

2. K-NN sailkatzaileak

Irakasgaia: Datu Meatzaritza

Especialitatea: **Konputazioa**, hirugarren ikasmaila
Titulazioa: **Informatika Ingenieritzako Gradua**
Konputazio Zientzia eta Adimen Artifiziala saila
Universidad de Pais Vasco - Euskal Herriko Unibertsitatea

Sarrera

- ▶ **K-NN:** (K-Nearest Neighbour)
- ▶ Kasu berri bat sailkatzerakoan bere **hurbileneko K** **auzokideen klaseen artean sarrien agertzen den klasea** egokituiko zaio.
- ▶ Ideia simple eta intuitiboa. Inplementazio erraza
- ▶ Ez dago eredu espliziturik. Distantzien kalkuluan oinarritzen da (ikus <http://es.wikipedia.org/wiki/Distancia>)

Notazioa

D datubasea, $X_1, \dots, X_n$ aldagai iragarleak, C klase-aldagaia, N kasu, **x** kasu berria.

D	X_1	...	X_j	...	X_n	C
$(\mathbf{x}_1, c_1)$	x_{11}	...	x_{1j}	...	x_{1n}	c_1
$\vdots$	$\vdots$		$\vdots$		$\vdots$	$\vdots$
$(\mathbf{x}_i, c_i)$	x_{i1}	...	x_{ij}	...	x_{in}	c_i
$\vdots$	$\vdots$		$\vdots$		$\vdots$	$\vdots$
$(\mathbf{x}_N, c_N)$	x_{N1}	...	x_{Nj}	...	x_{Nn}	c_N
x	x_1	...	x_j	...	x_n	?


Oinarrizko K-NN algoritmoa

Algoritmoaren sasikodea

HASIERA
Sarrera: $D = \{(\mathbf{x}_1, c_1), \dots, (\mathbf{x}_N, c_N)\}$
 $\mathbf{x} = (x_1, \dots, x_n)$ sailkatu beharreko kasu berria
ERREPIKATU sailkatutako (x_i, c_i) guztietarako
kalkulatu $d_j = d(\mathbf{x}, \mathbf{x}_j)$
Ordenatu $d(j = 1, \dots, N)$ txikienetik handienera
x-tik hurbilen dauden K kasuekin geratu, D_K^x
x-ri D_K^x -ko sarrieneko klasea esleitu
AMAIERA

Oinarrizko K-NN algoritmoa


Adibide grafikoa: 3-NN, 24 kasu, 2 klase, 2 aldagai iragarle



3 auzokide hurbilenen artean bi 'o' klasekoak, bat '+' klasekoa
3-NN sailkatzaile honek 'o' iragarriko du • kasuarentzat
(K=1 balitz?)

Oinarrizko K-NN algoritmoa

K parametroaren aukeraketa



Erlazioa ez da monotonoa. K bakoitia aukeratzea komeni da

K-NN algoritmoaren aldaerak

1. K-NN bermegabeak baztertuz
2. K-NN batzbesteko distantziarekin
3. K-NN distantzia minimoarekin
4. K-NN aukerutako auzokideen pisaketarekin
5. K-NN aldagaien pisaketarekin


1. Aldaera: K-NN bermegabeak baztertuz

K-NN bermegabeak baztertuz

- ▶ Kasu berri bat sailkatzeko **nahikoa berme** izan behar da
- ▶ Ez izatekotan, **kasua sailkatu gabe utz daiteke**
- ▶ Aurretik **atalase bat** ezartzen da
- ▶ Gehiengo absolutua

2. Aldaera: K-NN batzbesteko distantziarekin

Batzbesteko distantziarik txikieneko klasea esleitu
Adibidea. 7 auzokide hurbilenak hartuz



- kasu berriari + klasea esleitzeko zaio


3. Aldaera: K-NN distantzia minimoarekin

- ▶ **Klase bakoitzerako ordezkari bat aukeratu** (adb. klaseko barizentruetik hurbilen dagoen kasua)
- ▶ Gorde beharreko kasuen fitxategiaren dimentsioa N -tik m -ra murriztuko da
- ▶ 1-NN algoritmoa aplikatu murrizturako fitxategiari
- ▶ Eraginkortasuna klase barruko homogenotasunaren mende dago
- ▶ Klase bateko kasuak multzo edo cluster batean baino gehiagotan banatuta badaude, aldaera ez da egokia gertatzen, ordezkaria ez delako klasearen adierazgarri egokia izango

4. Aldaera: K-NN auzokideen pisaketarekin

- ▶ Kasu guztiek ez dute garrantzia bera. **Auzokide hurbilenei pisu bat egokitu** (distantziaren mendekoa, adibidez)
- ▶ Pisuen baturan oinarrituz emango da klasearen iragarpena

Adibidea



K-NN auzokideen pisaketarekin. Adibidea

- ▶ Pisu distantziaren alderantzizko proportzionala

Adibidea

Auzokide hurbilenak	Klasea C	Distantzia $d(x_i, x)$	Pisua w_i
x_1	O	2	$\frac{1}{2} = 0,5$
x_2	O	2	$\frac{1}{2} = 0,5$
x_3	O	2	$\frac{1}{2} = 0,5$
x_4	O	2	$\frac{1}{2} = 0,5$
x_5	+	0,7	$\frac{1}{0,7} = 1,42$
x_6	+	0,8	$\frac{1}{0,8} = 1,25$

$1,42 + 1,25 > 0,5 + 0,5 + 0,5 + 0,5 \rightarrow +$ klasea iragarriko da

5. Aldaera: K-NN aldagairen pisaketarekin

Aldagai iragarleen pisaketa

- ▶ Aldagai guztiek C klase-aldagaiaren iragarpenerako garrantzia bera ez dutenean erabiltzea komeni da
- ▶ Distantzia eta distantzia ponderatua:

$$d(\mathbf{x}, \mathbf{x}_r) = \sqrt{\sum_{j=1}^n (x_j - x_{rj})^2}, \quad d(\mathbf{x}, \mathbf{x}_r) = \sqrt{\sum_{j=1}^n w_j (x_j - x_{rj})^2}$$

- ▶ X_j aldagaiari w_j pisua egokitu, X_j aldagaiaren eta C klase-aldagaiaren $I(X_j, C)$ elkarrekiko informazioaren neurria erabiliz, adibidez. Informazio-teoria

Kasuen aukeraketa

- ▶ Datubaseetatik kasuen aukeraketa egin daiteke, sailkatzaile **azkarragoak** eta **hobeak** lortzeko.
 - ▶ Distantzien kalkuluan oinarritutako K-NN teknikak **kostu konputazional handia** izaten dute datubase handietarako.
 - ▶ Datubasean **gaizki etiketatutako kasuak** badaude, K-NN sailkatzailearen **asmatze-tasa jaitsi** egingo da.
- ▶ Bi teknika: edizio-teknikak eta kondentsazio-teknikak.
 - ▶ **Edizio-teknikak**: datubasean zarata sortzen duten kasuak kenduz, erabaki-muga leunak sortzen saiatzen dira
 - ▶ **Kondentsazio-teknikak**: jatorrizko datubaseko kasuetatik indutitutako erabaki-mugak mantentzen saiatzen dira
- ▶ Datubase murriztua erabiliko da sailkatzailea sortzeko

Ediziorako-teknikak: Wilson-en edizioa

- ▶ Klaseen arteko mugak garbitu, gainjarritako kasuak kenduz
- ▶ K-NN sailkatzaileak gaizki sailkatutako lituzkeen kasuak datubasetik kendu

Wilson-en ediziorako sasikodea

- ▶ Errepikatu / guztietarako
 - ▶ Datubaseko $X_1, \dots, X_{i-1}, X_{i+1}, \dots, X_n$ kasuen artean **K auzokide hurbilenak aurkitu**
 - ▶ X_i kasuari bere auzokide hurbilenen artean **sarrien agertzen den klasea esleitu**
- ▶ Esleitutako klasea eta klase erreala **bat ez datozen kasu guztiak datubasetik ezabatu**

Kondentsazio-teknikak: Hart-en kondentsazioa

Hart-en kondentsaziorako sasikodea

1. Datubaseko lehenengo kasua **STORE** zerrendan gorde
2. Datubaseko bigarren kasuaren iragarpena egin **STORE**-ko kasuetan oinarrituz. Sailkapena zuzena bada, **GRABBAG** zerrendan sartu, bestela **STORE**-en sartu
3. Modu berean jarraitu datubaseko kasu guztiekin
4. Datubaseko kasu guztiak aztertu ondoren, **GRABBAG** zerrendakoekin prozedura errepikatu behin eta berriz. Prozesuaren amaiera bi modutara lor daiteke:
 - ▶ **GRABBAG** zerrenda hutsa dago (kasu guztiak **STORE** zerrendan daude)
 - ▶ **GRABBAG** zerrendako kasu guztiak aztertu ondoren bat bera ere **STORE** zerrendara ez da pasa
5. **GRABBAG**-eko kasuak datubasetik ezabatu

Oinarrizko bibliografia

- ▶ Liburua: **Aprendizaje Automático: conceptos básicos y avanzados**
 - ▶ **Capítulo 3: Algoritmos de clasificación por vecindad**
- ▶ Koordinatzailea: Basilio Sierra Araujo
- ▶ Departamento de Ciencias de la Computación e Inteligencia Artificial, Universidad del País Vasco
- ▶ Argitaratzailea: Pearson Prentice Hall, 2004
- ▶ ISBN 10: 84-8322-318-X, ISBN 13: 978-84-8322-318-5