

"Statistika"

bev.

most \neq máshol kurzus

\neq alkalmazható ipari/kutatási

inkább: fejlesztő a főbb változós stat. és MI kapcsolatáról
MI egyik része: - csoportosítás (clustering, pattern rec.) ^{ferm. tud.}

- osztályozás (classification)

- modellezés (pl. regression)

- egyes további (egy. vált. is)

klasszikus módszerek (átláthatóbbak, kevesebb adatra)

újabb módszerek (interpretáció? big data...)

deep learning egységek közül

előadás + tutoriálok + adathiértékelés

magamról... Szepesvári Pál...

tárgy átfedései

Hastie, Tibshirani, Friedman: The element of statistical learning

Cornell kurzus: Machine Learning for Intelligent Systems


Egyváltozós stat.-valószínűségi sűrűségfüggvények a hűtés ugalvher

kisérlet (random process) → esemény → valószínűségi változó

tudjuk ábrázolni ξ, X

fv. értékhalmaza
 diszkrét v. folytonos ⇒ $0, 1, 2, \dots$
 $1, 2, 3, 4, \dots$
 $168, 132m$
 összehasonlítás!

diszkrét val. vált. eloszlása



tf. 3. szegely...

k valószínűsége

$P_n = \lim_{n \rightarrow \infty} \frac{n_k}{n}$ ← et jön ki

↑ axiómák vannak rá

kumulatív:


$F(k) = P(X < k)$

$P(X \leq k)$

melésk?

$(= \sum_{x_i \leq k} P(x_i))$

"eloszlás fv."



vagy fordítva




folytonos:

histogram

eloszlás fv.

sűrűség fv.

pl. rel. gyak.



$P(a \leq X \leq b) = \int_a^b f(x) dx$

momentumai: számok, amik mondják az eloszlásról valamit

$\int_{-\infty}^{\infty} \left(\frac{1}{\sigma^n} \right) (x - E(x))^n f(x) dx$

↑ normálizált ↑ centrális

Várható érték

$$E(x) = \int_{-\infty}^{\infty} x f(x) dx \quad E(x) = \sum_{i=1}^n x_i p(x_i)$$

hol van

hoppó! $\bar{y} = \frac{\sum_{i=1}^n y_i}{N}$ ez min \leftarrow statisztika \leftarrow statisztika

sokaság, minta

statisztika: mintából \rightarrow sokaságról mondjuk valamit, hogyan vannak, utána a valószínűségi eloszlásot.

sűrűségfüggvény = variancia

$$\sigma^2 = \int_{-\infty}^{\infty} (x - E(x))^2 f(x) dx$$

terjedelelem

$$s^2 = \frac{\sum_{i=1}^n (y_i - \bar{y})^2}{N-1} \quad s = \sqrt{s^2}$$


\bar{y}, s^2, s ~~itt~~ \leftarrow új példa a távolsághoz

\bar{y}, s^2, s becült a mintából, pl. becült sűrűség

Robusztus becülés: hibás adat kevésbé befolyásol

median, alsó-felső kvartilis, interkvartilis táv,

boxplot:



Tukey

** \leftarrow kihagyó adat (med $\pm 1,5$ iht-on kívül)
 \leftarrow eldobható adat ($\pm 2,5$)

Eloszlások: binomiális, Poisson, exponenciális, normál, egyenletes...

 χ^2, F, t származtatott

$$f(x) = \frac{1}{\sqrt{2\pi}\sigma} \cdot \exp\left(-\frac{(x-E)^2}{2\sigma^2}\right) \quad F(x) = \text{erf. f.}$$

Ferdesség, csúcsosság, variancia koefficiens: $\frac{s}{\bar{y}}$

Adattípusok:

metrikus (diszkrét, folytonos) - intervallum vagy arányos

kategorikus - nominális A, B, C - ← hot encodinggal

bináris 0,1

bináris

sorrendbel: +, ++, +++ → pl. vegyszer "zöldisége"

Többváltozós adatok tere:


$X, y \rightarrow D^{N \times M}$ mátrix

sor: objektum, eset


oslop: tulajdonság (T, P, V, H, cm³)

vagy hipermátrix (tömb)
2D <

$$O_1 \begin{pmatrix} v_1 & v_2 \\ 1 & 2 \\ 3 & 4 \end{pmatrix}$$



változóh tere



objektumok tere

függő adat - valamit beírni, ha kell

Centrális - oszlopátlag 0 lesz

Skálázás - pl. min-max → 0,1, vagy osztás sűrűséssel

standardizálás → $\frac{y_i - \bar{y}}{s_y} \rightarrow \mathcal{N}(-3; 3)$, ha Gauss $\frac{d_{ij} - \bar{d}_j}{s_j}$

variancia $s_j^2 = \frac{\sum (d_{ij} - \bar{d}_j)^2}{N-1} \quad [0, +\infty)$

kovariancia $s_{jk} = \frac{\sum (d_{ij} - \bar{d}_j)(d_{ik} - \bar{d}_k)}{N-1} \quad (-\infty, +\infty)$

korreláció $r_{jk} = \frac{s_{jk}}{s_j \cdot s_k} \quad [-1, 1]$

$r_{jk} = \cos$ of v_1, v_2 vectors in object space

$r_{jk} = 1$ v. $-1 \Rightarrow$ kollináris

Gram mátrix: $G = D^T D$ kov.mátrix: $C^{M \times M} = \frac{D_c^T D_c}{N-1}$

korrelációs mátrix: $R = \frac{D_{st}^T D_{st}}{N-1}$

Objektumok a változó térben:



távolság:

~~$d_{ij} = |x_i - x_j|$~~ $\underline{x}_{ij} = \underline{x}_i - \underline{x}_j$



Eukleidés:


$$d_E = \sqrt{\underline{x}_{ij}^T \underline{x}_{ij}}$$



$$d_{Pearson} = \sqrt{\underline{x}_{ij}^T S^{-1} \underline{x}_{ij}}$$

$S = \begin{pmatrix} s_1^2 & 0 \\ 0 & s_2^2 \end{pmatrix}$ variánciák

Mahalanobis-távolság és létkorrelált változókra:




forgetásod és skálázása!

Mah. táv. Eu. térben = Eu. táv. Mah. térben

$$d_M = \sqrt{\underline{x}_{ij}^T C^{-1} \underline{x}_{ij}}$$

Manhattan (city block táv.)



$$d_{CB} = \sum_{n=1}^M |x_{in} - x_{jn}|$$

távolság mátrix (N x N)


$$\begin{pmatrix} 0 & a_1 & \dots & a_1 \\ a_1 & 0 & & 0 \\ \vdots & & \ddots & \\ a_n & & & 0 \end{pmatrix} \quad [0, \infty)$$

hasznosítás

$$\frac{1}{1+d_{ij}} \text{ vagy } 1 - \frac{d_{ij}}{d_{max}} \quad [0, 1]$$

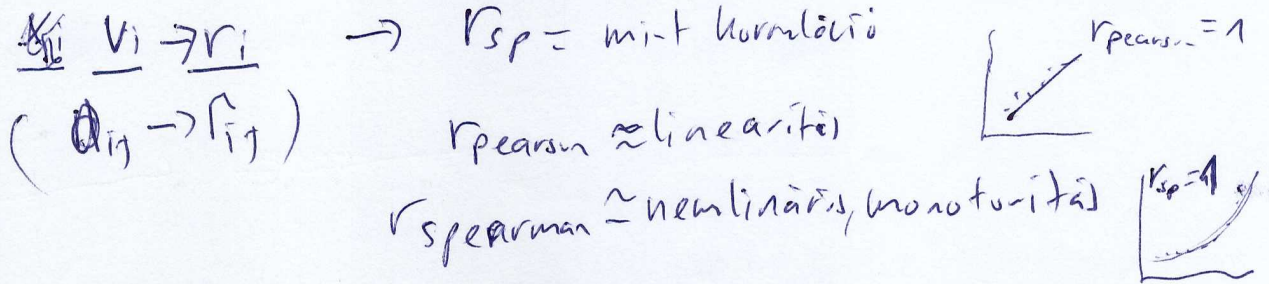
bináris adatok távolosága és hasonlósága:

TV.terc 3.

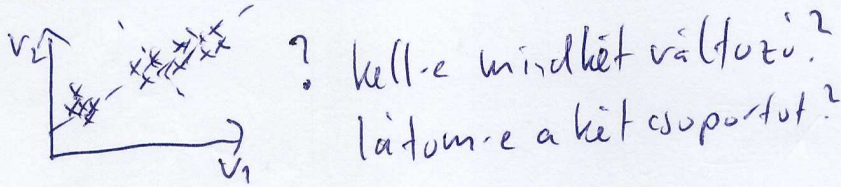


rang: sorrend 1...N

Spearman rangkorreláció két változó között



Főkomponens-elemzés:




$v_1, v_2 \rightarrow$ más bázisra átváltás $\dots \rightarrow$ bázistranszformáció

Felbontás $D^{N \times M} = T \cdot P^T$

\uparrow score loading
 új bázisban az értékek \uparrow régi változók súlya

$$\begin{matrix} \underline{t}_i^T \underline{t}_j = 0 \\ \underline{p}_i^T \underline{p}_j = 0 \end{matrix}$$
 \uparrow merőleges



matematikai, több példán, pl. SVD de PCA

$C = \frac{D_c^T D_c}{N-1}$ diagonálizálással (sorjótörkeli esze-let)

$$C = \underbrace{Z}_{+} \cdot \underbrace{\lambda}_{+} \cdot \underbrace{Z^{-1}}_{P^+}$$

$Z^{-1} = Z^T$ ha valódi szimmetrikus (Ca)
 $a \leq \text{rank}(C)$


Összvariancia:

$$\sum S_j^2 \rightarrow C_i (S_j^2) \rightarrow$$

átlós elemek összege
 megmarad

$$\lambda = \begin{pmatrix} \lambda_1 & & 0 \\ & \dots & \\ 0 & & \lambda_m \end{pmatrix}$$


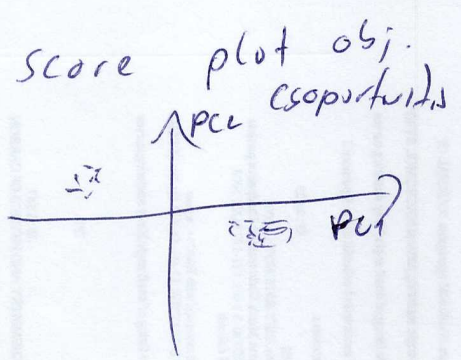
összvariancia



megmaradt összvariancia

$$\frac{\sum_{i=1}^a \lambda_i}{\sum_{i=1}^m \lambda_i} \rightarrow \text{pl. } 95\%$$

Mirejő:



pl: porolitis \rightarrow 5 anyag \rightarrow 2 főkomponens \rightarrow 2 mechanizmus 2 anyagcsoport
 összedől

Spektralanalízis, ~~kompozit~~ velt. \rightarrow PC-k a fő változókat \in modell rá

olajkutatás: két főkomponens: kelaini, ~~kvart~~ tenges kénészű pár
 gránit: fő kőzeteser főkomponens $(\text{SiO}_2 + \text{K})$, $(\text{Al}_2\text{O}_3 + \text{IV})$, $\text{Fe}_2\text{O}_3 - \text{FeO}$, $\text{Na} - \text{K}$
 gránit albrt oxid. alkali
 \downarrow térkép

Prinos Dacia

PCA → változik számának csökkenése (dim. csök.)

clust 1.

→ változik köztük kapcsolatok

→ objektumok csoporthozítása (klaszterezés, mintázat felismerés)


↑
unsupervised learning (nem felügyelt, felügyelet nélküli;
nem ellenőrzött...)

Hierarchikus klaszterezés:

- min t_{ij} a T távolságmátrixból ($N \times N$ a kezdetben)
- két közeli klaszterba vonása
- $(N-1) \times (N-1)$ T kiámulás

Kérdések: klaszter-klaszter távolság? ~~átlag~~, min, ~~max~~ \approx linkage
távolságmétriKA (eu, Mah, max...)


$$S \rightarrow 1 - \frac{t_{ij}}{t_{max}}$$



K-mean klaszterezés: c_g klaszter közepét n_g adott oda tartozók

$$\min \sum_g \sum_{i \in g} (x_i - c_g)^T (x_i - c_g) \text{ keresése}$$

\approx Wigner-Seitz vagy Voronoi cella \Rightarrow tér felosztása



ki, hol, mennyire kompakt cellában, szilárd

hány csoport \rightarrow nézetesség!

k-nearest-neighbour (Farvis-Patrick)

clust 2.

$T \rightarrow$ szomszéd mátrix adott szomszédainig (k)

i és j minimum k közös szomszédja $\Rightarrow i$ és j egy csoport

pl. i, j egy csoport és j, l is $\Rightarrow i, j, l$ egy csoport

pl.: $k = \frac{N}{2}$ $M = \frac{N}{4}$ ← használatos

k, M próbálkozások.

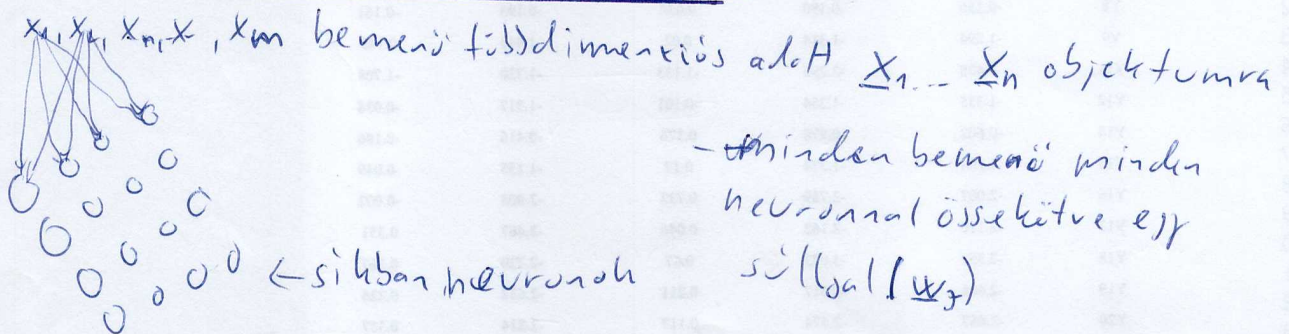
PCA: virtuális deszák síkja

Hierarchikus k -mean, k nn: adott érték felbontása...

elmosódott határ: pl. fuzzy (életl.) klaszterezés \rightarrow hi hová csak $\%_{0-100}$

legyen 2D képernyő: self-organizing map = SOM

\approx nem felügyelt neurális háló - Kohonen térkép



súlyok változtatása úgy, hogy ~~súly~~ súlyértékük is adott x_i értékek használatát legyenek: x_i a leghasználtabb súly w_{ij} súlyra hat + a környező w_{ik} is hatnak.

~~for~~ input vector (random choice)

minimizing $(x_i - w_{ij})^T (x_i - w_{ij})$ → hibafüggvény

Környék és hibafüggvények: $w_{ij}(s+1) = w_{ij}(s) + \eta_{ij} (x_i - w_{ij})$

○ ○ ○ → adott objektumok 1-1 neuronra

○ ○ ○ ○ ← adott neuron súlyai vagy átlagos x bemenő adatok


○ ○ ○ ○

Osztályozás - Klasszifikáció

(11)

felügyelt tanulás

prediktor
mátrix
feature
deskriptor




$y \in \{1, 1\} \{0, 1\}$ bináris \leftarrow one class (spam)
 $\{0, 1, 2, \dots, 5\}$ osztályok \leftarrow multiclass (iris)
 classes
 $y \in \mathbb{R}$ regresszió
 (árfolyam)
 (nyár)
 (költség)

Célok: - ismert $X \rightarrow y$ ra modellezés, alkalmazás, ahol csak X ismert
 - modell értékelése: \rightarrow súlyok, elválasztó felületek
 \rightarrow adott objektumok \leftarrow modell kiterjesztése

leggyakoribb ötletek:

k-legközelebbi szomszéd:



pl. $k=4 \rightarrow 1 \rightarrow X$
 $2 \rightarrow 3 \text{ or } 1x$

Honnan tudjuk, jó-e a modell?

osztályozási - klasszifikációs táblázat

pl: keresztellenőrzés (pl. eszeletem kihagyásos) CV-LOO, vagy k-fold

valós

	1	2	3	
1	50	0	0	\leftarrow osztályozott □ jól ○ hibásan
2	0	48	2	
3	0	1	49	

példa $Z=150$
 $50/50/50$
 $1 \ 2 \ 3$

+ vesztésmátrix

$$\begin{bmatrix} 0 & 0 & ? \\ ? & 0 & 0 \\ \vdots & \vdots & \vdots \end{bmatrix}$$





$\Rightarrow \Sigma \Rightarrow$ közhézet

hiba arány $\frac{\Sigma 0}{\text{összes}} \Rightarrow \frac{3}{150}$

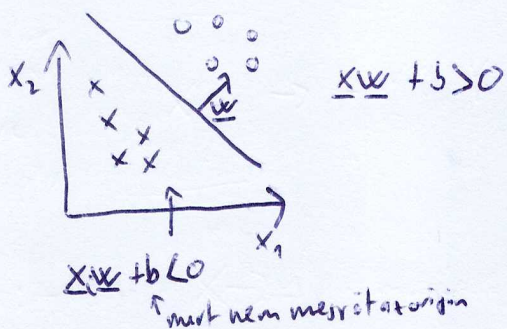

referencia hiba: $1 - \frac{N_{max}}{N} \leftarrow$ mindent jóra

k-legközelebbi szomszédnál 2D, 3D, ... sok D \leftarrow találsz-e problémát

$dis = \sqrt{x_{i1}^2 + x_{i2}^2 + x_{i3}^2 + \dots} \leftarrow$ nagy távolság lesz, a "rohant"



pontok közt távolság helyett határoló síkhoz, hipersíkhoz való távolság;



→ ha növeltem +1-szel adimenzióit.


$$\begin{bmatrix} x_i \\ 1 \end{bmatrix} \leftarrow \begin{matrix} 0 \\ x_i \end{matrix}$$

$$\begin{bmatrix} w \\ b \end{bmatrix} \leftarrow w \quad x_i w \leq 0$$

előjele adja!

Hogyan találjuk meg az elválasztó felületet?

Perceptron algoritmus: felvevő algoritmus elemek segítségével iteráljuk w -t, amíg nem lesz felvevő algoritmus



konvergenál!

max M lépésben



$$M \leq \frac{1}{\gamma^2} \leftarrow \text{seles margó a jobb}$$

Támogató vektorok módszere Support vector machine

kb. ez, de maximális margó mindkét oldalra + további képszeres....

↓
Knn-
tömegalapja.

↓
krit. SVM
kritikus helyzetben levő
alapián, ← ezekre megy
a támogató vektor

nemilyen egyszerű, vannak akik rossz oldalon lesznek,
szó további dolog....

Hol volt itt a valószínűség és statisztika? Na most lesz!

Feltételes valószínűség (posterior) Bayes

$$P(A|B) = \frac{P(A|B)}{P(B)} \leftarrow \begin{matrix} \text{szóval } P(A, B) \text{ közt is pl. } P(X, y) \\ \text{közös} \end{matrix}$$

$$P(A|B) = P(B|A) \cdot \frac{P(A)}{P(B)} \quad \text{Bayes tétele}$$

$P(X, y)$ -t keressük a modellünkkel maximálni, modell paraméter w

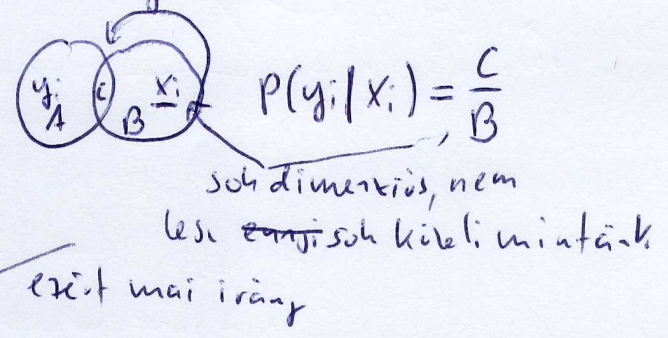
Maximum likelihood estimate (discriminative)

$P(y|X, w)$ w keresése, ahol ez maximumod ad (keretből)

$y \rightarrow y_i \quad X \rightarrow x_i$, függetlenség

$$= \prod_{i=1}^n P(y_i|x_i, w)$$

Venn-diagram



Maximum posterior estimate

w elonlással rendelkező valószínűségi változó


$$P(w|X, y) \approx P(y|X, w) \cdot P(w)$$

$$P(x_i|y_i) = \frac{C}{A} \leftarrow \begin{matrix} \text{alacsony dimenziós} \\ \text{sőt elméleti értelemben} \\ \text{pl. dobószóval } 1/2 \text{ } 1/4 \\ 1/6 \end{matrix}$$

posterior

$$P(y_i|x_i) = \frac{P(x_i|y_i) \cdot P(y_i)}{P(x_i)} \leftarrow \begin{matrix} \text{szóval becsülhet} \\ \text{feltételek} \end{matrix}$$

Mi volt a \underline{w}



$(\frac{w}{n})$ formában

CL4

$\underline{w}^T \underline{x} \rightarrow$ előjele mindig support $y_i \in \{-1, +1\}$

MLE-vel:
$$p(y_i | \underline{x}_i) = \frac{1}{1 + e^{-y_i \underline{w}^T \underline{x}_i}}$$

discriminativ

↓ mat min. kereszt loss (or után, (- előjelek))

$$\log \left(\prod_{i=1}^n p(y_i | \underline{x}_i, \underline{w}) \right) = - \sum_{i=1}^n \log(1 + e^{-y_i \underline{w}^T \underline{x}_i})$$

$$\hat{\underline{w}}_{MLE} = \underset{\underline{w}}{\operatorname{argmin}} \sum_{i=1}^n \log(1 + e^{-y_i \underline{w}^T \underline{x}_i})$$

logisztikus regresszió

MPE-vel
$$\hat{\underline{w}}_{MAP} = \underset{\underline{w}}{\operatorname{argmin}} \sum_{i=1}^n \log(1 + e^{-y_i \underline{w}^T \underline{x}_i}) + \lambda \frac{\underline{w}^T \underline{w}}{2\sigma^2}$$

generativ

$\frac{1}{2\sigma^2}$

$$\underline{w} \sim N(0, \sigma^2 I)$$

lényeg: + tag

+ házmintánál fontos

+ segid fel tételekkel elvonalashoz

Naive Bayes

Diszkriminancia analízis - régi módszer (régí alapmódszer)

felt. adatok csoporton belül Gauss eloszlásúak (főssdim)

g osztály $\underline{c}_g \leftarrow$ centruma C_g kovarianciája


felt. valószínűség maximálása, hogy odatartható:

$$p(g|\underline{x}_i) = \max_g \frac{n_g/N}{|C_g| \sqrt{2\pi}} \cdot \exp\left(-\frac{1}{2} (\underline{x}_i - \underline{c}_g)^T C_g^{-1} (\underline{x}_i - \underline{c}_g)\right)$$

\approx Mahalanobis táv.

log. formában sokkal kevesebb

diszkriminációs távolság
í-dik elem megjelöl csoporthoz tart.
határnál $D_A \approx D_B$



C_g egyforma Lináris diszkriminancia analízis
LDA

C_g csoportként különböző ~~kvadratis~~ kvadratis his diszk. anal.
QDA

Döntési fáh módszerek

CART-classification

(1-6)

- A hozott osztályozás az objektumokhoz egy-egy változó érték alapján. Osztás alapja: legyen egy nagy és egy kicsi diverzitási csoport

↑
heterogén
az osztályokra

↑
homogén
az osztályokra

diverzitás mérése: Gini-index

$n_1, n_2, n_3, \dots, n_m$ - km osztályelemek száma $\sum_{i=1}^m n_i = N$ $p_i = \frac{n_i}{N}$

$$Gini = \sum_{j=1}^m \sum_{k \neq j}^m p_j p_k = \frac{1}{N^2} \sum \sum n_j n_k$$

$Gini = 0$ ← csak egy osztály van az adott végcsúcsban az egyháromban

$$\max Gini = \frac{(1 - \frac{1}{m})}{2} \rightarrow Gini / Gini_{\max} \in [0, 1]$$

$$Gini \Leftrightarrow \text{Shannon } H = - \sum_{i=1}^m p_i \ln p_i$$

↑
lineáris
súly

↑
logaritmus
súly

$$p_1 = 1 \quad p_{1+1} = 0$$

↓
 $H = 0$

$$p_i = \frac{1}{m} \quad H = \max$$