené vs. neriadené učenie klasifikátora
- Neurónové siete a hlboké konvolučné neurónové siete
- Hodnotenie kvality klasifikácie

# Podmienky ukončenia

- 60 bodov skúška
- 40 bodov cvičenie
- Z každého aspoň 50%
  
- 50 b – E                      60 b – D
- 70 b – C                      80 b – B
- 90 b – A

# Literatúra (v knižnici FMFI UK)

- Christopher M. Bishop: **Pattern Recognition and Machine Learning**
- Richard O. Duda, Peter E. Hart, David G. Stork: **Pattern classification**
- Trevor Hastie, Robert J. Tibshirani, J. Jerome H. Friedman: **The elements of statistical learning**
- V. Kvasnička et al: **Úvod do teórie neurónových sietí**

# Pattern recognition

- „The assignment of a physical object or event to one of several pre-specified categories“
- R. O. Duda, P. E. Hart, and D. G. Stork, *Pattern Classification*
- Disciplína je prepojená s počítačovým videním, podobá sa na strojové učenie či dolovanie dát
- Zaraduje sa neznámy objekt do triedy na základe popisu (obrazca)

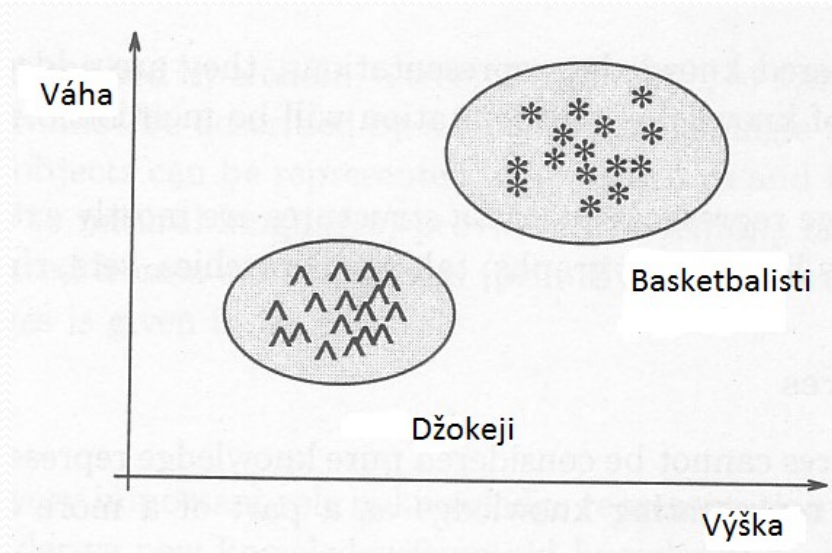
# Štatistický vs. syntaktický popis

- Štatistický popis je kvantitatívny, je to príznakový vektor  $\mathbf{x} = (x_1, x_2, \dots, x_n)$ , kde zložky  $x_i$  sú číselné príznaky z popisu oblasti a ich všetky možné hodnoty tvoria n-rozmerný Euklidovský príznakový priestor
- Syntaktický popis je štrukturálny, je to reťazec  $\mathbf{x} = abcdef$ , kde znaky slova  $\mathbf{x}$  označujú primitíva, teda ďalej nedeliteľné časti obrazu



# Rozpoznávanie obrazcov

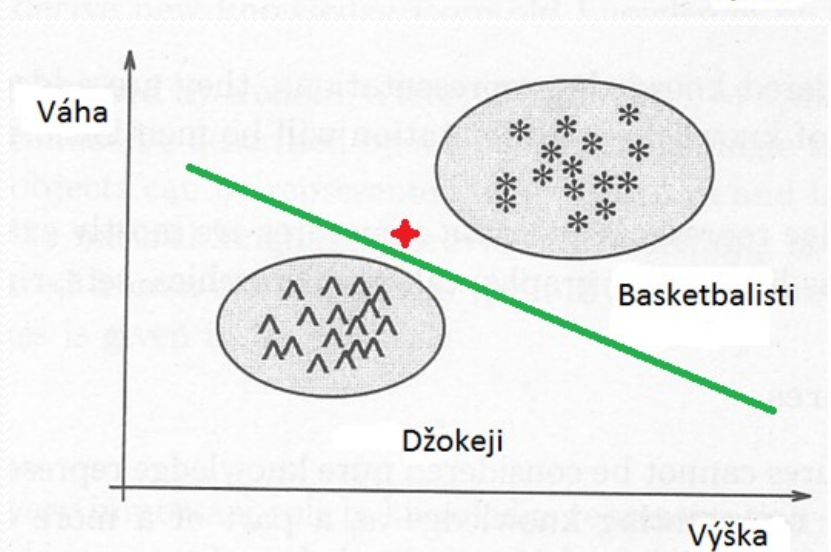



- Príklad: 2D príznakový vektor  $\mathbf{x} = (\text{výška}, \text{váha})$ , klasifikujeme do dvoch tried a sú známe prvky tried



- Klasifikátor rozhodne o zaradení do triedy na základe pravidla vytvoreného učením na základe známych prvkov tried

# Rozpoznávanie obrazcov II

- Kam zaradíme neznámeho uchádzača?



# Rozpoznávanie obrazcov III


- **Objekt** je fyzická jednotka, obvykle reprezentovaná oblasťou v obraze
- Objekt popisujeme formálnym popisom, ktorý sa nazýva **obrazec** (angl. pattern)
- Obrazcom môže byť **príznakový vektor**, vyjadrujúci kvantitatívny popis oblasti alebo **slovo** z primitív a relácií medzi nimi vyjadrujúce štrukturálny (kvalitatívny) popis

# Rozpoznávanie obrazcov IV

- Množinu všetkých objektov možno rozdeliť na podmnožiny s podobnými príznakmi, ktoré sa nazývajú **triedy**
- **Rozpoznanie objektu** znamená priradenie triedy k neznámemu objektu a zariadenie, ktoré priraduje, sa nazýva **klasifikátor**
- Počet tried sa vie obvykle dopredu alebo sa dá odvodiť zo špecifikácie problému


# Rozpoznávanie obrazcov V

- Klasifikátor nerozhoduje o rozpoznaní objektu priamo, ale na základe formálneho popisu vlastností objektu = obrazec
- Preto hovoríme o rozpoznávaní obrazcov (angl. Pattern recognition)



# Rozpoznávanie obrazcov VI


- Najprv uvedieme **klasický prístup**, založený na príznakoch určených človekom a klasifikátore – dá sa použiť pre malý počet známych vzoriek
- Potom **neurónové siete** - vedia sami nájsť vhodné príznaky a na základe toho rozhodnúť o triede, potrebujú veľmi veľa známych vzoriek






# Klasický prístup k rozpoznávaniu

- Aké príznaky by ste použili na klasifikáciu nasledovných objektov?



# Klasický prístup k rozpoznávaniu II

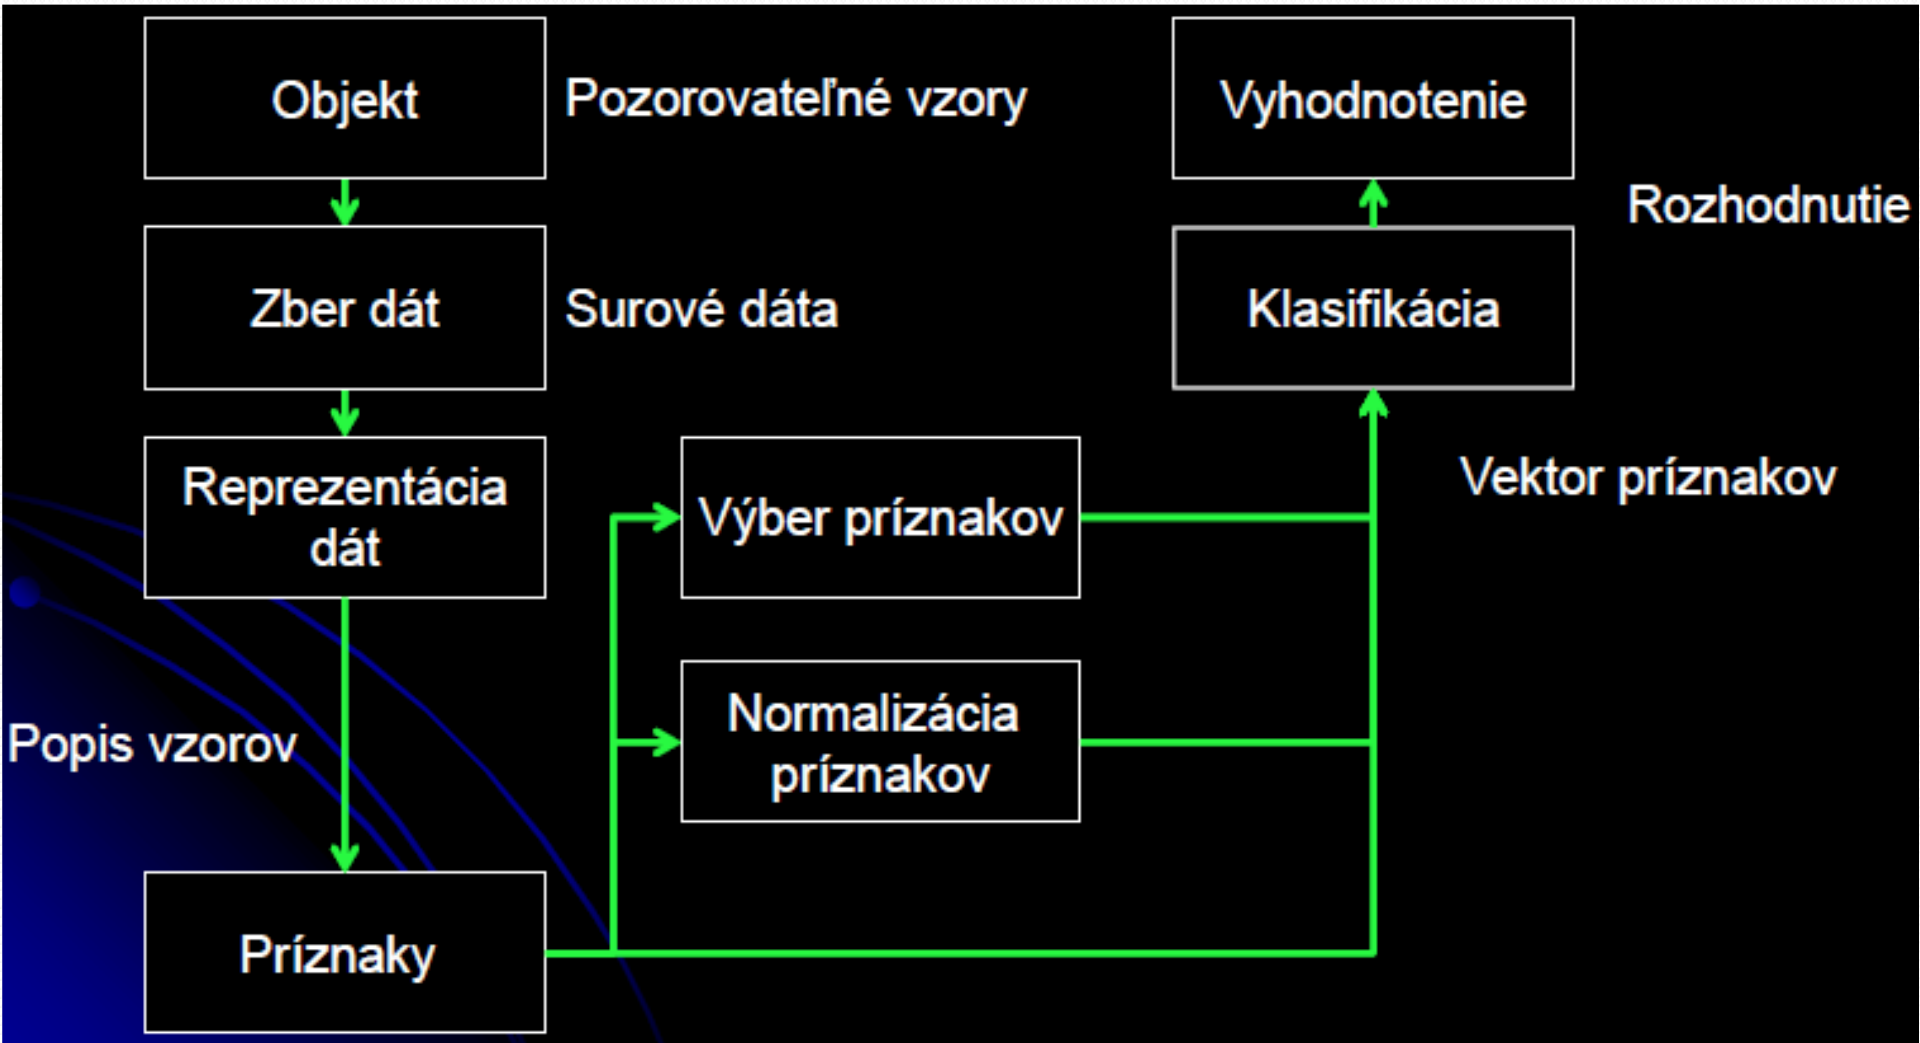
- Aké príznaky by ste použili na klasifikáciu nasledovných objektov?



Príznakový vektor  
 $\mathbf{x} = (\textit{veľkosť}, \textit{kompaktnosť})$




# Rozpoznávanie



# Príznamy

- Výber príznamov ovplyvní klasifikáciu
- Príznamy na odlíšenie tried **odevy** (nohavice, košele), **ovocie** (jablká, pomaranče), **zelenina** (šalát, paradajky)
- Ak zvolíme príznam „zelené veci“ tak sa dostanú jablká, šalát, košele do triedy **zelené oddelenie**

# Príklad



(a)




(b)

Cukríky v  
krabiciach:

$$0,7 < a \leq 1,5$$

$$0,5 < r \leq 1$$




# Dva príznaky

	kruh	štvorec
Obvod	$P(r) = 2\pi r$	$P(r) = 4a$
Obsah	$A(r) = \pi r^2$	$A(r) = a^2$


- Obvod x obsah = priestor príznakov

$$A = \frac{p^2}{4\pi} \text{ vs. } A = \frac{p^2}{16}$$




# Kritérium na rozpoznanie

- $A = \frac{P^2}{k}$ , kde  $4\pi < k < 16$



# Iná situácia z hľadiska príznakov



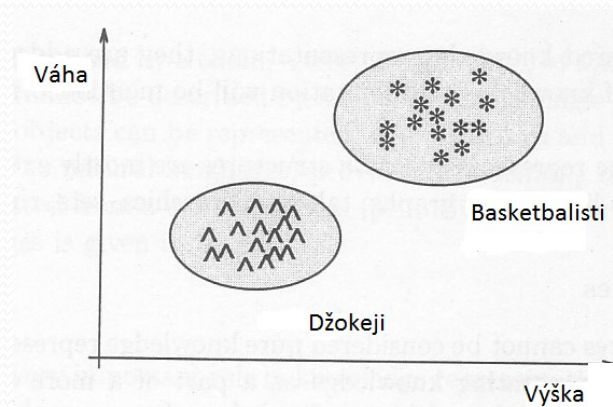


# Rozdelenie tried objektov

- **Separovateľné** triedy – objekty z rôznych tried sa dajú oddeliť nadplochami
- **Lineárne separovateľné** triedy – dajú sa oddeliť nadrovinami
- **Neseparovateľné** triedy – jeden objekt môže patriť do viacerých tried, čiže klasifikátor pri klasifikácii urobí chybu - taká je väčšina reálnych problémov

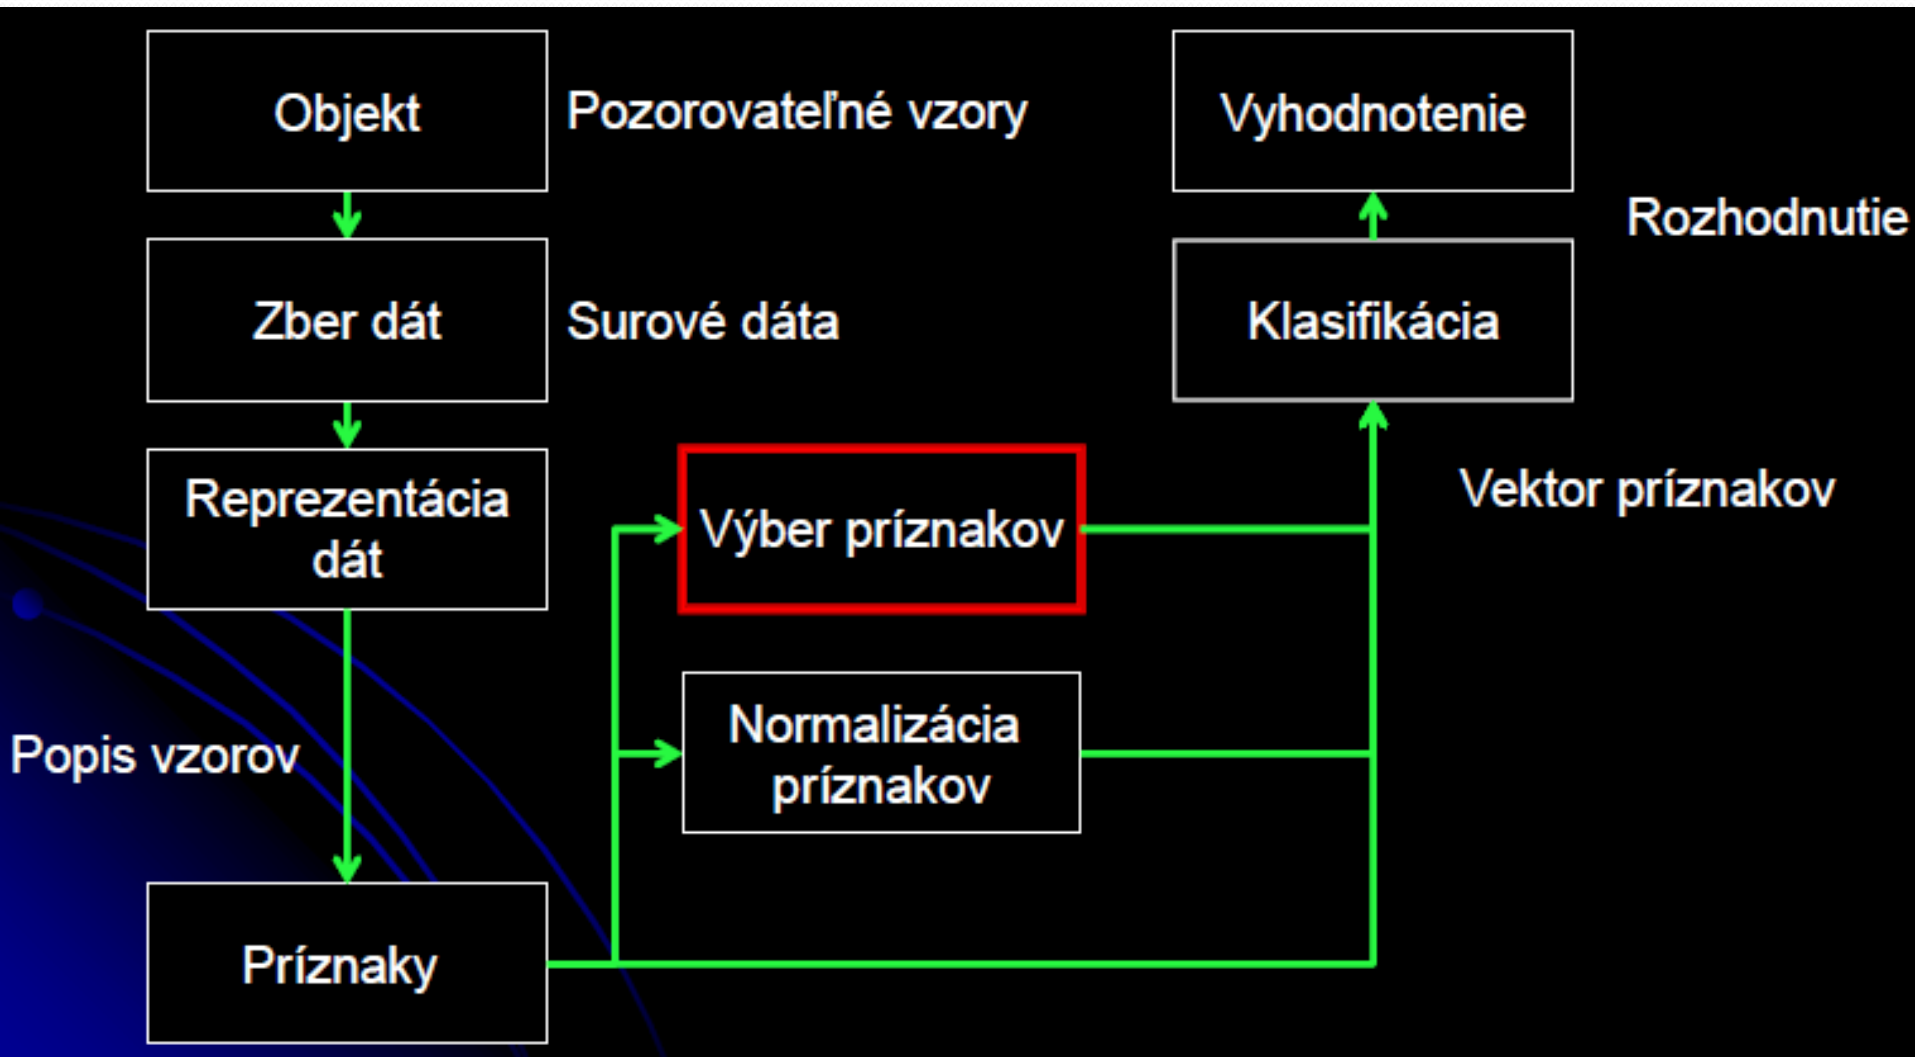
# Rozdelenie tried objektov II

- **Lineárne separovateľné**
- **Separovateľné, ale nie lineárne**
- **Neseparovateľné**





# Rozpoznávanie




# Príznaky

- viac príznakov => viac informácie, vyššia presnosť
- viac príznakov => zložitejšia extrakcia
- viac príznakov => zložitejší tréning klasifikátora
- Riešenie: **optimálny počet príznakov**

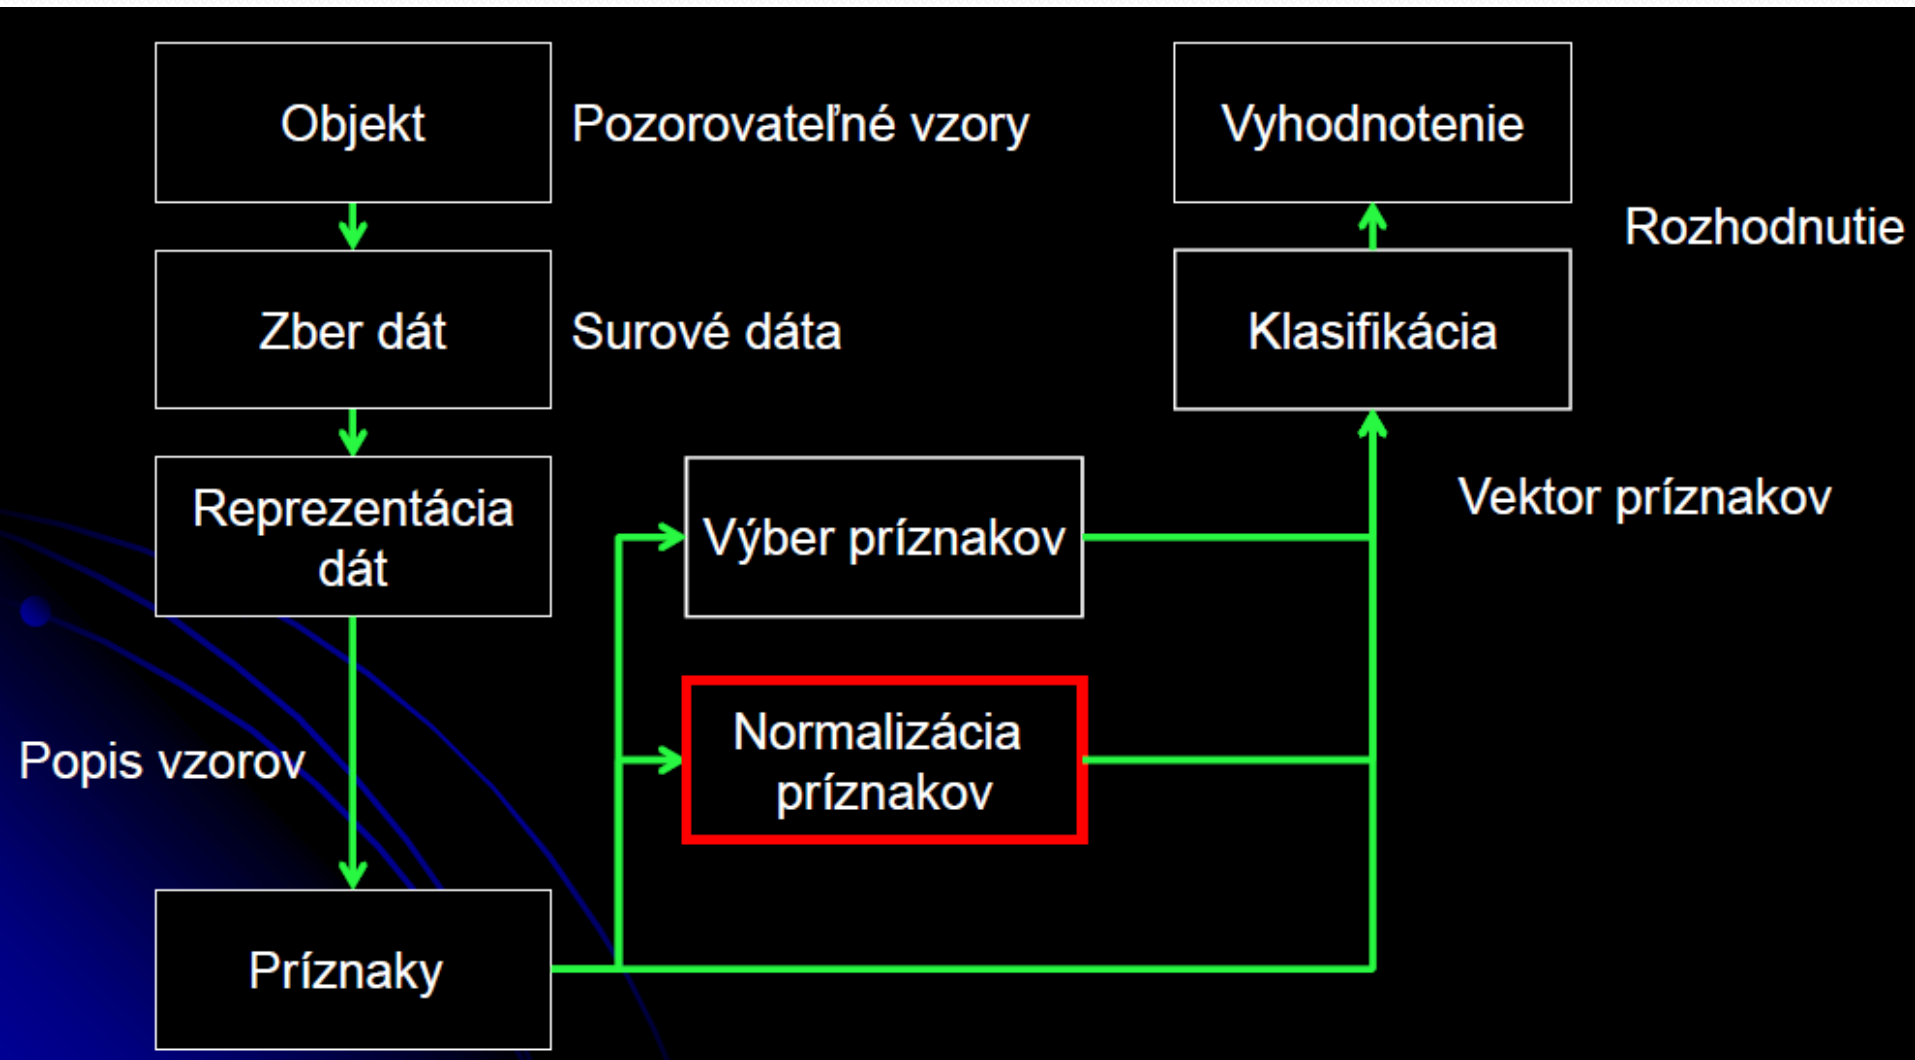
# Príznamy II

- Riešenie: optimálny počet príznamov aj kvôli curse of dimensionality (prekliatie dimenzionality)



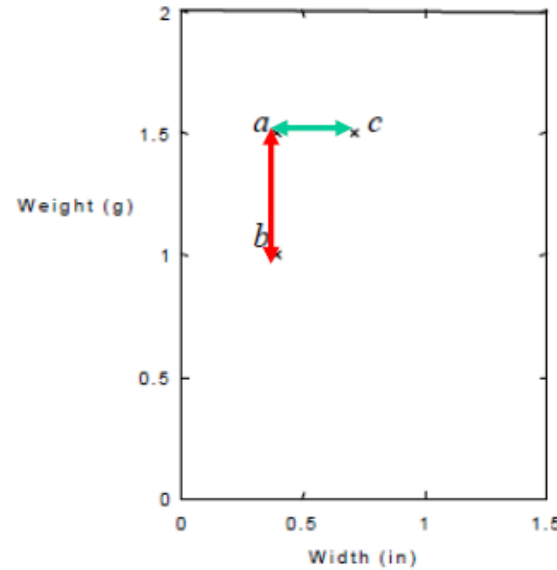

Dimenzionalita je rozmer príznamového vektora

# Rozpoznávanie

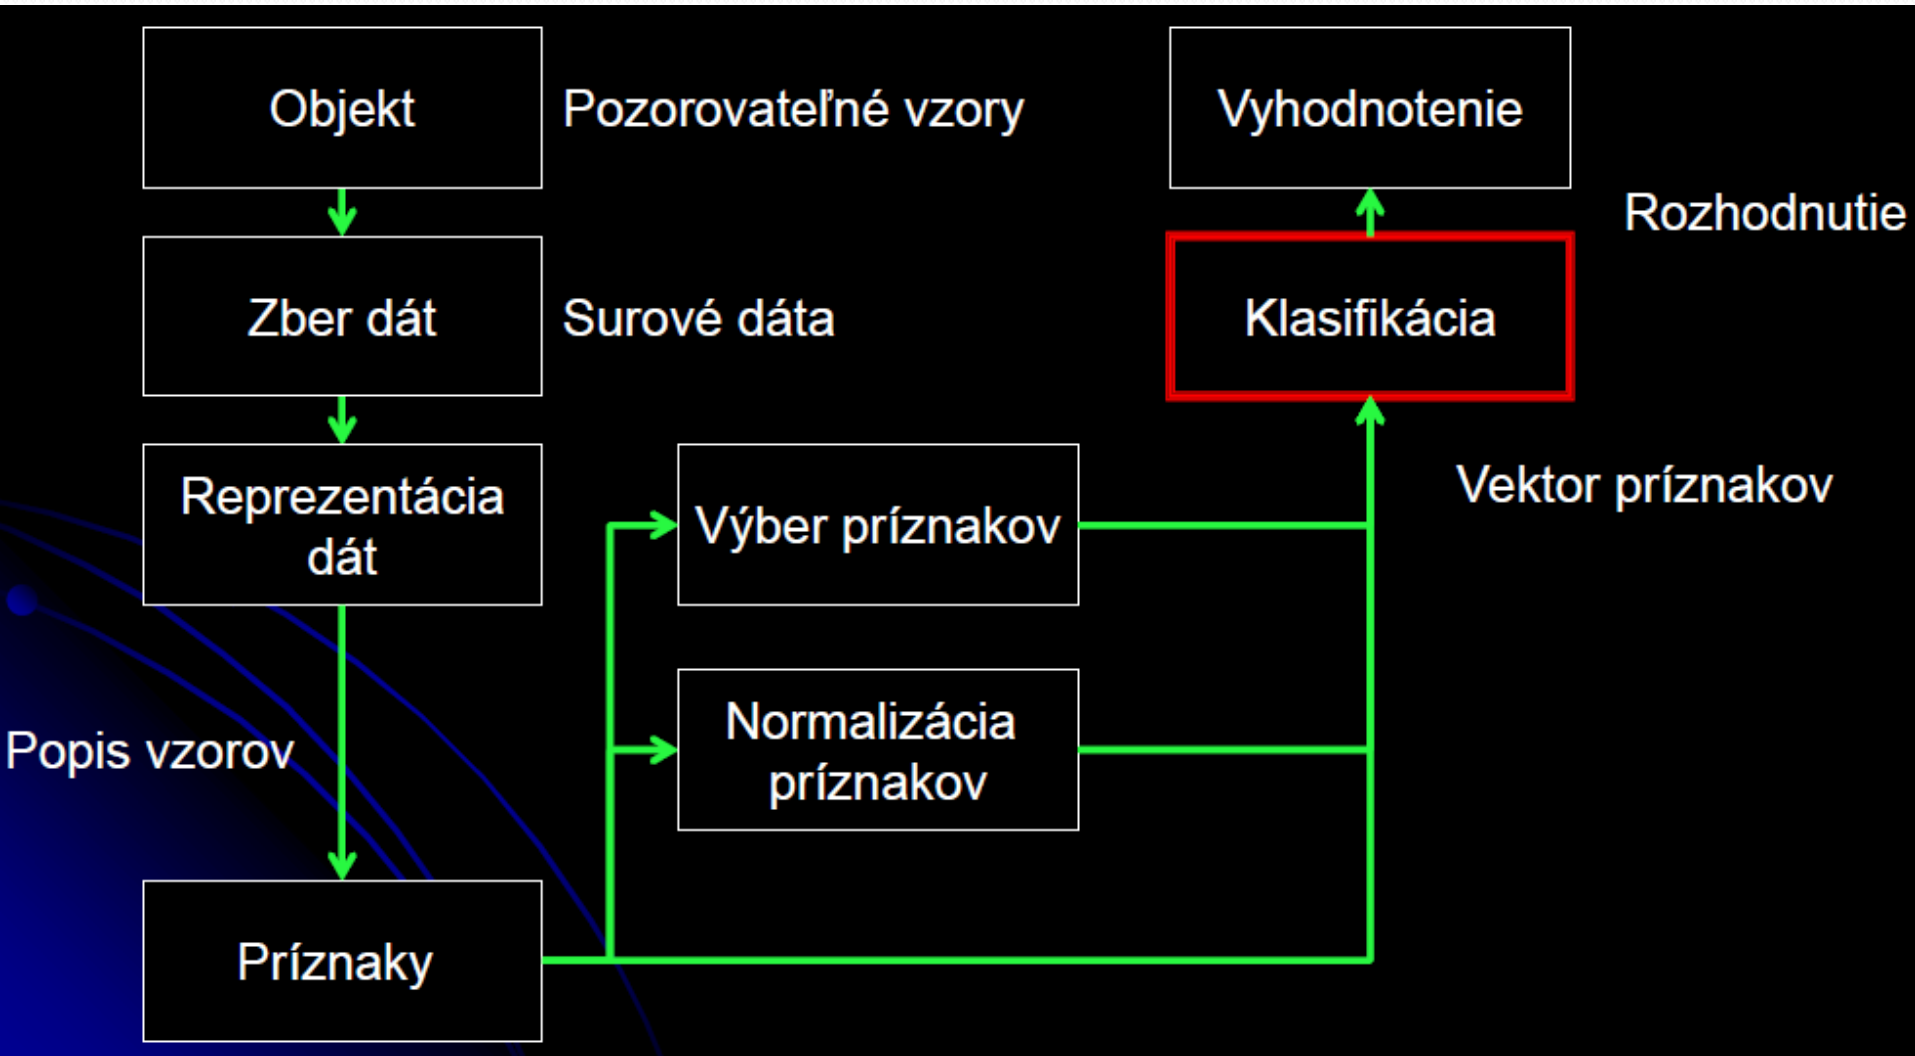


# Normalizácia príznačov

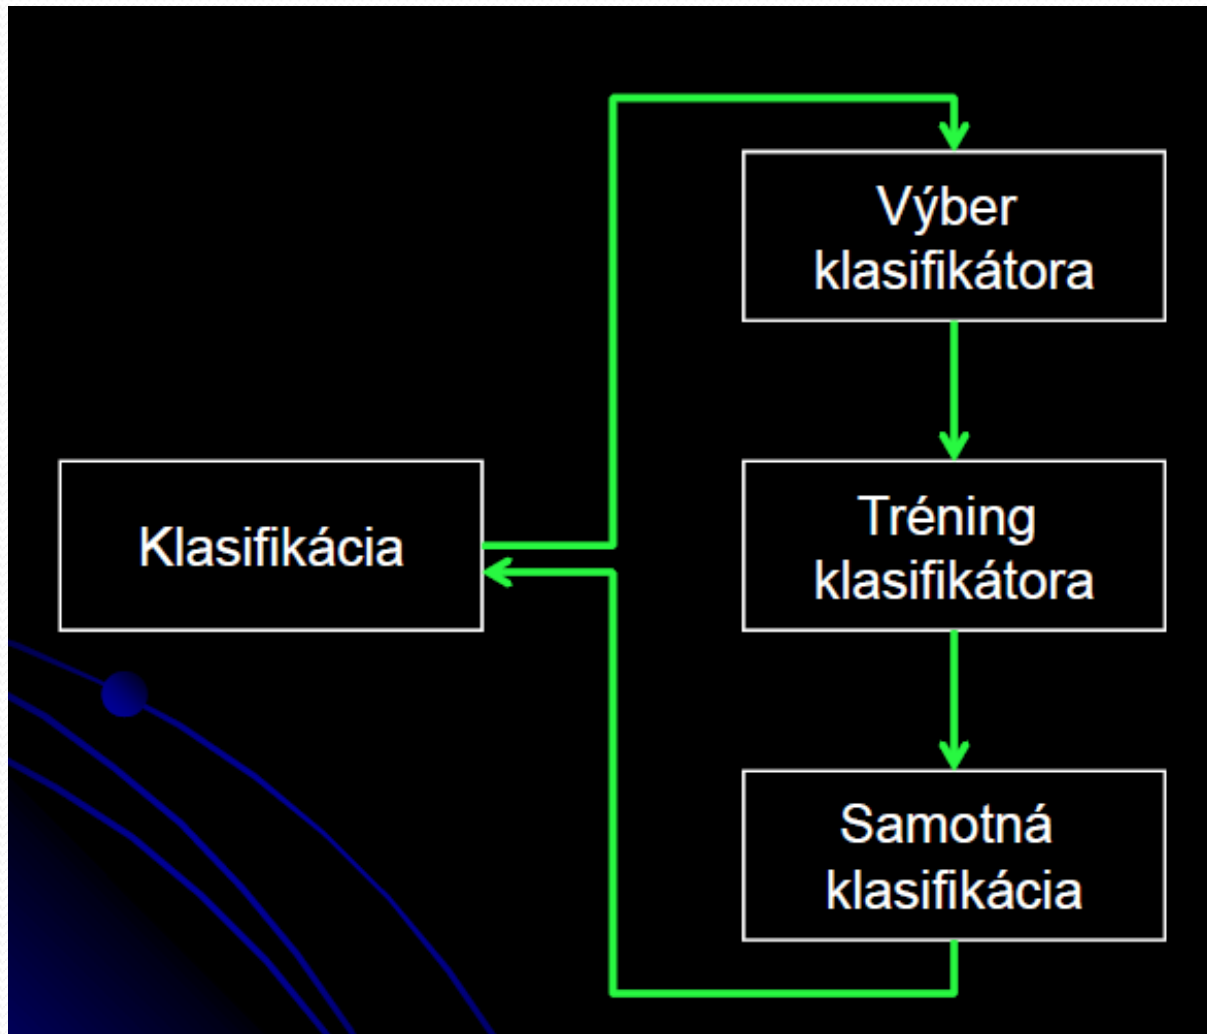
- Príznaky majú rozmer (cm, m, cl, ...)
- Výber jednotiek ovplyvňuje vzdialenosť v priestore príznačov
- Normalizáciou dostaneme bezrozmerné



# Rozpoznávanie



# Klasifikácia



# Tréning (učenie) klasifikátora

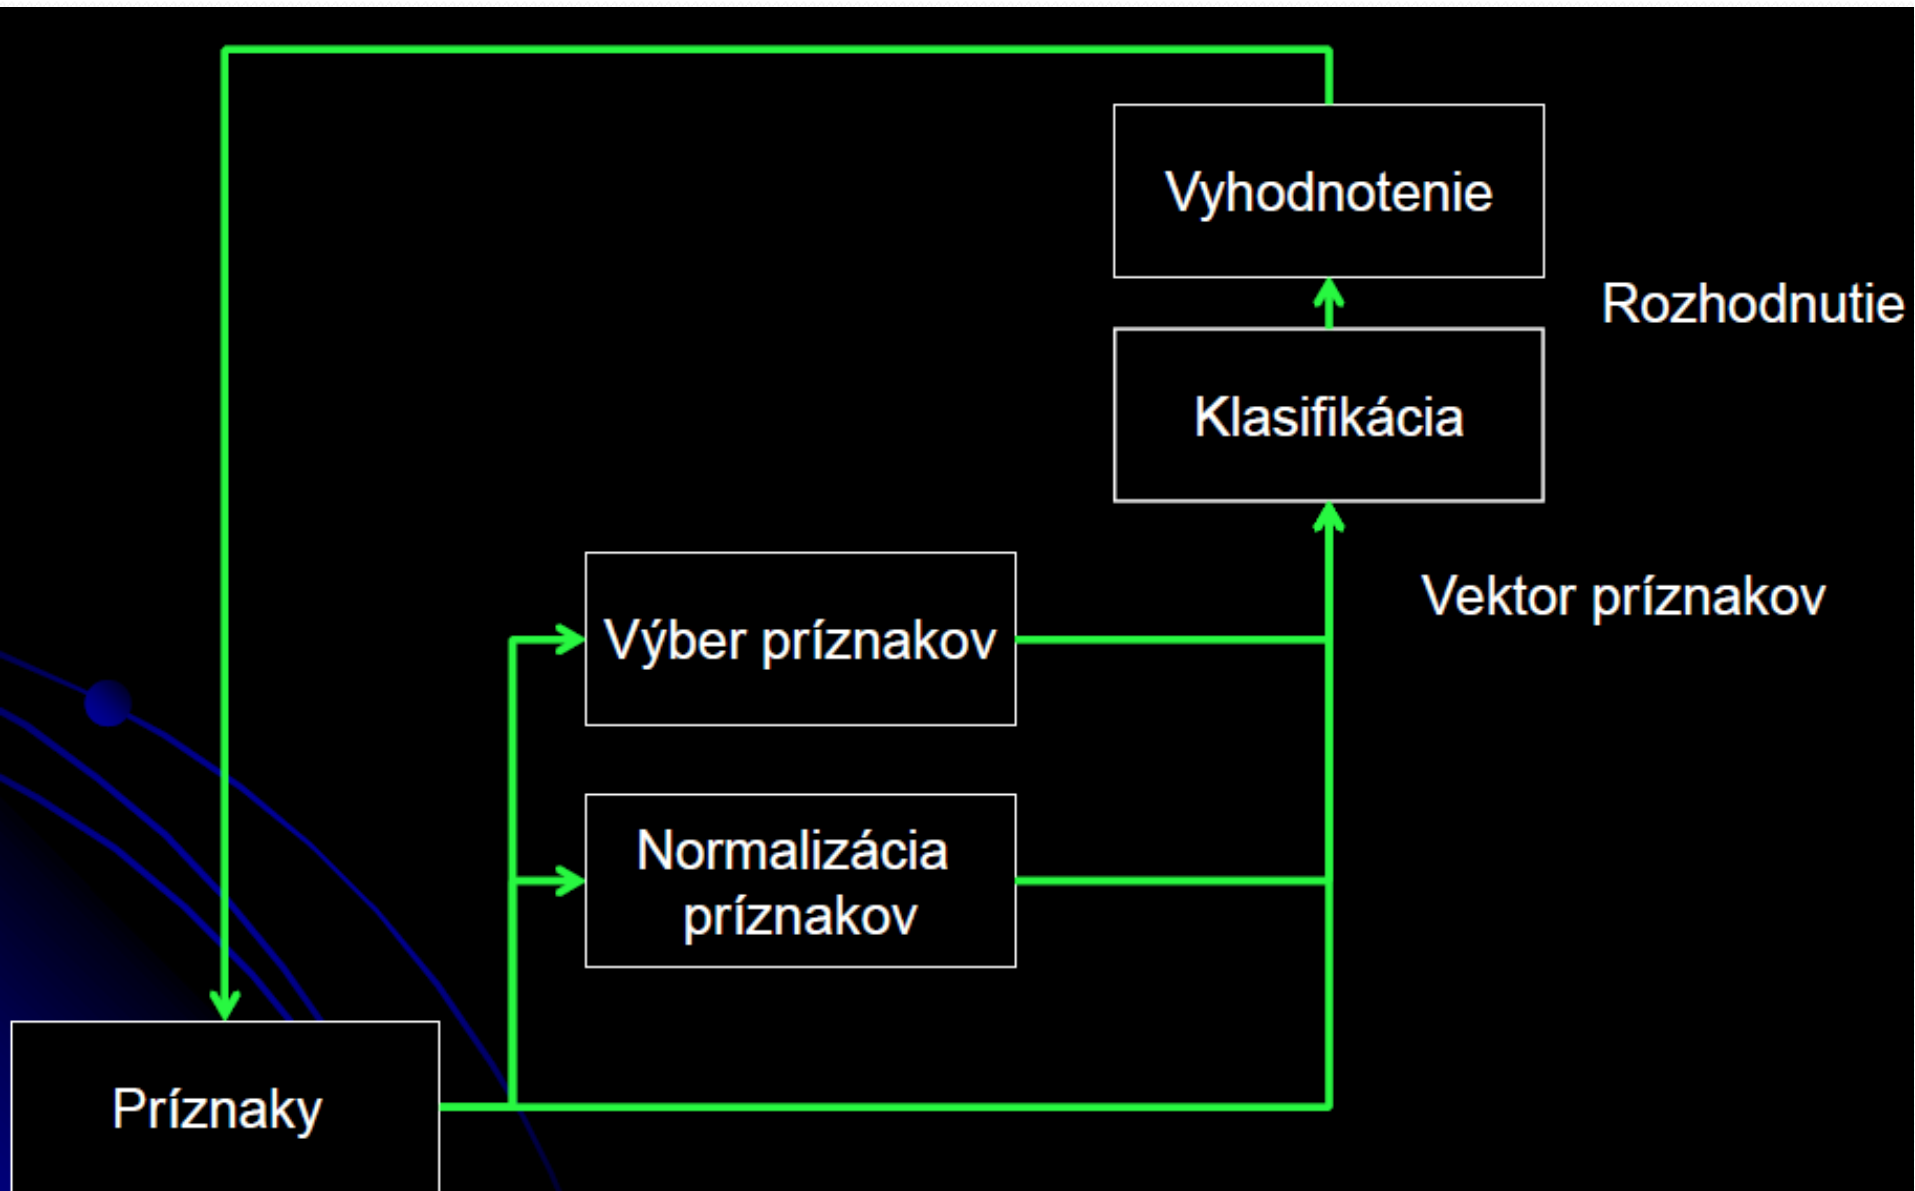
- Učenie s učiteľom:
  - Ak máme príznakové vektory a k nim označenie triedy, do ktorej patria
  - Vo fáze učenia klasifikátor postupne nastavuje parametre oddeľujúcich nadplôch
  - Pri neurónových sieťach sa pri učení nastavujú váhy jednotlivých spojení neurónov



# Tréning (učenie) klasifikátora II

- Učenie bez učiteľa
  - Ak nemáme takéto označenie a treba vytvoriť triedy bez pomoci učiteľa
  - Robí sa to pomocou tzv. zhlukovej analýzy, kde sa do tried zoskupujú príznakové vektory, ktoré sú blízko
- Ďalšie modifikácie učenia – napr. prenos učenia (transfer learning)

# Obsah prednášky



# Typy klasifikátorov

- Šablóny (PV)
- Príznakové metódy
  - Klasické techniky
- Neurónové siete
  - Konvolučné neurónové siete
- Syntaktické (štrukturálne) metódy

# Klasické (príznakové) metódy

- ***Štatistika***

- Bayesovská teória rozhodovania

- ***Vzdialenosti medzi príznakmi***

- Techniky najbližších susedov
- Diskriminačná analýza
- Mechanizmy podporných vektorov
- Metóda K priemerov


- ***Pravidlá***

- Rozhodovacie stromy

# Neurónové siete

- ***Biologicky inšpirované***
  - Neurónové siete
  - Samoorganizujúce sa mapy
  - Hlboké neurónové siete
- Neurónové siete vyžadujú veľké množstvo tréningových dát – od 100.000 vyššie
- Pri menšom počte dát – skôr klasické metódy alebo prenos učenia

# Aplikácie 1




Clustering of microarray data.

# Aplikácie 2



Building and building group recognition using satellite data.

# Aplikácie 3




Cancer detection and grading using microscopic tissue data.



# Aplikácie 4



Plain Arch



Tented Arch



Right Loop



Left Loop



Accidental



Pocket Whorl



Plain Whorl



Double Loop

Fingerprint recognition.

# Aplikácie 5

From  
Jim Elder  
829 Loop Street, Apt 300  
Allentown, New York 14707

Nov 10, 1999

To  
Dr. Bob Grant  
602 Queensberry Parkway  
Omar, West Virginia 25638

We were referred to you by Xena Cohen at the University Medical Center. This is regarding my friend, Kate Zack.

It all started around six months ago while attending the "Rubeq" Jazz Concert. Organizing such an event is no picnic, and as President of the Alumni Association, a co-sponsor of the event, Kate was overworked. But she enjoyed her job, and did what was required of her with great zeal and enthusiasm.

However, the extra hours affected her health; halfway through the show she passed out. We rushed her to the hospital, and several questions, x-rays and blood tests later, were told it was just exhaustion.

Kate's been in very bad health since. Could you kindly take a look at the results and give us your opinion?

Thank you!  
Jim

From  
Jim Elder  
829 Loop Street, Apt 300  
Allentown, New York 14707

Nov 10, 1999

To  
Dr. Bob Grant  
602 Queensberry Parkway  
Omar, West Virginia 25638

We were referred to you by Xena Cohen at the University Medical Center. This is regarding my friend, Kate Zack.


It all started around six months ago while attending the "Rubeq" Jazz Concert. Organizing such an event is no picnic, and as President of the Alumni Association, a co-sponsor of the event, Kate was overworked. But she enjoyed her job, and did what was required of her with great zeal and enthusiasm.

However, the extra hours affected her health; halfway through the show she passed out. We rushed her to the hospital, and several questions, x-rays and blood tests later, were told it was just exhaustion.

Kate's been in very bad health since. Could you kindly take a look at the results and give us your opinion?

Thank you!  
Jim

# Aplikácie 6



Rozpoznávanie tváre


# Aplikácie 7



Zrelosť úrody, triedenie potravín



# Aplikácie 8



Robotické zváranie, kontrola pri montáži

# Aplikácie 9





Autonómne autá, inteligentné riadenie dopravy

# Aplikácie 10



Humanoidné roboty

# Aplikácie 11



Diaľkový prieskum zeme (poškodenie lesa, rozsah rybolovu)



# Aplikácie 12



Určenie obrazu v galérii alebo na internete

# Aplikácie a aplikačné oblasti

Problémová oblasť	Aplikácia	Vstupný obrazec	Triedy obrazcov
Analýza dokumentu	OCR	Obraz dokumentu	Písmená, slová
Klasifikácia dokumentov	Hľadanie na internete	Textové dokumenty	Sémantické kategórie
Klasifikácia dokumentov	Filtrovanie SPAMov	E-mail	SPAM/OK
Výber z MM databázy	Hľadanie na internete	Videoklip	Žánre videa

# Aplikácie a aplikačné oblasti II

Problémová oblasť	Aplikácia	Vstupný obrazec	Triedy obrazcov
Rozpoznávanie reči	Asistent v telefóne	Rečová vlnová forma	Hovorené slová
Spracovanie prirodz. jazyka	Extrakcia informácie	Vety	Časti reči
Biometrické rozpoznávanie	Identifikácia osoby	Tvár, dúhovka, odtlačok	Autorizované osoby
Medicína	Asistovaná diagnostika	Obraz z mikroskopu	Rakovinová/zdravá bunka

# Aplikácie a aplikačné oblasti III

Problémová oblasť	Aplikácia	Vstupný obrazec	Triedy obrazcov
Armáda	Rozpoznanie cieľa	Viditeľný/IR obraz	Typ cieľa
Priemyselná automatizácia	Doska plošných spojov	Obraz intenzít	Kvalitný/nekvalitný prod
Priemyselná automatizácia	Triedenie ovocia	Obrazy z priem. pásu	Stupne kvality ovocia
Dial'kový prieskum zeme	Predpoved' úrody	Multispektrálny obraz	Kategórie úrovnosti

# Aplikácie a aplikačné oblasti IV

Problémová oblasť	Aplikácia	Vstupný obrazec	Triedy obrazcov
Bioinforma- tika	Analýza genómu	Postupnosť DNA	Známe typy génov
Dolovanie dát	Hľadanie zmysluplných	Body v mul- tiD priestore	Kompaktné klastre
Triedenie pošty	Rozpoznanie ručného PSČ	Sken obálky alebo balíka	Triedy PSČ podľa krajín
Autonómne autá	Rozpoznanie objektov	RGBD dáta	Typy objek- tov na ceste