

# Adatelemzés

2017-2018 őszi félév

2018.03.19,26,27

1. Bevezetés
2. Osztályozás és klaszterezés feladata
3. Numpy és Ipython
4. Logisztikus regresszió

# Elérhetőségek


Daróczy Bálint


[daroczyb@ilab.sztaki.hu](mailto:daroczyb@ilab.sztaki.hu)

Személyesen: MTA SZTAKI, Lágymányosi u. 11

Tantárgy honlapja:

<http://cs.bme.hu/~daroczyb/Adatelemzes2018/>





# Következő hetek


Március 19: bevezetés, osztályozás-klaszterezés,  
kiértékelés, kNN

Március 26-27: logisztikus regresszió, SVM, kernelek

Április 2: húsvét

Április 9-10: MLP, CNN, RNN

Április 16: Bayes hálózatok, Boosting



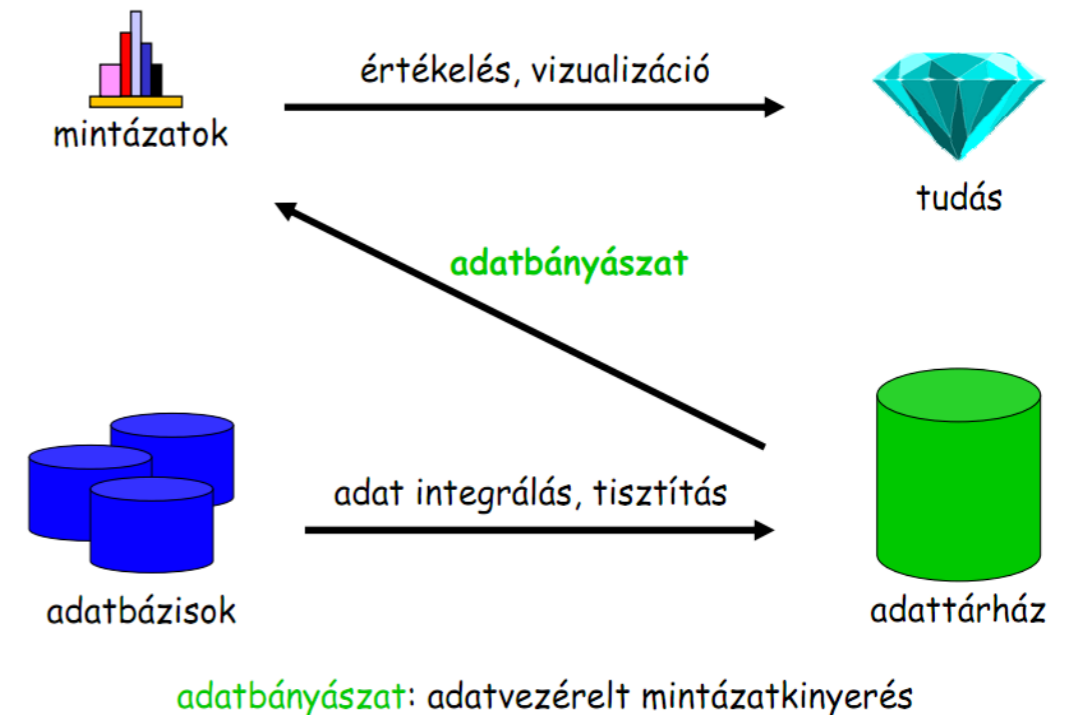
# Adatbányászat feladatai


Adatbányászat (Data Mining):

- nagy adathalmazokon
- nem triviális (implicit, eddig ismeretlen) információ
- Strukturális minták kinyerése

Knowledge discovery in databases (KDD)

- ismeretszerzés adatbázisokból
- adat/mintázat vizsgálata
- összefüggések azonosítása
- stb.





# Kicsit bővebben

Jobbról balra.....

NETFLIX

## 1. Keresés (IR)

- szöveg, kép, videó, hang stb.

## 2. Ajánló rendszer (RecSys)

- user-item ajánlás
- link-prediction

## 3. Szociális hálózatok

- de-anonymizálás
- barát/termék ajánlás
- reklám mérő

## 4. Klasszifikációs problémák

- szöveg/kép/videó/hang annotálás
- spam detekció
- bioinformatika

## 5. Big Data


- Entity Resolution
- log elemzés

Google Magyarország

amazon

YAHOO!





# Kicsit bővebben

Balról jobbra.....

## 1. Klasszifikációs problémák:

- döntési fák, fa alapú algoritmusok
- Bayes network
- perceptron, logistic regression
- Artificial Neural Networks
- Deep Learning
- Support Vector Machine
- Kiértékelés

## 2. Klaszterezés:

- K-means, GMM, X-means
- DBSCAN, OPTICS, Single-link

## 3. Attribútum és feature szelekció

- SVD (PCA), IG




## 4. Hálózati problémák:

- HITS, PageRank, Influence

## 5. Ajánlórendszerek:

- RBM, MF, SVD


## 6. Asszociációs szabályok



+ GPU-k és elosztott rendszerek (pl. OpenCL, CUDA, GraphLab)

Kép: wikipedia

# Egyéb példák



## Web és egyéb hálózat:

- keresés (szöveg,kép,videó,honlap,információ)
- ajánlás (reklám,cikk,kép...)
- log elemzés (telefonhálózat, ügyfélhálózat stb.)

## Üzleti intelligencia:


- döntés segítő rendszerek (tőzsde,biztosítás)
- összefüggés keresés (hasonló ügyfél, hasonló megoldás)

## Multimédia:


- automatikus annotáció (kép,videó,zene stb.)
- hangfelismerés és beszéd felismerés

## Orvosi kutatás és diagnosztika:

- szűrés (rák, TBC stb)
- élettani folyamatok elemzése
- génkutatás (génszekvenciák keresése, azonosítása, modellezése)
- gyógyszerkutatás



Ref: Lukács András




# Irodalom (ajánlott)

1. Tan, Steinbach, Kumar (TSK): Introduction to Data Mining  
Addison-Wesley, 2006, Cloth; 769 pp, ISBN-10: 0321321367, ISBN-13: 9780321321367  
<http://www-users.cs.umn.edu/~kumar/dmbook/index.php>
2. Bodon: Adatbányászati algoritmusok <http://www.cs.bme.hu/~bodon/magyar/adatbanyaszat/tanulmany/index.html>
3. Leskovic, Rajraman, Ullmann: Mining of Massive Datasets  
<http://infolab.stanford.edu/~ullman/mmds.html>
4. Devroye, Györfi, Lugosi: A Probabilistic Theory of Pattern Recognition, 1996
5. Rojas: Neural Networks, Springer-Verlag, Berlin, 1996
6. Hopcroft, Kannan: Computer Science Theory for the Information Age  
<http://www.cs.cmu.edu/~venkatg/teaching/CStheory-infoage/hopcroft-kannan-feb2012.pdf>

+ cikkek





# Adatbányászati szoftverek

Weka - open source java

DATO, Flink stb.

RapidMiner

Clementine (SPSS)


Darwin (Oracle)

SAS Enterprise Miner

IBM Intelligent Miner

+ Chainer, Tensorflow stb.

+ OpenSource libraries (R, **Scikit learn Python**)



# Reprezentáció


- Adathalmaz objektumok halmaza, mely tartalmazza az attribútumokat is
- Reményeink szerint az attribútumok megfelelően reprezentálják az adott objektumot
- Attribútumok típusai lehetnek:
  - pl. bináris
  - nominális
  - numerikus

Attribútumok, “feature”, változók

Adat objektumok, “record”

| <i>Tid</i> | Refund | Marital Status | Taxable Income | Cheat |
|------------|--------|----------------|----------------|-------|
| 1          | Yes    | Single         | 125K           | No    |
| 2          | No     | Married        | 100K           | No    |
| 3          | No     | Single         | 70K            | No    |
| 4          | Yes    | Married        | 120K           | No    |
| 5          | No     | Divorced       | 95K            | Yes   |
| 6          | No     | Married        | 60K            | No    |
| 7          | Yes    | Divorced       | 220K           | No    |
| 8          | No     | Single         | 85K            | Yes   |
| 9          | No     | Married        | 75K            | No    |
| 10         | No     | Single         | 90K            | Yes   |

# Reprezentáció



Attribútumok, “feature”, változók

Egy adathalmaz lehet:


- rendezhető
  - időbeli vagy soros
  - térbeli
- ritka vagy sűrű

Pár kikötés:

- fix attribútumhalmaz
- előre meghatározott attribútumok

Adat objektumok, “record”

| <i>Tid</i> | Refund | Marital Status | Taxable Income | Cheat |
|------------|--------|----------------|----------------|-------|
| 1          | Yes    | Single         | 125K           | No    |
| 2          | No     | Married        | 100K           | No    |
| 3          | No     | Single         | 70K            | No    |
| 4          | Yes    | Married        | 120K           | No    |
| 5          | No     | Divorced       | 95K            | Yes   |
| 6          | No     | Married        | 60K            | No    |
| 7          | Yes    | Divorced       | 220K           | No    |
| 8          | No     | Single         | 85K            | Yes   |
| 9          | No     | Married        | 75K            | No    |
| 10         | No     | Single         | 90K            | Yes   |



# Gépi tanulás

Legyen adott egy  $T$  elemű ismert halmaz  $\mathbb{R}^d$ -ben,  $X = \{x_1, \dots, x_T\}$  és minden eleméhez egy  $y$  érték.

Keressük az olyan  $f(x)$  függvényeket melyek jól közelítik  $y$ -t.

Sok a kérdés:

Hogyan határozzuk meg a közelítés minőségét?


Milyen függvényosztályok között keresünk?

Hogyan találunk egy adott függvényosztályon belül megfelelő példányt?

Komplexitás?

Generalizáció?

stb.




# Osztályozás vs. generatív modellek

Gyakorlatban, ha a célváltozónk bináris vagy egy véges halmaza eleme akkor osztályozásról beszélünk.

Nominális  $\rightarrow$  Bináris?

Megj.: A tanulás fontos része a visszajelzés.


Generatív modellek?










# Osztályozás

Mintahalmaz


cimke



# Klaszterezés



Ábra: TSK



# K-Means

Feltesszük, hogy az adatpontjaink egy valós vektortérben helyezkednek el.

A klasztereket a középpontjuk határozza meg.

K-means (D; k)

Adott egy  $C_1, C_2, \dots, C_k$  centroidok tetszőleges k elemű kezdeti halmaza

Amíg változik a centroidok halmaza:

minden d mintát soroljuk a hozzá legközelebbi centroid klaszterébe

Módosítsuk a meglévő centroidokat


$C_i$  legyen  $C_i$ -be tartozó elemek középértéke

A kezdőpontok meghatározása lehet:

- véletlen pontokból
- véletlen választott tanulópontokból

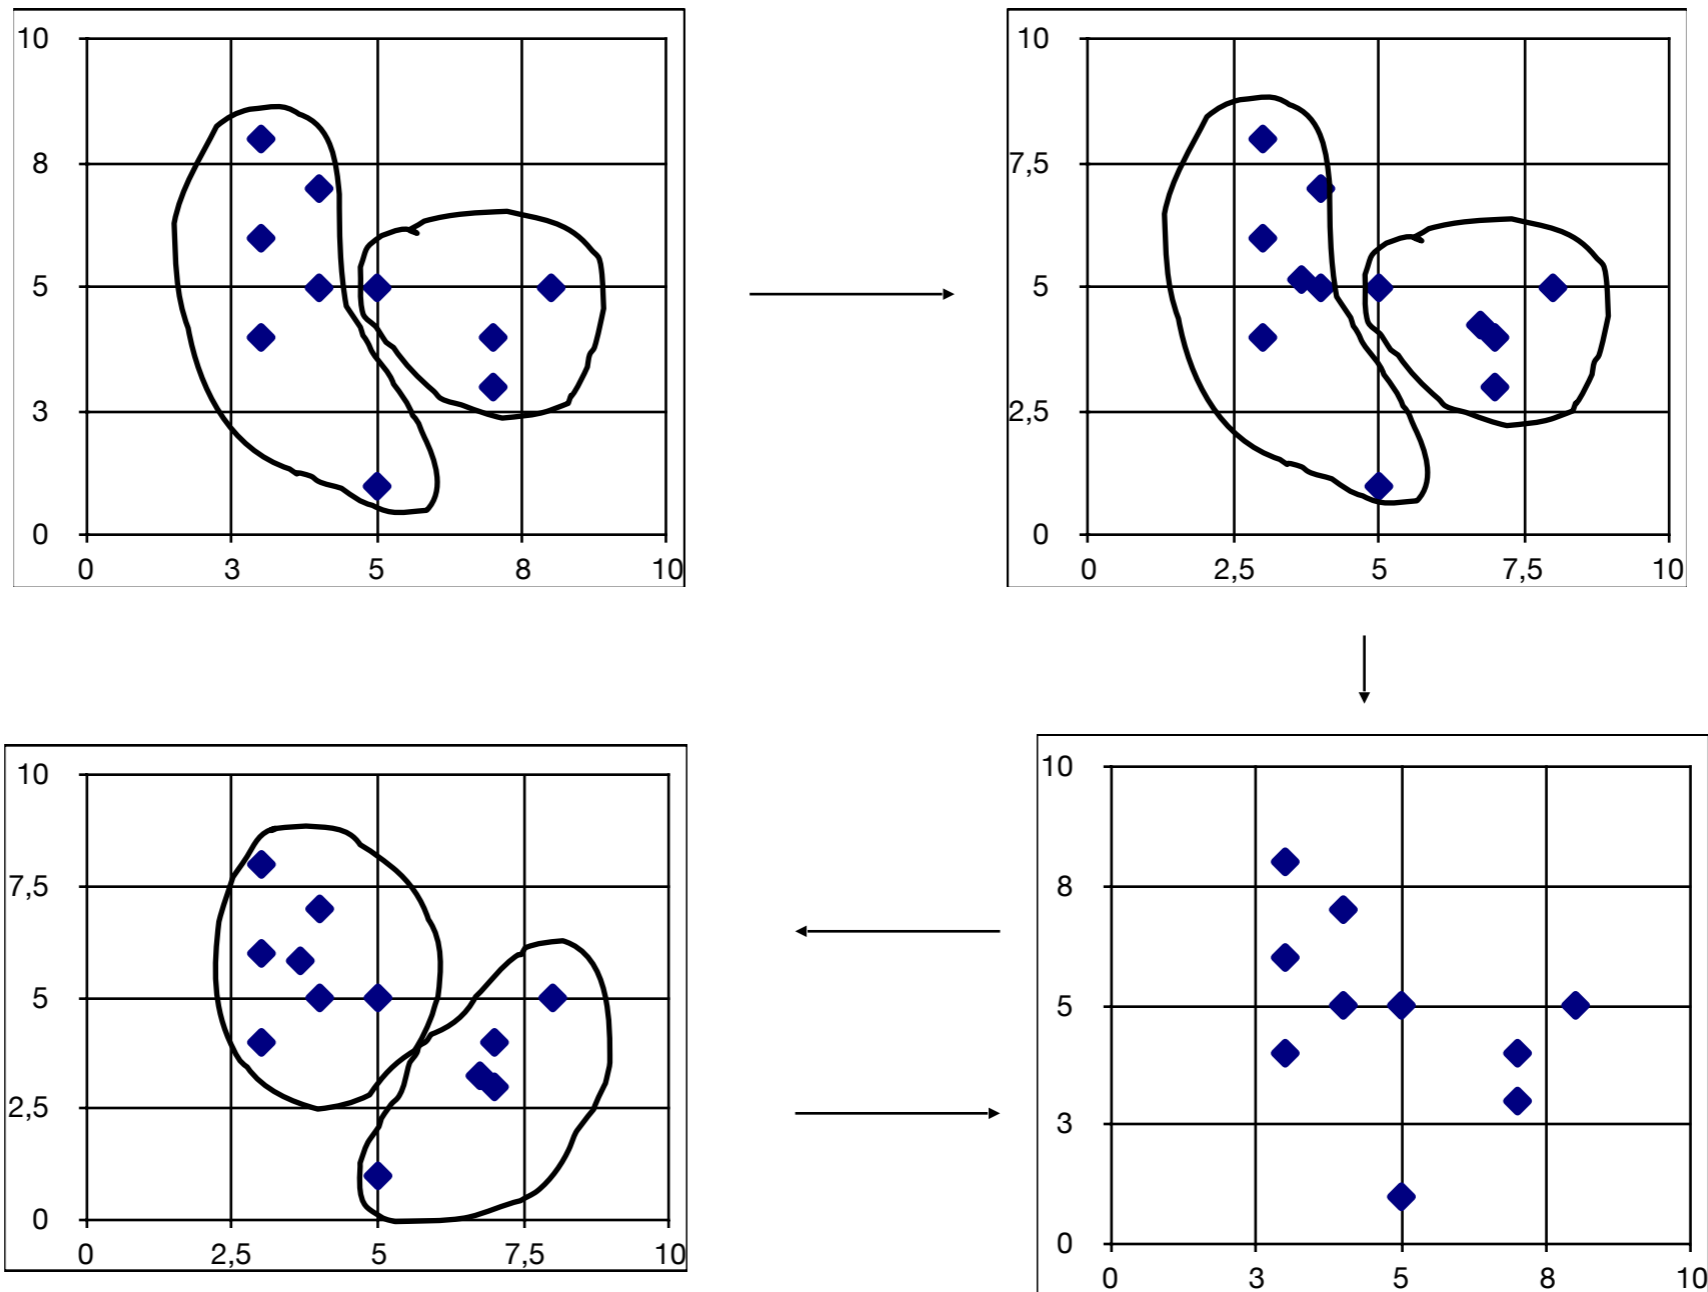
Az algoritmust megállítjuk, ha:


- a klaszterezés nem változik
- a küszöbhibánál kisebb az approx. hiba
- elértük a maximális iterációk számát







# K-means





# K-means






# K- nearest neighbor (K-NN)

Alapelv:

“Úgy megy mint egy kacsa, úgy úszik mint egy kacsa, úgy eszik mint egy kacsa, tehát kacsa!”

1. Minden tesztadathoz keressük meg a K legközelebbi elemet.
2. A legtöbbet reprezentált osztályt jósoljuk az adott tesztadatnak


Példa:




(a) 1-nearest neighbor

(b) 2-nearest neighbor

(c) 3-nearest neighbor



# K- nearest neighbor (K-NN)



Mi a gond?


- mohó (eager) algoritmus: kész modell készítése amint a tanuló adat létezik → többé nincs szükség a tanulóhalmazra
- lusta (lazy) algoritmus: kész jóslatot a tanulóhalmaz segítségével készít → szükséges a tanulóhalmaz a jósláshoz

A K-NN lusta algoritmus :

Méret?

Bonyolultság?

Skálázhatóság?




# K- nearest neighbor (K-NN)

Távolság mértékek (pl.)


- Minkowski távolság
- Mahalanobis  $D_M(x) = \sqrt{(x - \mu)^T S^{-1} (x - \mu)}$ .
- Cosine, Jaccard, Kullback-Leibler, Jensen-Shannon stb.

Problémák:

- skála
- automatikus távolság választás
- normalizáció




Ábra: TSK



# Kiértékelés

Confusion matrix:

| Alapigazság/<br>predikció | p                      | n                      | Total |
|---------------------------|------------------------|------------------------|-------|
| p                         | True Positive<br>(TP)  | False<br>Negative (FN) | TP+FN |
| n                         | False<br>Positive (FP) | True<br>Negative (TN)  | FP+TN |
| Total                     | TP+FN                  | FP+TN                  |       |



# Kiértékelés

Accuracy: a helyesen klasszifikálás valószínűsége

$$\frac{TP+TN}{TP+FP+TN+FN}$$


Precision (p): egy releváns dokumentum helyes klasszifikálásának valószínűsége

$$\frac{TP}{TP+FP}$$

Recall (r): annak a valószínűsége, hogy egy releváns dokumentumot helyesen klasszifikálunk

$$\frac{TP}{TP+FN}$$

F-measure: a precision és a recall harmónikus közepe ( $\frac{2 \cdot p \cdot r}{p+r}$ )



# Kiértékelés

False-Positive Rate (FPR) =  
 $FP / (FP + TN)$

True-Positive Rate (TPR) =  
 $TP / (TP + FN)$


ROC: Receiver Operating  
 Characteristic

MAP: Mean Average Precision


$$AveP = \frac{\sum_{r=1}^N (P(r) \times rel(r))}{\text{number of relevant documents}}$$

nDCG: normalized  
 Discriminative Cumulative  
 Gain


$$DCG_p = rel_1 + \sum_{i=2}^p \frac{rel_i}{\log_2(i)}$$









# Kiértékelés



|    |    |
|----|----|
| TP | FP |
| FN | TN |
| 1  | 1  |






## ROC: Receiver Operating Characteristic

- csak bináris osztályozásnál használható (i.e. egy osztályra)
- Area Under Curve: AUC annak a valószínűsége, hogy véletlen pozitív elemeket előrébb sorol mint véletlen negatívakat
- mivel az jóslatok sorrendjéből számítjuk, a klasszifikálónak nem csak bináris jóslatokat kell visszaadnia
- előnye, hogy nem függ a vágási ponttól
- Milyen szempontból lehetne továbbfejleszteni?

| Class | +    | -    | +    | -    | -    | -    | +    | -    | +    | +    |      |
|-------|------|------|------|------|------|------|------|------|------|------|------|
|       | 0.25 | 0.43 | 0.53 | 0.76 | 0.85 | 0.85 | 0.85 | 0.87 | 0.93 | 0.95 | 1.00 |
| TP    | 5    | 4    | 4    | 3    | 3    | 3    | 3    | 2    | 2    | 1    | 0    |
| FP    | 5    | 5    | 4    | 4    | 3    | 2    | 1    | 1    | 0    | 0    | 0    |
| TN    | 0    | 0    | 1    | 1    | 2    | 3    | 4    | 4    | 5    | 5    | 5    |
| FN    | 0    | 1    | 1    | 2    | 2    | 2    | 2    | 3    | 3    | 4    | 5    |
| TPR   | 1    | 0.8  | 0.8  | 0.6  | 0.6  | 0.6  | 0.6  | 0.4  | 0.4  | 0.2  | 0    |
| FPR   | 1    | 1    | 0.8  | 0.8  | 0.6  | 0.4  | 0.2  | 0.2  | 0    | 0    | 0    |

# ROC: Receiver Operating Characteristic

| Class | +    | -    | +    | -    | -    | -    | +    | -    | +    | +    |      |
|-------|------|------|------|------|------|------|------|------|------|------|------|
|       | 0.25 | 0.43 | 0.53 | 0.76 | 0.85 | 0.85 | 0.85 | 0.87 | 0.93 | 0.95 | 1.00 |
| TP    | 5    | 4    | 4    | 3    | 3    | 3    | 3    | 2    | 2    | 1    | 0    |
| FP    | 5    | 5    | 4    | 4    | 3    | 2    | 1    | 1    | 0    | 0    | 0    |
| TN    | 0    | 0    | 1    | 1    | 2    | 3    | 4    | 4    | 5    | 5    | 5    |
| FN    | 0    | 1    | 1    | 2    | 2    | 2    | 2    | 3    | 3    | 4    | 5    |
| TPR   | 1    | 0.8  | 0.8  | 0.6  | 0.6  | 0.6  | 0.6  | 0.4  | 0.4  | 0.2  | 0    |
| FPR   | 1    | 1    | 0.8  | 0.8  | 0.6  | 0.4  | 0.2  | 0.2  | 0    | 0    | 0    |



AUC=?




# Távolság ism.

## Távolság mértékek (pl.)


- Minkowski távolság
- Mahalanobis  $D_M(x) = \sqrt{(x - \mu)^T S^{-1} (x - \mu)}$ .
- Cosine, Jaccard, Kullback-Leibler, Jensen-Shannon stb.

## Problémák:

- skála
- automatikus távolság választás
- normalizáció



Ábra: TSK



# Holnapi gyakorlat


[NN\\_dataset.zip](#)


**image\_histograms.txt és sample\_histogram.txt:**

Adottak az images könyvtár képein számolt  $3 \times 8$  dimenziós RGB hisztogramok

Rendezzük sorrendbe távolság szerint a sample\_histogram.txt fájl-ban található kép hisztogramjától számított L2 távolság alapján az image\_histograms.txt képeit!

Mi lehet a hiba? Mi történik ha L2 normalizáljuk a hisztogramokat?





# Naïve-Bayes

Bayes-i alapok:

$$p(h | d) = \frac{P(d | h)P(h)}{P(d)}$$

Priori:  $P(h)$

Posteriori:  $P(h|d)$

Evidence:  $P(d)$

Total probability:  $P(h)=P(h,d)+P(h,/d)=P(h|d)P(d)+P(h|/d)P(/d)$

**Feladat:** Az épületben megforduló emberek tizede tanár a többi diák. 10-ből 8 diák saját lappal rendelkezik míg minden 10 tanárból csak 5-nek van laptopja, mennyi a valószínűsége, hogy egy ember aki bejön az ajtón:

- a) tanár
- b) diák
- c) van laptopja
- d) van laptopja és diák
- e) van laptopja és tanár

# Naïve-Bayes

Szeretnénk attribútumok alapján meghatározni a posteriori valószínűségeket:

$P(\text{class}=1 | A_1, A_2, \dots, A_n)$  és  $P(\text{class}=0 | A_1, A_2, \dots, A_n)$

Amelyik nagyobb arra döntünk.  $P(A_1, A_2, \dots, A_n | \text{class}=1) P(\text{class}=1) / P(A_1, A_2, \dots, A_n)$

$$P(A_1, A_2, \dots, A_n | \text{class}=1) = \prod P(A_i | \text{class}=1)$$

konstans!

| Saját háza van | Családi állapot | kereset | Van hitele? |
|----------------|-----------------|---------|-------------|
| van            | egyedülálló     | 125e    | nincs       |
| nincs          | házas           | 100e    | nincs       |
| nincs          | egyedülálló     | 70e     | nincs       |
| van            | házas           | 120e    | nincs       |
| nincs          | elvált          | 95e     | van         |
| nincs          | házas           | 60e     | nincs       |
| van            | elvált          | 220e    | nincs       |
| nincs          | egyedülálló     | 85e     | van         |
| nincs          | házas           | 75e     | nincs       |
| nincs          | egyedülálló     | 90e     | van         |



# Naïve-Bayes

Szeretnénk attribútumok alapján meghatározni a posteriori valószínűségeket:

$P(\text{class}=1 | A_1, A_2, \dots, A_n)$  és  $P(\text{class}=0 | A_1, A_2, \dots, A_n)$

Amelyik nagyobb arra döntünk.  $P(A_1, A_2, \dots, A_n | \text{class}=1) P(\text{class}=1) / P(A_1, A_2, \dots, A_n)$

$$P(A_1, A_2, \dots, A_n | \text{class}=1) = \prod P(A_i | \text{class}=1)$$

**konstans!**

| Saját háza van | Családi állapot | kereset | Van hitele? |
|----------------|-----------------|---------|-------------|
| van            | egyedülálló     | 125e    | nincs       |
| nincs          | házas           | 100e    | nincs       |
| nincs          | egyedülálló     | 70e     | nincs       |
| van            | házas           | 120e    | nincs       |
| nincs          | elvált          | 95e     | van         |
| nincs          | házas           | 60e     | nincs       |
| van            | elvált          | 220e    | nincs       |
| nincs          | egyedülálló     | 85e     | van         |
| nincs          | házas           | 75e     | nincs       |
| nincs          | egyedülálló     | 90e     | van         |

$P(\text{saját ház}=nincs | \text{hitel}=nincs) = 4/7$   
 $P(\text{saját ház}=van | \text{hitel}=nincs) = 3/7$   
 $P(\text{saját ház}=nincs | \text{hitel}=van) = 1$   
 $P(\text{saját ház}=van | \text{hitel}=van) = 0$   
 $P(\text{családi\_áll}=egyedülálló | \text{hitel}=nincs) = 2/7$   
 $P(\text{családi\_áll}=házas | \text{hitel}=nincs) = 4/7$   
 $P(\text{családi\_áll}=elvált | \text{hitel}=nincs) = 1/7$   
 $P(\text{családi\_áll}=egyedülálló | \text{hitel}=van) = 2/3$   
 $P(\text{családi\_áll}=házas | \text{hitel}=van) = 0$   
 $P(\text{családi\_áll}=elvált | \text{hitel}=van) = 1/3$

$P(\text{kereset}=? | \text{hitel}=van) = ?$

$P(\text{kereset}=? | \text{hitel}=nincs) = ?$

## Naïve-Bayes

### Folytonos változók esetében

- diszkrétizáljuk az adatot : 0-90e Ft-ig 91-125e stb
- modellezzük a problémát normál eloszlással!

$$P(X_i = x_i | Y = y_j) = \frac{1}{\sqrt{2\pi}\sigma_{ij}} \exp^{-\frac{(x_i - \mu_{ij})^2}{2\sigma_{ij}^2}}$$

| Saját háza van | Családi állapot | kereset | Van hitele? |
|----------------|-----------------|---------|-------------|
| van            | egyedülálló     | 125e    | nincs       |
| nincs          | házas           | 100e    | nincs       |
| nincs          | egyedülálló     | 70e     | nincs       |
| van            | házas           | 120e    | nincs       |
| nincs          | elvált          | 95e     | van         |
| nincs          | házas           | 60e     | nincs       |
| van            | elvált          | 220e    | nincs       |
| nincs          | egyedülálló     | 85e     | van         |
| nincs          | házas           | 75e     | nincs       |
| nincs          | egyedülálló     | 90e     | van         |

Kereset:

hitel=nincs:

Átlag: 110e  
Szórás<sup>2</sup>: 2975

hitel=van:

Átlag: 90e  
Szórás<sup>2</sup>: 25

# Naïve-Bayes

Szeretnénk attribútumok alapján meghatározni a posteriori valószínűségeket:

$P(\text{class}=1 | A_1, A_2, \dots, A_n)$  és  $P(\text{class}=0 | A_1, A_2, \dots, A_n)$

Amelyik nagyobb arra döntünk.  $P(A_1, A_2, \dots, A_n | \text{class}=1)P(\text{class}=1) / P(A_1, A_2, \dots, A_n)$

$$P(A_1, A_2, \dots, A_n | \text{class}=1) = \prod P(A_i | \text{class}=1)$$

**konstans!**

| Saját ház | Családi állapot | kereset | Van hitele? |
|-----------|-----------------|---------|-------------|
| van       | egyedülálló     | 125e    | nincs       |
| nincs     | házas           | 100e    | nincs       |
| nincs     | egyedülálló     | 70e     | nincs       |
| van       | házas           | 120e    | nincs       |
| nincs     | elvált          | 95e     | van         |
| nincs     | házas           | 60e     | nincs       |
| van       | elvált          | 220e    | nincs       |
| nincs     | egyedülálló     | 85e     | van         |
| nincs     | házas           | 75e     | nincs       |
| nincs     | egyedülálló     | 90e     | van         |

Van-e hitele a következő tulajdonságokkal rendelkező személynek:

- nincs saját háza
- házas
- 120e a keresete

$P(\text{hitel}=\text{van} | \text{saját ház}=\text{nincs}, \text{családi\_áll}=\text{házas}, \text{kereset}=120\text{e})=?$   
 $P(\text{hitel}=\text{van} | \text{saját ház}=\text{nincs}, \text{családi\_áll}=\text{házas}, \text{kereset}=120\text{e})=?$

## Naïve-Bayes

A 0-a valószínűségek több esetben zajként jelentkeznek (pl. nincs rá elem az eredeti adathalmazban ergo nem is lehetséges)

### M-estimate:

Legyen  $p$  egy előre meghatározott minimum valószínűség

Módosítsuk a feltételes valószínűségek kiszámítását:

$$P(x_i|y_j) = \frac{n_c + mp}{n + m}$$

Ahol  $m$  egy előre meghatározott konstans,  $n_c$  azon  $x_i$  tulajdonsággal rendelkező tanulóponatok száma melyek osztályváltozója  $y_i$ ,  $n$  pedig az összes ide tartozó tanulóponatok száma.

Olyan esetekben is  $p$  lesz a posterior valószínűség, ha egyáltalán nincs olyan tanulóponatok melynek  $y_i$  az osztályváltozója.


M-estimate nagyban segíti a zajos, hiányos vagy egyszerűen speciális esetek korrekt kiértékelését anélkül, hogy azok szerepeltek volna az adathalmazban.


# Zajos attribútumok

Hogyan viselkedik a kNN és egy NB a következő adaton?

Attribútumok

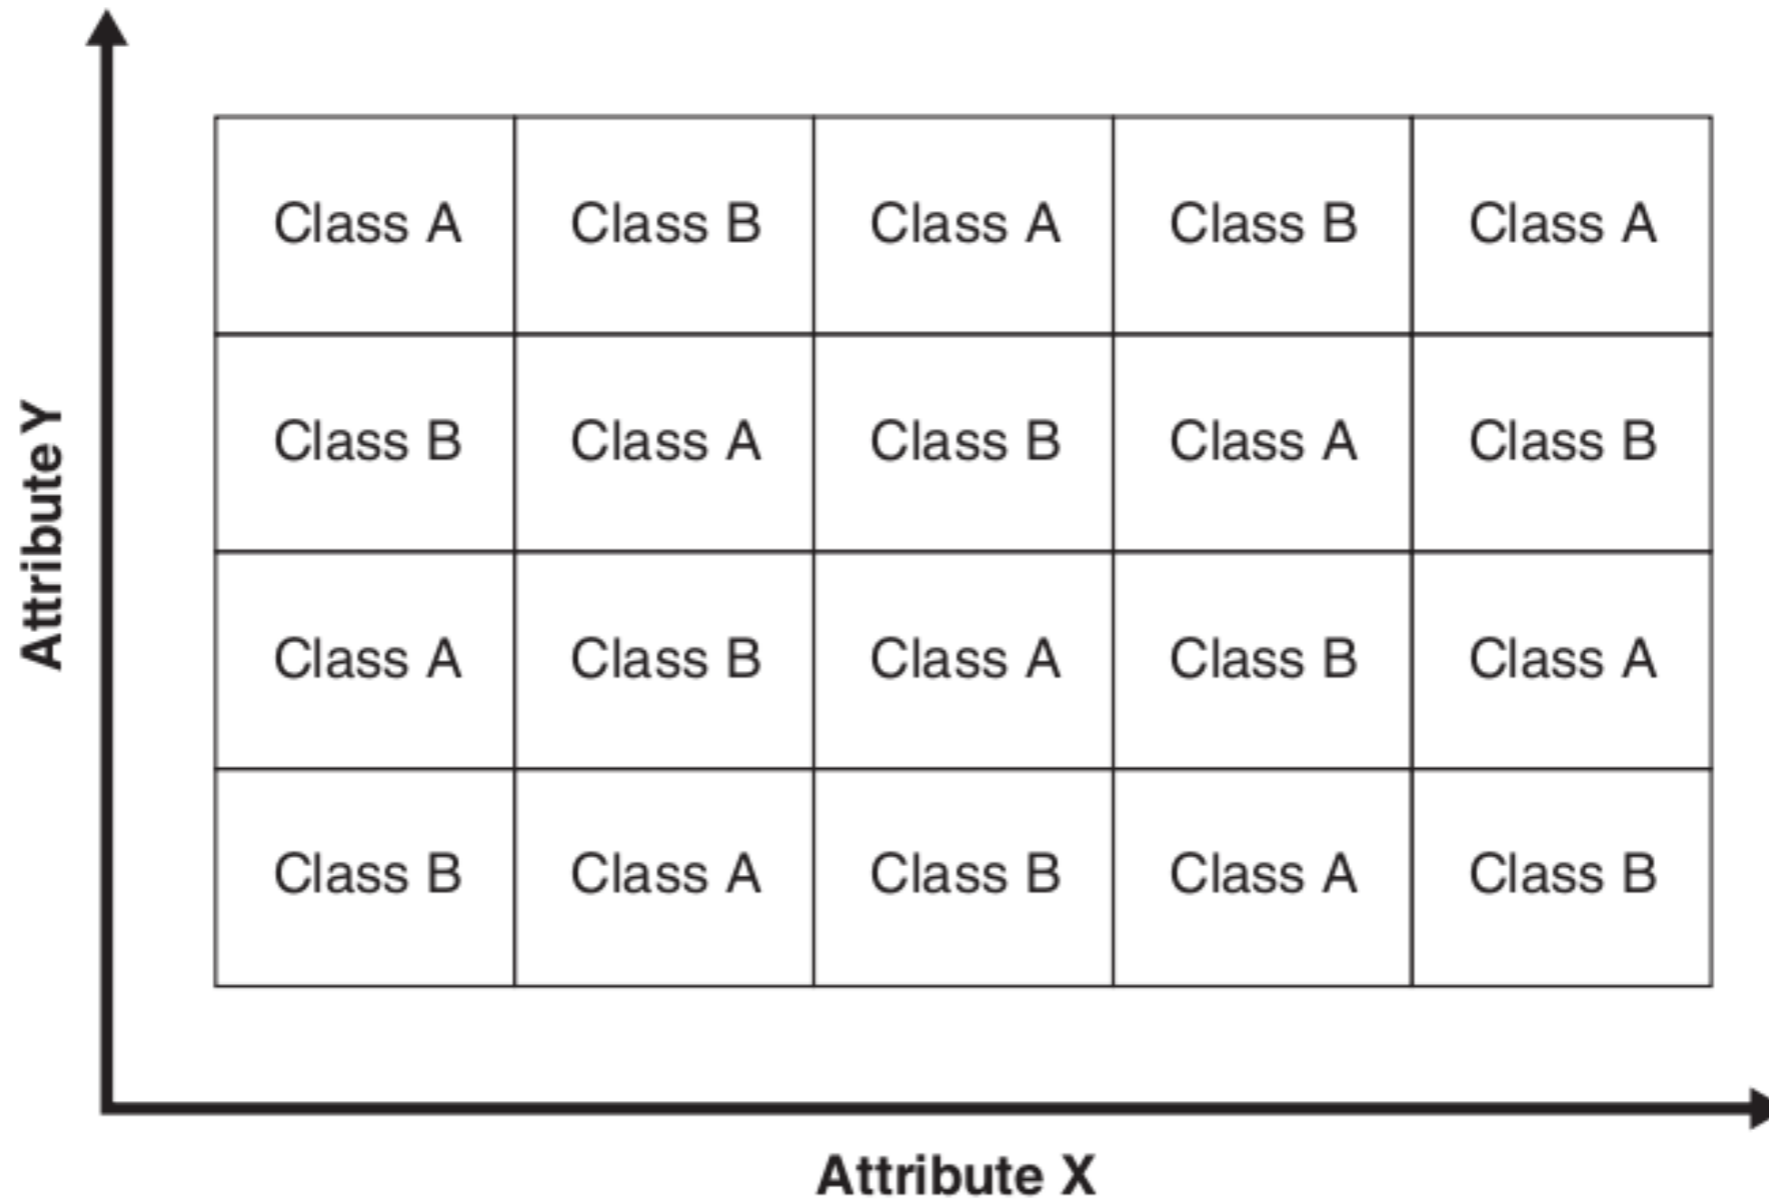
Rekordok






## Órai feladat 1:

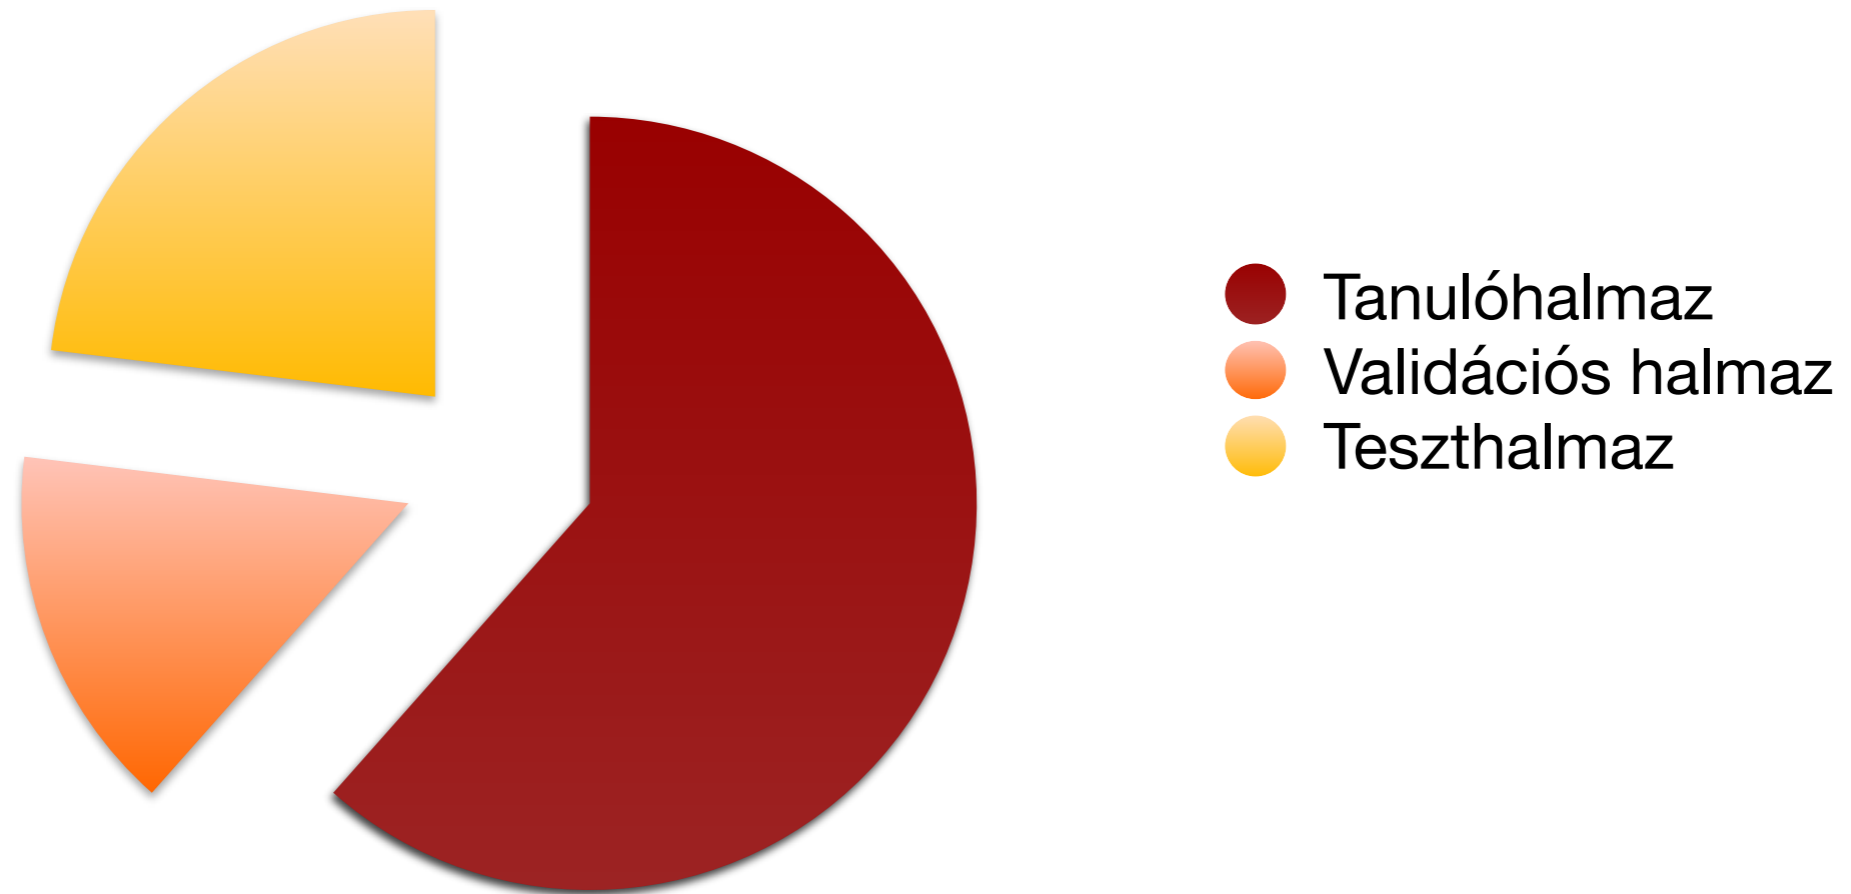
Melyik klasszifikátor működik jól/rosszul s miért?  
(K-NN, Naïve-Bayes)







# Kereszt validáció és hiba

## Validáció







# Kereszt validáció és hiba








# Lineáris szeparálás






# Lineáris szeparálás

Legyen adott egy véges  $n$  elemű mintahalmaz  $\mathbf{X}=\{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n\}$  egy  $d$ -dimenziós térben illetve minden elemhez rendeljünk egy osztályváltozót ( $y_i$ ). Keressünk egy  $d$ -dimenziós  $\mathbf{w}$  normál vektort melyre a következő egyenlőtlenségek igazak

$\mathbf{w} \cdot \mathbf{x}_i > b$  minden  $\mathbf{x}_i$  elemre melynek a címkéje  $+1$

$\mathbf{w} \cdot \mathbf{x}_i < b$  minden  $\mathbf{x}_i$  elemre melynek a címkéje  $-1$

Azon vektor-küszöb párosok  $(\mathbf{w}, b)$ , melyekre igazak a fenti egyenlőtlenségek  $\mathbf{X}, \mathbf{y}$  lineáris szeparátorai.




# Lineáris szeparálás

Egészítsük ki a meglévő vektorainkat egy extra dimenzióval. A probléma átírható a következő formára

$$(\mathbf{w}' \cdot \mathbf{x}'_i) \mid_i > 0$$

ahol  $1 \leq i \leq n$  és  $\mathbf{x}'_i = (\mathbf{x}_i, 1)$  illetve  $\mathbf{w}' = (\mathbf{w}, b)$ .

Hogyan találjunk egy lineáris szeparáló hipersíkot?



# Perceptron tanulás

Iteratív algoritmus, hogy találjunk egy lineáris szeparálót

Kezdőállapot:

Legyen  $\mathbf{w} = y_1 \mathbf{x}_1$  és  $|\mathbf{x}_i|=1$  minden  $\mathbf{x}_i$ -re

Amíg létezik  $\mathbf{a}_i$  melyre nem igaz az egyenlőtlenség azaz  $(\mathbf{w} \cdot \mathbf{a}_i) \leq 0$ , módosítsuk a modellünket

$$\mathbf{w}^{t+1} = \mathbf{w}^t + y_i \mathbf{x}_i$$

Az algoritmus megáll ha létezik lineáris szeparáló!

# Lineáris regresszió

Tegyük fel újra, hogy a tanulóhalmaz attribútumait kiegészítettük megint egy bias változóval. ( $X$  a tanulóhalmaz ( $N$  elemű),  $Y$  az osztályváltozó) Ebben az esetben az előbbi lineáris kombináció :

$$Y = X^T w$$

Szeretnénk megtalálni a regressziós görbét, melynél a négyzetesen hiba minimális (lehet más hibamértéket is alkalmazni):

$$\text{error}_{\text{square}}(f) = E[(Y - f(X))^2]$$

Mivel a tanulóhalmaz véges, a hiba :

$$\text{error}(f) = \sum_1^N (y_i - x_i^T w_i)^2$$

# Lineáris regresszió

Vagy:

$$\text{error}(f) = \sum_1^N (y_i - x_i^T w_i)^2 = (y - Xw)^T (y - Xw)$$

Mindig létezik minimuma és egyértelmű, így képezzük  $w$  szerinti deriváltját, s megkeressük hol 0-a:

$$-2X^T y + 2X^T Xw = 0 \quad X^T (y - Xw) = 0$$

Melyből következik , hogy ha nem 0-a a determináns  $\rightarrow$

$$w = (X^T X)^{-1} X^T y$$

# Logisztikus regresszió

Balról jobbra:

Épp ezért el kell döntenünk hogy mikor döntünk 1-es osztályra vagy 0-as osztályra (feltételezve, hogy eredetileg az osztályváltozóink értékkészlete  $\{0,1\}$ ). Amennyiben a jóslás nagyobb 0.5 akkor (ebben az esetben közelebb van 1-hez vagy nagyobb egynél) legyen a jóslat értéke 1, ha pedig kisebb 0-a.

$$y = x^T w - 0.5$$

$$f(y) = y_{osztály} = \frac{1 + \operatorname{sgn}(y)}{2}$$

Sajnos már nem alkalmazhatunk lineáris regressziót a  $w$  meghatározásához.

# Logisztikus regresszió

Hogy meghatározhassuk  $w$ -t, keresnünk kell egy olyan  $f(y)$  függvényt melyre a következő állítások igazak:

1. értéke 1-hez közelít, ha  $y$  értéke végtelenhez tart
2. értéke 0-hoz közelít, ha  $y$  értéke mínusz végtelenhez tart
3.  $f(0) = 0.5$
4. szimmetrikus nullára nézve, tehát  $f(y) + f(-y) = 1$  azaz  $2f(0)$
5.  $f(y)$  differenciálható minden pontban
6. ne legyenek lokális szélsőértékei ( pl. monoton növekvő)

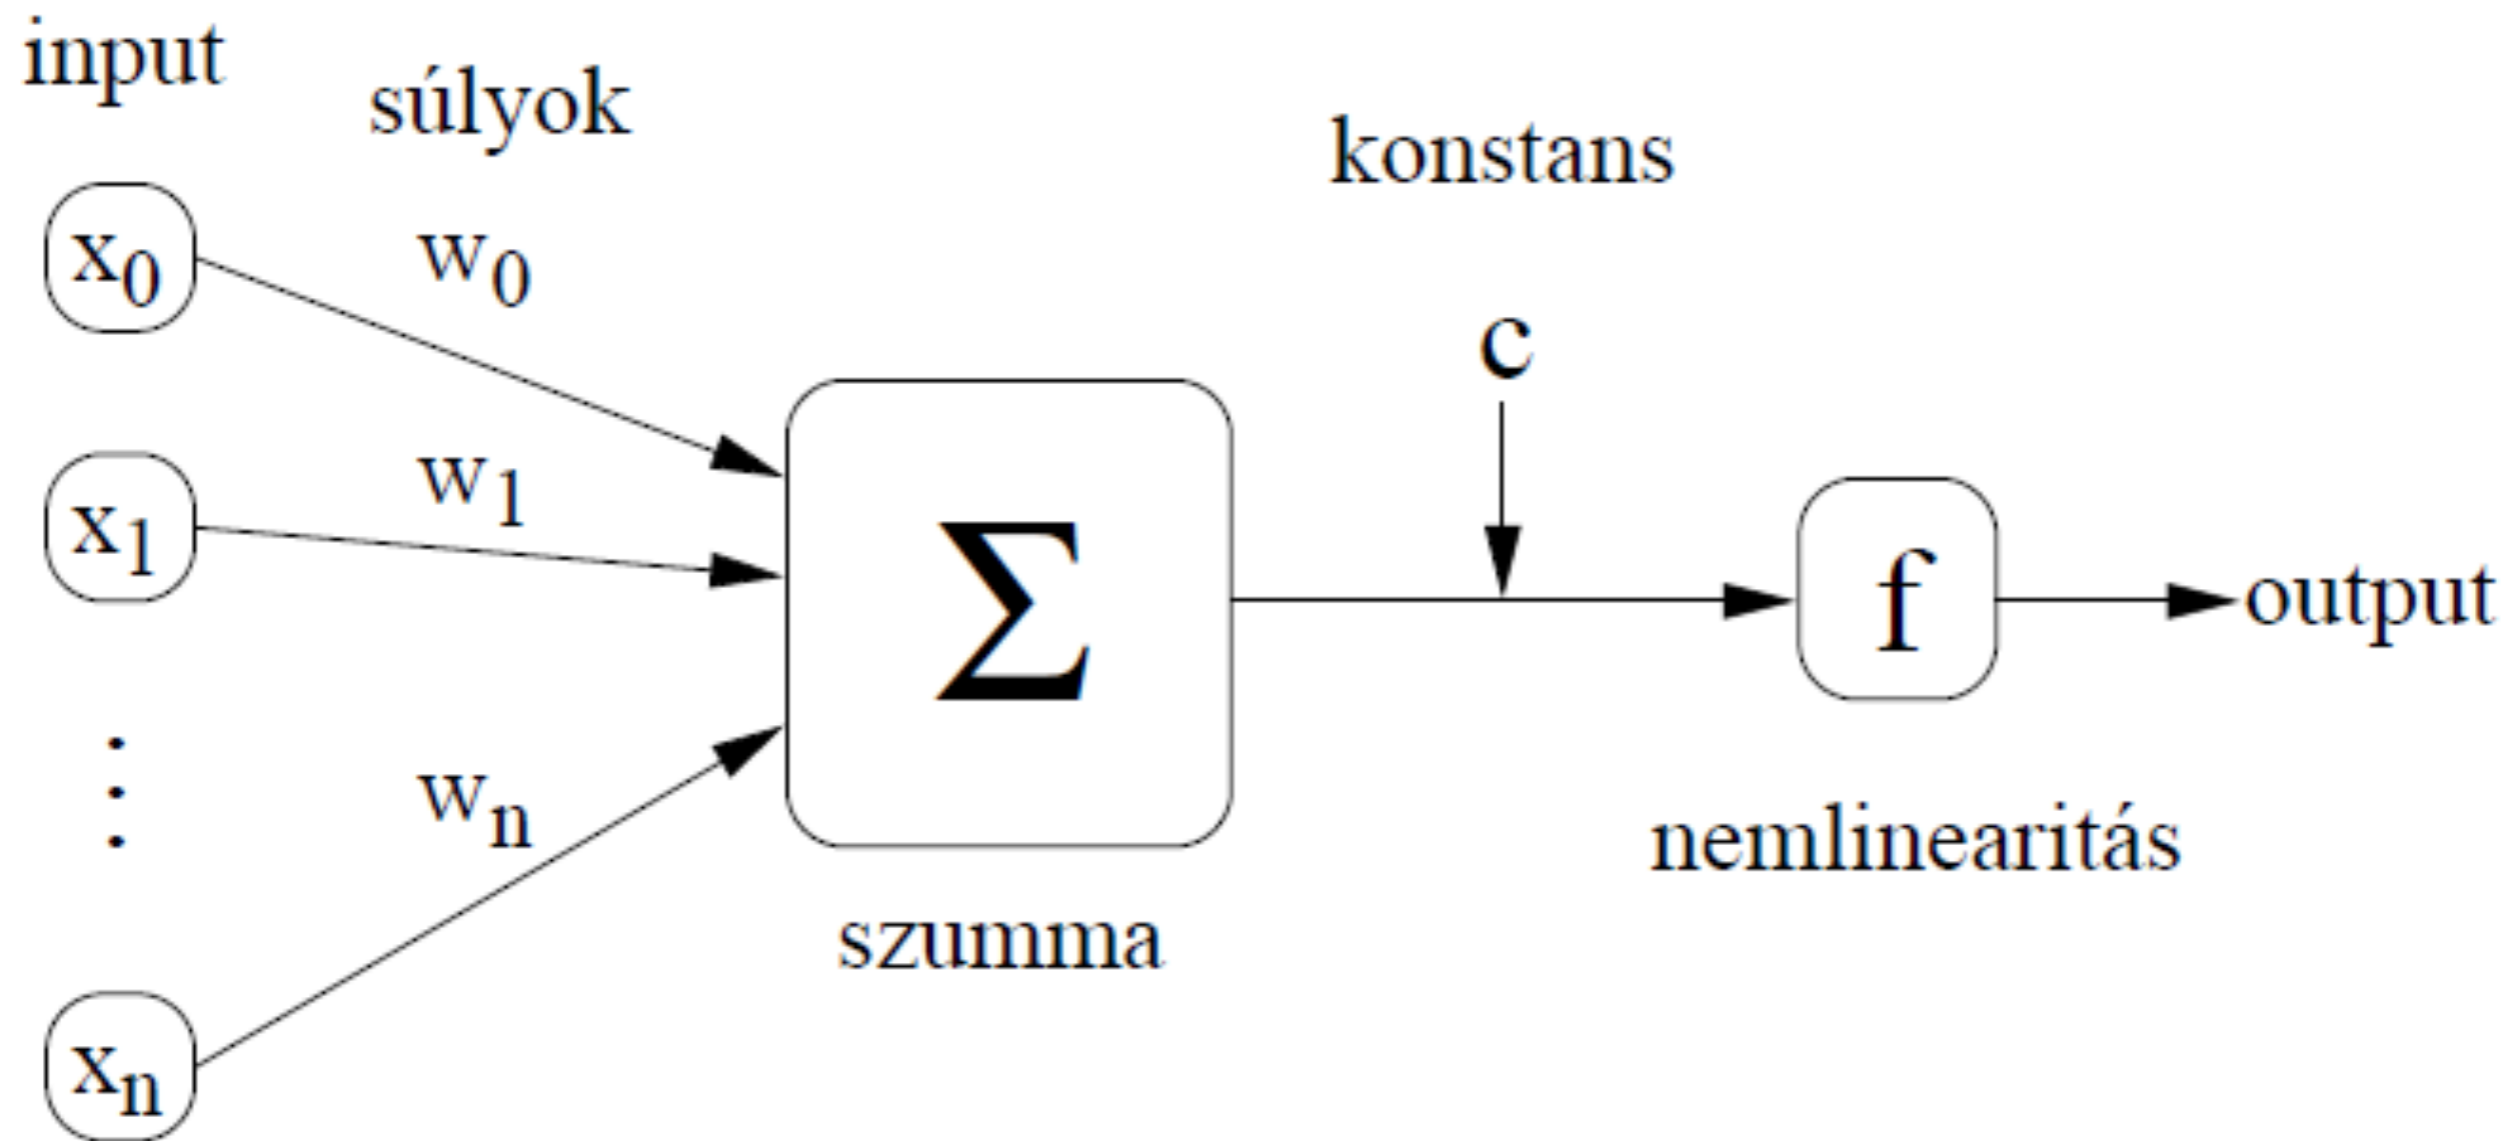
A szigmoid függvények megfelelnek a fenti követelményeknek

$$f(y) = 1 / (1 + a^{(-y)})$$


amennyiben  $a > 1$ .




# Logisztikus regresszió




Linear function




Sigmoid function



Tanh function



Sign function



# Logisztikus regresszió

Optimalizálás lehet pl. gradiens módszerrel (részletesen később):

$$w_{\text{opt}} = \operatorname{argmax}_w \sum \ln(P(y_i | x_i, w))$$

Viszont felhasználhatjuk, hogy bináris osztályozás esetén  $y_i=0$  vagy  $y_i=1$ :

$$L(w) = \sum y_i \ln(P(y_i = 1 | x_i, w)) + (1 - y_i) \ln(P(y_i = 0 | x_i, w))$$

Kiindulunk  $w^{(0)}$ -ból, majd minden iterációban  $w^{(l)}$ -hez hozzáadjuk  $dL(w)/dw$  (parciális deriváltak)  $\lambda$  szorosát (mely egy előre meghatározott konstans, a tanulási növekmény): ( $w_j$ -re)

$$\sum x_{ij}(y_i - P(y_i | x_{ij}, w_j))$$

# Logisztikus regresszió


**Balról jobbra:** Legyen  $p(x)$  az első osztályra döntés valószínűsége és tegyük fel, hogy:

$$\ln \frac{p(x)}{1 - p(x)} \approx x^T \omega + \omega_0$$

Melyből:  $p(x | \omega) = \text{sigm}(x | \omega) = \frac{1}{1 + e^{-(x^T \omega + \omega_0)}}$

Amennyiben a log-likelihood-ra optimalizálunk (tanulóhalmaz  $X = \{x_1, \dots, x_t\}$ ) és a mintáinkat függetlennek tekintjük:

$$\begin{aligned} \frac{\partial \mathcal{L}(\omega | X)}{\partial \omega_i} &= \sum_{x_t \in X^{(+)}} \frac{\partial \ln p(x_t | \omega)}{\partial \omega_i} + \sum_{x_t \in X^{(-)}} \frac{\partial \ln(1 - p(x_t | \omega))}{\partial \omega_i} \\ &= \sum_{x_t \in X^{(+)}} (1 - p(x_t | \omega)) x_{ti} - \sum_{x_t \in X^{(-)}} p(x_t | \omega) x_{ti} \\ &= \sum_{x_t \in \{X^{(-)}, X^{(+)}\}} (y_t - p(x_t | \omega)) x_{ti} \end{aligned}$$




# Maximális margó


**Definíció:** Legyen  $w$   $(X,y)$  egy lineáris szeparátora. Ebben az esetben a margó a hipersík és bármely minta  $x_i$  távolsága


$$\min_i \frac{w x_i}{|w|}$$

Amennyiben létezik egy ideális megoldás (ahol maximális a margó), a perceptron tanulás konvergál.



# Margó





# Maximális margó (balról)

Legyen  $\delta$  a  $\mathbf{w}$  margója.


Módosítsuk az eredeti egyenlőtlenségünket a következő módon

$$y_i(\mathbf{v}^T \mathbf{x}_i) > 1$$

ahol

$$\mathbf{v} = \frac{\mathbf{w}}{\rho |\mathbf{w}|}$$

Maximális margó helyett minimális  $|\mathbf{v}|$ -ra optimalizálunk!



# Maximális margó (balról)


Az új optimalizálási problémánk

$$\min |\mathbf{v}| \text{ ahol } y_i(\mathbf{v}^T \mathbf{x}_i) > 1, \forall i.$$


Miután a fenti probléma optimuma megegyezik a következő probléma optimumával, a végső optimalizáció:

$$\min |\mathbf{v}|^2 \\ \text{ahol } y_i(\mathbf{v}^T \mathbf{x}_i) \geq 1, \forall i.$$





# Maximális margó



$$wx_1 + b = 1$$

$$wx_2 + b = -1$$

$$x_2 - x_1 = -n \frac{w}{\|w\|} \longrightarrow x_2 = x_1 - n \frac{w}{\|w\|}$$

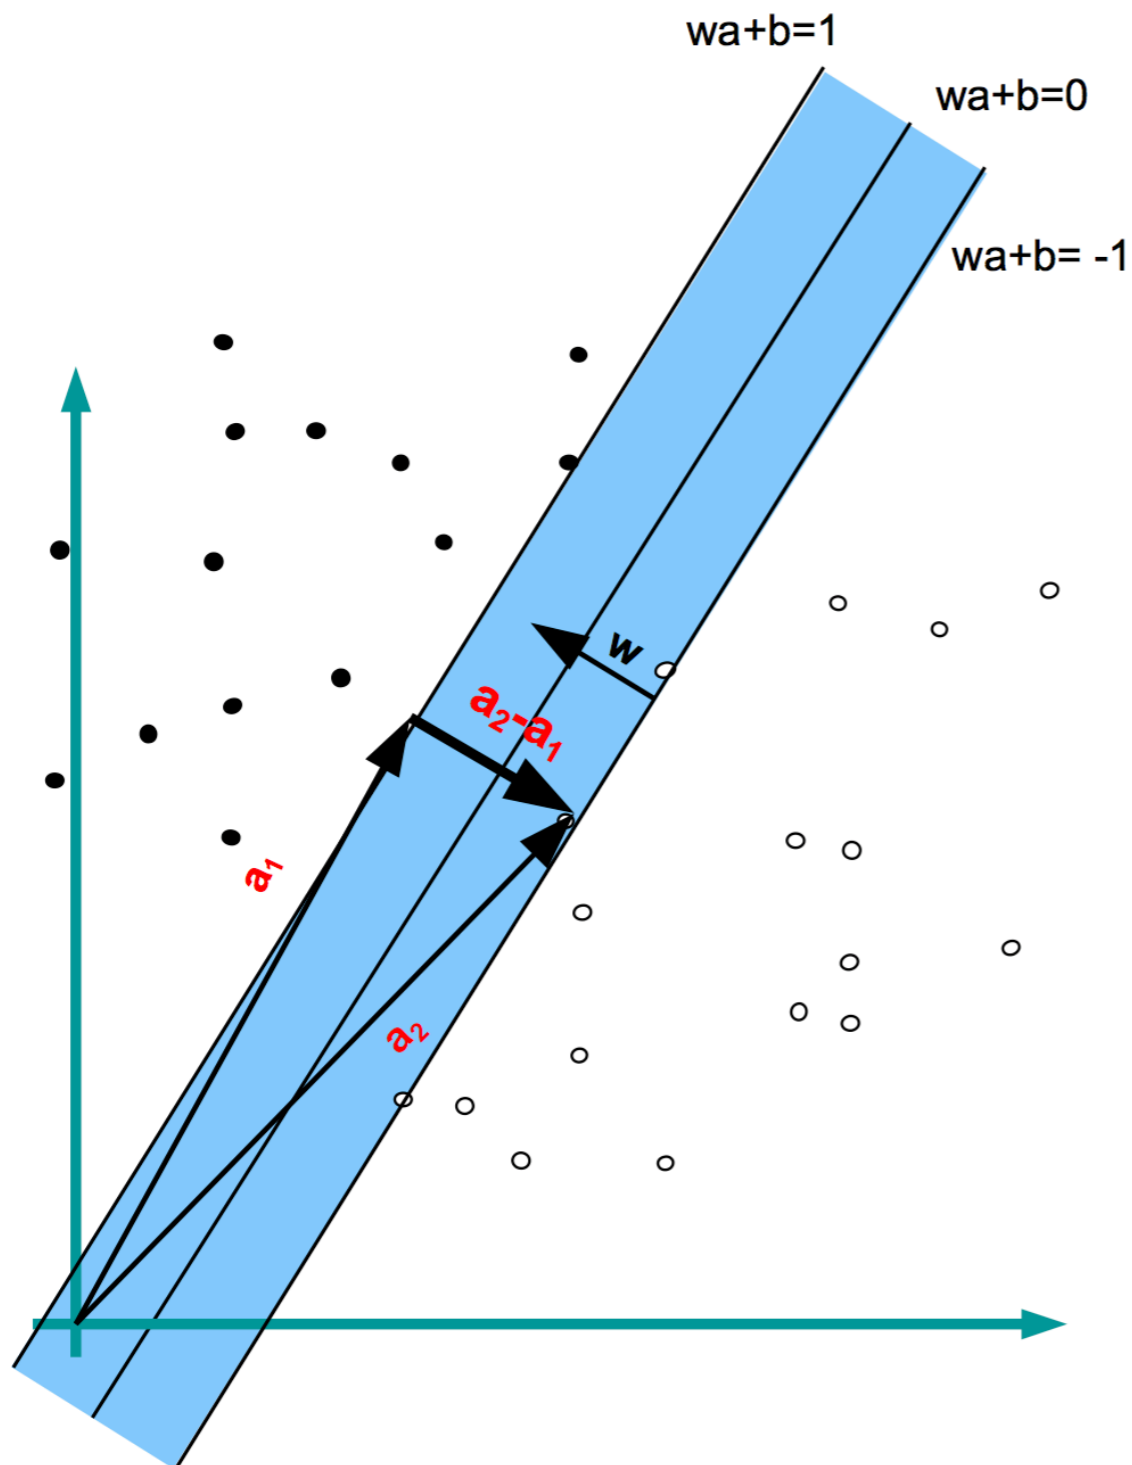

$$wx_2 + b = \left(x_1 - n \frac{w}{\|w\|}\right) w + b = -1$$

$$wx_1 + b = 1$$

$$wx_1 + b - n \frac{w}{\|w\|} w = -1$$

$$1 - n \frac{w}{\|w\|} w = -1 \longrightarrow n = \frac{2}{\|w\|}$$

# Maximális margó



$$wa_1 + b = 1$$


$$wa_2 + b = -1$$

$$a_2 - a_1 = -n \frac{w}{\|w\|} \longrightarrow a_2 = a_1 - n \frac{w}{\|w\|}$$

Maximize  $n = \frac{2}{\|w\|}$

Minimize  $\|w\|$

$$1 - n \frac{w}{\|w\|} \cdot w = -1 \longrightarrow n = \frac{2}{\|w\|}$$




# Lineáris szeparálhatóság

Lehetséges-e és ha igen, hogyan a következő függvényeket megadni lineáris szeparátorral?

- OR
- AND

Keressük meg gradiens módszerrel a következő függvény maximumát:

$\sin(x)$



# Lineáris szeparálhatóság


Lehetséges-e és ha igen, hogyan a következő függvényeket megadni lineáris szeparátorral?

- OR
- AND

Keressük meg gradiens módszerrel a következő függvény maximumát:

$\sin(x)$

Majd pedig a következőét:  $x \cdot \sin(x)$



# Lineáris szeparálhatóság

Lehetséges-e és ha igen, hogyan a következő függvényeket megadni lineáris szeparátorral?


- OR
- AND

Keressük meg gradiens módszerrel a következő függvény maximumát:

$\sin(x)$

Majd pedig a következőét:  $x \cdot \sin(x)$

Ha  $x > -10$  és  $x < 10$ ...



# Lineáris szeparálhatóság

Lehetséges-e lineáris szeparálót találni a lenti adathalmazhoz?

|    |    |
|----|----|
| -1 | +1 |
| +1 | -1 |

Mit is jelent ez számunkra a lineáris osztályozók szempontjából?