

T061215

1a) Kriteriet är

$$J(\bar{m}_1, \bar{m}_2, \dots, \bar{m}_K) = \sum_{k=1}^K \sum_{x \in C_k} \|x - \bar{m}_k\|^2$$

C_k : kluster k

J = summan av spridning runt respektive klustercentrum


J liten innebär att $\bar{m}_1, \dots, \bar{m}_K$ är bra representanter.

1b)

1. Beräkna distansmatris D med element D_{ij}
 2. Identifiera det par (p, q) av kluster med kortast avstånd.
 3. Slå ihop (p, q) till ett kluster och räkna om motsvarande avstånd till en ny distansmatris.
- För att kunna räkna ut nya avstånd måste det finnas en definition för hur avstånd mellan grupper av observationer. Detta mått måste i sin tur bygga på en definition av avstånd mellan två individuella observationer.


1c)

Farthest neighbor = d_{max} = avståndet mellan det par av exempel som ligger längst ifrån varandra

Ex.

d_{min} = Nearest neighbor = avståndet mellan det par av exempel som ligger närmast varandra.

1d)

Ex.

Den hierarkiske klustringen kommer förstås att slå ihop alla exempel som tillhör ett kluster innan nästa påbörjas

1e) PCA: I princip har kalle endast fem observationer $\bar{x}_1, \bar{x}_2, \bar{x}_3, \bar{x}_4, \bar{x}_5$ som motsvarar var sitt kluster

⇓


$$C_{xx} = \frac{1}{5} \sum_{n=1}^5 (\bar{x}_n - \hat{m})(\bar{x}_n - \hat{m})$$

$$\hat{m}_x = \frac{1}{5} \sum_{n=1}^5 \bar{x}_n$$

⇓

C_{xx} har rang 4 $\Rightarrow$ 6 egenvärde är noll.

2a)




b)

Linjära klassifikationer överanpassar sig normalt inte lika mycket som olinjära & flexibla motsvarigheter

2c) Fisher: $\bar{y} = \underline{W}^T \bar{x}$

Linjär extraktion av särdrag $\bar{y}$ som separerar väl mellan klasserna och har relativt liten intern varians.


2d)



2e)

Alla beslut tas genom att studera värden på ett särdrag i taget $\Rightarrow$ uppdelning av datarummet i rektanglar, se 2d ovan.

3a



(a) Optimalt att välja w_1 om

$$p(w_1|x) > p(w_2|x)$$

$$\Downarrow$$

$$p(x|w_1) > p(x|w_2)$$

$$\Downarrow$$

Välj klass w_1 för alla ~~observationer~~ i regionen $[0,1] \times [0,1]$. obs! Gör endast fel med w_2 -exempel.

(b) $p_1 = 19\%$ $p_2 = 81\%$

$$\Downarrow$$

$$p(w_1|x) = \frac{p(x|w_1) \cdot p_1}{p(x)} = \frac{\overbrace{p(x|w_1)}^1 \cdot 0.19}{p(x)}$$

$$= \frac{0.19}{p(x)}$$

$$p(w_2|x) = \frac{p(x|w_2)p_2}{p(x)} = \frac{\frac{1}{4} \cdot 0.81}{p(x)} = \frac{0.2025}{p(x)}$$

$\Rightarrow$ Välj alltid w_2 ! $\Rightarrow$ 100% fel på w_1

(c) Extremt dyrt att klassa w -exempel fel



Mask klassa alla rätt från klass w_1



Lägg beslutsgränsen som i (a) så att de enda fel som ~~hitta~~ kommer att ske är felklassningarna ~~av~~ av exempel från w_2 .

4 a)

~~$X = B * rand(10000,$~~


$$X = B * randn(3, 10000);$$

b) PCA: Hitta det underrum där variansen är störst. Kolumnerna i X har ingen spridning utanför det rum som spänns av kolumnerna i B .



PCA kommer att ge ~~för~~ egenvektorer med egenvärden som är längst ifrån noll. Dessa ~~för~~ spänne upp samma rum som kolumnerna i B .

5a)




1. Dela N exempel i k block
2. Gör design m.h.a. $N-1$ block, testa prestanda med exemplen i det utelämnade blocket $\Rightarrow \hat{e}_k$
3. Upprepa 2 för alla k möjligheter där ett block utelämnas
4. Beräkna estimate av prestanda genom att ta medelvärde av de k prestanda estimate $\hat{e}_k$

$$\hat{e}_{cv} = \frac{1}{k} \sum_{k=1}^k \hat{e}_k$$

5b) $\hat{e}_{cv} = 15\%$

men slutdesign $\Rightarrow 35\% !!$

Antag "pror" - fördelning $P(e|N)$
som är bred: Inte osannolikt att få



dålig prestanda p.g.a. att designexemplen inte balancerade


Sc) Bayes satz

$$P(e | h_t, N_t) = \frac{P(h_t | e, N_t) P(e | N_t)}{P(h_t)}$$

$$= \frac{\binom{N}{h} e^h (1-e)^{N-h} \cdot \overbrace{P(e)}^{=1 \text{ uniform } p \in [a,1]}}{P(h_t)}$$


$\Downarrow$

$$P(e | h_t, N_t) = \frac{e^h (1-e)^{N-h}}{\int_a^1 e^h (1-e)^{N-h} de}$$



Bayesianscher
Kreditintervall
 $[a, b]$.

6



- (b) Marginalfördelningarna för x_6 och x_7 är identiska för w_1 och w_2 : Var för sig är alltså särdrag helt utan information om klass tillhörighet.
- ⇓
- En särdragsalgoritm som endast studerar ett särdrag i taget skulle aldrig upptäcka att x_6 och x_7 är informativa tillsammans.