

- 1 a)
- särdrag tolkt som beroende  $\Rightarrow$  redundans
  - Bästa generalisering i klassificeraren - minskar risk för överanpassning
  - enklare tolkning

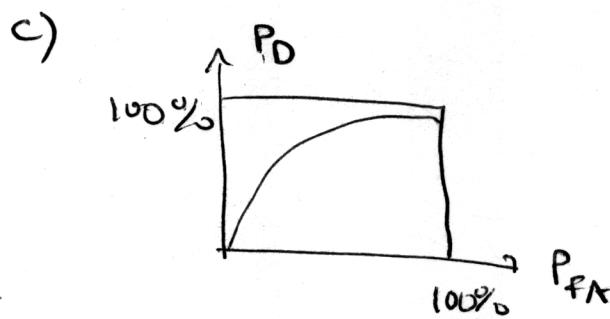
b) kNN: Långsam respons!

c) Se svar i a). Kan bli sämre om verkliga särdrag är ganska oberoende men informativa

2. a)

$$\frac{\frac{-\frac{1}{2}(x-1)^2}{e}}{\sqrt{2\pi}} < \frac{-\frac{x^2}{2}}{\sqrt{2\pi}} \Rightarrow \text{klass 1}$$

b) Flyttar så att fånt exempel klasser till  $w_2$



3 a)  $\tilde{x}_i = \frac{x_i - m_x}{\sigma_i}$

b)  $\tilde{y} = \tilde{\alpha}' \tilde{x}$   $\hat{x} = D(\tilde{x} - \bar{m}_x)$

$$D_{ii} = 1/\sigma_i$$

$$\tilde{y} = \frac{y - m_y}{\sigma_y}$$

$$\frac{y - m_y}{\sigma_y} = \tilde{\alpha}' D \tilde{x} - \bar{m}_y$$

$$y = \underbrace{\tilde{\alpha}' D \tilde{x}}_{\tilde{w}} + \underbrace{m_y - \tilde{\alpha}' D \bar{m}_x}_{w_0}$$

c)  $\lambda^* = 0 \Rightarrow \text{OLS ok}$

4. a) PCR = PCA + OLS

b) (i) Flöende variable konserverade  $\Rightarrow$   
stora variancer i OLS-estimat

(ii) Att först exponerat  $\Rightarrow$  OLS lösning  
existerar ej

c)  $J(\tilde{w}) = \frac{1}{N} \sum_{n=1}^N (y_n - \tilde{w}' \tilde{x})^2$

$$\frac{\partial J}{\partial \tilde{w}} = - \frac{2}{N} \sum_{n=1}^N (y_n - \tilde{w}' \tilde{x}) \tilde{x}_n = 0$$

$$\tilde{w}_{OLS} = \left( \frac{1}{N} \sum_{n=1}^N \tilde{x}_n \tilde{x}_n' \right)^{-1} \left( \frac{1}{N} \sum_{n=1}^N \tilde{x}_n y_n \right)$$

$$\frac{1}{N} \sum_{n=1}^N y_n \tilde{x}_n = \left( \frac{1}{N} \sum_{n=1}^N \tilde{x}_n \tilde{x}_n' \right) \tilde{w}$$

6 a) ~~bestämta~~

Punktskattningen  $\frac{2}{20} = 10\%$  säger  
möt lite. ~~ta~~

Osäkerheten om var  $e_T$  ligger kan  
beskrivas via  $p(e_T | h, N)$ . Denna  
osäkerhetsfördelning har nästan all massa  
koncentrerat till intervallen  $[2\%, 28\%]$   
dvs "troligen" ligger  $e_T$  på detta intervall.

b)

- ⊕ Får info om prestanda vid design med  
 $N-1 \approx N$  exemplar
- ⊖ Får ingen info specifikt för den  
klassificering som sedan tillämpas.

7a)

$$J(\bar{w}) = \frac{m_2 - m_1}{\sigma_1^2 + \sigma_2^2}$$

projekteras  $y = \bar{w}^\top \bar{x}$  såsom att  $J(\bar{w})$   
maximeras  $\Rightarrow$  "Bästa" separator av klasserna

7b)

$$J(\bar{w}) = \|\bar{y} - \cancel{\bar{w}}^\top \bar{w}\|^2$$

7c

$$\hat{y}_i = \begin{cases} \begin{bmatrix} 1 \\ \hat{x}_i \end{bmatrix} & \text{on } \hat{x}_i \in \text{Klass 1} \\ \begin{bmatrix} -1 \\ -\hat{x}_i \end{bmatrix} & \text{on } \hat{x}_i \in \text{Klass 2} \end{cases}$$

$$\hat{w}^T \hat{x}_i > 0 \Rightarrow \text{Klass 1}$$

$$[-\theta \quad \hat{w}^T] \begin{bmatrix} 1 \\ \hat{x}_i \end{bmatrix} > 0 \Rightarrow \text{Klass 1}$$

$$\hat{v}^T \hat{x}_i > 0 \Rightarrow \text{Klass 1. Ingen fel om } \hat{x}_i \in \text{Klass 1}$$

$$\Rightarrow \text{Fel om } \hat{v}^T \hat{x}_i > 0 \text{ men } \hat{x}_i \in \text{Klass 2}$$

eller

$$\hat{v}^T \hat{x}_i < 0 \text{ men } \hat{x}_i \in \text{Klass 1}$$

$$\Rightarrow \text{Fel om } \hat{v}^T \hat{y}_i < 0$$