

Úvod do strojového učenia

Machine learning

Zuzana Rošťáková

23. september 2021

Seminár ÚM


Doplňková literatúra I

- James G., Witten D., Hastie T., Tibshirani R. (2021)
An Introduction to Statistical Learning: with applications in R.
Springer. Second Edition. ISBN: 978-1-0716-1417-4.
<https://doi.org/10.1007/978-1-0716-1418-1>
 - detailný popis vybraných metód strojového učenia
 - príklady na reálnych dátach v štatistickom softvéri R
<https://link.springer.com/content/pdf/10.1007%2F978-1-0716-1418-1.pdf>
- Everitt B. S. (2005)
An R and S-plus Companion to Multivariate Analysis
Springer. ISBN 978-1-85233-882-4.
<https://doi.org/10.1007/b138954>


Doplnková literatúra II

- elektronické zdroje k predmetu *Analýza zhlukov a klasifikácia dát* od doc. Mgr. Radoslava Harmana, PhD.
 - <http://www.iam.fmph.uniba.sk/ospm/Harman/VSAp.pdf>
- Lamoš, F., Potocký, R. (1998)
Pravdepodobnosť a matematická štatistika (štatistické analýzy)
Univerzite Komenského, Bratislava. ISBN: 80-223-1262-2
- Mohammed, M., Khan, M. B., Bashier, E. B. M. (2016).
Machine learning: algorithms and applications.
Crc Press. ISBN: 978-1-31537-165-8
<https://doi.org/10.1201/9781315371658>
 - príklady implementácie jednotlivých metód v MATLAB-e

Machine learning - strojové učenie








Machine learning - strojové učenie



Učenie bez učiteľa - unsupervised learning


- cieľ:
 - **redukcia dimenzie:** nájsť menší počet skrytých (latentných) premenných
- **zhluková analýza:** nájsť skryté podskupiny podobných pozorovaní



Učenie s učiteľom - supervised learning

- cieľ:

- **klasifikačná analýza:** vytvoriť model, ktorý by na základe vstupných údajov zaradil pozorovania do skupín



- **regresná analýza:** nájsť vzťah medzi vstupnými premennými a výstupnou premennou (premennými)

$$Y = X \beta + E$$

Vizualizácia mnohorozmerných dát

Vizualizácia mnohorozmerných dát


- pozorujeme p premenných na n objektoch
- **dáta:** matica X o rozmere $n \times p$

$$X = \begin{bmatrix} & x_1^T & \\ & x_2^T & \\ \vdots & & \\ & x_n^T & \end{bmatrix} = \begin{bmatrix} | & & & | \\ x_1^* & x_2^* & \dots & x_p^* \\ | & | & & | \end{bmatrix} \in \mathbb{R}^{n \times p}$$

- $x_i = (x_{i1}, x_{i2}, \dots, x_{ip})^T$
→ vektor hodnôt p premenných pre i -ty objekt, $i = 1, \dots, n$
- $x_l^* = (x_{1l}, x_{2l}, \dots, x_{nl})^T$
→ vektor hodnôt l -tej premennej, $l = 1, \dots, p$ pre n objektov
- pred samotnou analýzou je vhodné získať určitý **obraz** o dátach
- rôzne prístupy k vizualizácií p -rozmerných dát

Histogram

- sĺpcový diagram
- základňa každého obdĺžnika diagramu má dĺžku zvoleného intervalu
- výška každého obdĺžnika je rovná počtu pozorovaní, ktoré patria do zvoleného intervalu
- MATLAB: *histogram(x, vektor_hranic_intervalov)*



Histogram - Príklad: Dotazníky

- 148 ľudí, 2 noci v spánkovom laboratóriu → 296 pozorovaní [Rosipal et al., 2013]
- večer a ráno vypĺňali dotazníky ohľadom ich subjektívneho stavu


→ **9 premenných**

- Self-rating questionnaire for sleep quality, awakening quality and somatic complaints (s_qua, a_qua,s_com)
- Well-being self-assessment scale evening/morning (wb_e, wb_m)
- Visual analog scale test for drive, mood, affectivity and drowsiness (drive, mood, aff, drows)

Histogram - Príklad: Dotazníky


- každú premennú osobitne znázorníme pomocou histogramu

$histogram(data, 0 : 2 : 100)$




Boxplot - krabicový graf

- autor: John Tukey (navrhnuté 1970, publikované 1977)
- medián, minimum, maximum
- prvý (Q_1 , 25%-ný kvantil) a tretí kvartil (Q_3 , 75%-ný kvantil)
- $IQR = Q_3 - Q_1$, medikvartilové rozpäťie
- whiskers (fúzy) = $1.5 \times IQR$ (alebo vlastná definícia)




Boxplot - krabicový graf



Boxplot - Príklad: Dotazníky

- `boxplot(data, 'labels', variable_names)`




Scatterplot

scatter(x, y)

alebo


plot(x, y, 'o')



Heatmap

- vizualizácia korelačnej matice dát
- $R = \text{corr}(\text{data})$
 - $p \times p$ matica
 - R_{ij} = korelácia medzi i-tou a j-tou premennou
- $h = \text{heatmap}(xval, yval, R)$
 - $xval, yval$ = označenie premenných na osi x, y
 - $R = p \times p$ korelačná matica

HeatMap - Príklad: Dotazníky




Mnohorozmerné škálovanie

- transformácia p -rozmerných dát do "2D" pre lepšiu vizualizáciu
- v MATLAB-e:
 - ➊ matica vzájomných vzdialenosí pomocou funkcie `pdist`
 - $D = pdist(X, 'metric') \rightarrow n \times n$ matica
 - 'metric' = euclidean, squaredeuclidean, cityblock, correlation, ...
 - ➋ mnohorozmerné škálovanie pomocou funkcie `cmdscale` (*classical multidimensional scaling*)
 - $Xd = cmdscale(D, pocet_dimenzií)$
→ ak chceme dáta len v "2D", tak `pocet_dimenzií = 2`
 - ➌ vykreslenie dát v "2D"
 - `scatter(Xd(:,1),Xd(:,2))`



Mnohorozmerné škálovanie - Príklad: Kocka

- $X \in \mathbb{R}^{8 \times 3} \rightarrow$ kocka so stredom v $[0,0,0]$
- vykreslene pomocou funkcie $plot3(x, y, z)$





Mnohorozmerné škálovanie - Príklad: Kocka

- kocka v 2D pomocou funkcie *cmdscale*



Mnohorozmerné škálovanie - Príklad: Kocka


- kocka v 2D pomocou funkcie *cmdscale*



Mnohorozmerné škálovanie - Príklad: Potraviny

- 25 krajín Európy
- 9 premených (v mil. ton):
 - červené mäso - hovädzie, bravčové, ...
 - biele mäso - hydina, ...
 - vajíčka
 - mlieko
 - ryby
 - obilniny
 - potraviny obsahujúce škrob - zemiaky, ...
 - orechy
 - ovocie, zelenina
- staršie dáta (Juhoslávia, Československo, ...)
- zdroj:
<http://www.iam.fmph.uniba.sk/ospm/Harman/data/nutrition.txt>

Mnohorozmerné škálovanie - Príklad: Potraviny



Otázky ?

Literatúra



Rosipal, R., Lewandowski, A., and Dorffner, G. (2013).
In search of objective components for sleep quality indexing in normal sleep.
Biological Psychology, 94(1):210–220.