

Apprentissage non-supervisé

1

- Typologie de la **réduction de dimension**

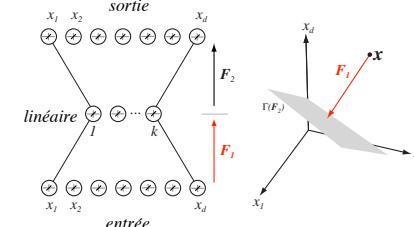
- méthode de base: **ACP**
- “groupement (clustering) des dimensions”
- extensions:
 - **ACP non-linéaire (NLP PCA)**
 - échelonnement multidimensionnel (multidimensional scaling – MDS)
 - cartes auto-organisatrices (self-organizing maps – SOM)
 - local linear embedding (LLE)
 - ISOMAP
 - courbes principales (principal curves)

Apprentissage non-supervisé

2

- ACP non-linéaire – **auto-encodage**

- modèle de réseau de ACP

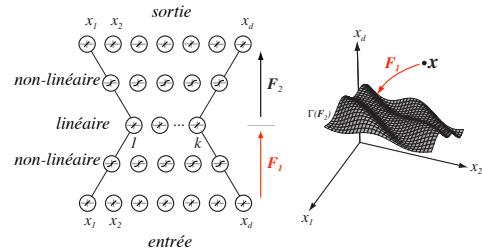


Apprentissage non-supervisé

3

- ACP non-linéaire – **auto-encodage**

- extension **non-linéaire**

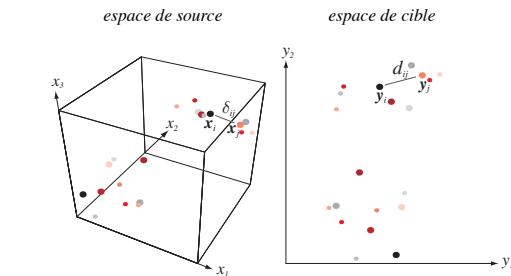


Apprentissage non-supervisé

4

- Échelonnement multidimensionnel (MDS)

- représentation de dimension réduite qui **préserve les distances**



Apprentissage non-supervisé

5

- Échelonnement multidimensionnel (MDS)

- fonctions d'erreur

- $J_{ee} = \frac{\sum_{i < j} (d_{ij} - \delta_{ij})^2}{\sum_{i < j} \delta_{ij}^2}$

- $J_{ff} = \sum_{i < j} \left(\frac{d_{ij} - \delta_{ij}}{\delta_{ij}} \right)^2$

- $J_{ef} = \frac{1}{\sum_{i < j} \delta_{ij}} \sum_{i < j} \frac{(d_{ij} - \delta_{ij})^2}{\delta_{ij}}$

Apprentissage non-supervisé

6

- Échelonnement multidimensionnel (MDS)

- minimisation

- descente de gradient standard

- initialisation

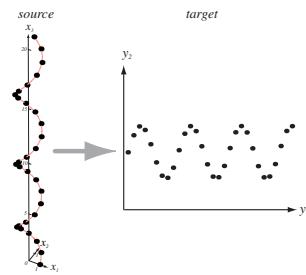
- les d' coordonnées avec les variances plus grandes

- ACP avec d' composantes

Apprentissage non-supervisé

7

- Échelonnement multidimensionnel (MDS)



Apprentissage non-supervisé

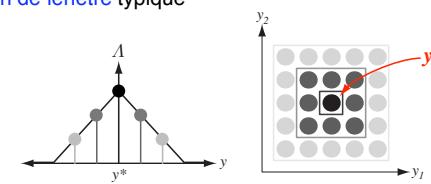
8

- Cartes auto-organisatrices (SOM)

- x_i appartient à V_ℓ avec un poids $\mathbf{W}_{i,\ell}$

- $\mathbf{W}_{i,\ell}$ ne dépend que de la distance entre \mathbf{v}_ℓ et $\mathbf{v}(x_i)$

- fonction de fenêtre typique



Apprentissage non-supervisé

9

- Cartes auto-organisatrices (SOM)

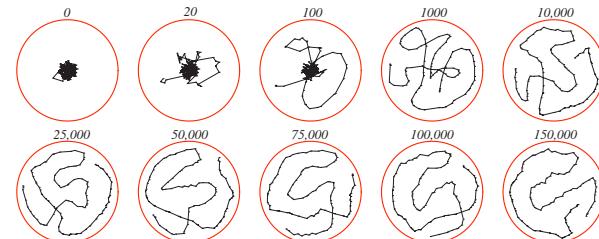
```
SOM( $X_n$ )
1    $C^{(0)} \leftarrow \{\mathbf{v}_1^{(0)}, \dots, \mathbf{v}_k^{(0)}\}$ 
2    $j \leftarrow 0$ 
3   faire
4     recalculer  $\mathbf{W}^{(j)}$ 
5     pour  $\ell \leftarrow 1$  à  $k$  faire
6        $\mathbf{v}_\ell^{(j+1)} \leftarrow \frac{1}{n} \sum_{i=1}^n \mathbf{W}_{i,\ell}^{(j)} \mathbf{x}_i$ 
7      $j \leftarrow j + 1$ 
8   jusqu'à changement > seuil
```

Apprentissage non-supervisé

10

- Cartes auto-organisatrices (SOM)

- 2 dimensions → 1 dimension

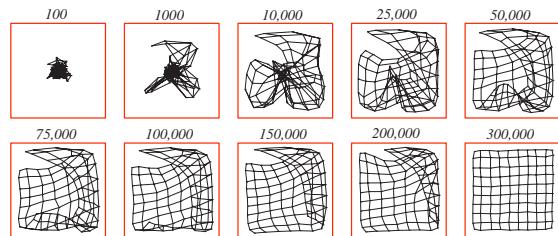


Apprentissage non-supervisé

11

- Cartes auto-organisatrices (SOM)

- 2 dimensions → 2 dimensions

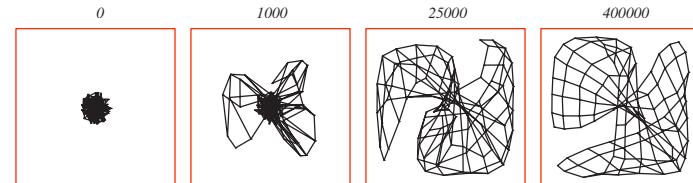


Apprentissage non-supervisé

12

- Cartes auto-organisatrices (SOM)

- problème: minimum local

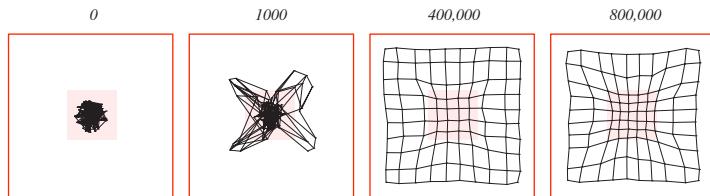


Apprentissage non-supervisé

13

- Cartes auto-organisatrices (SOM)

- estimation de densité



Apprentissage non-supervisé

14

- Cartes auto-organis. (SOM) – théorie de communication

- Codage de **source** – quantification vectorielle:

$$\bullet \text{fonction d'erreur: } J_s = \sum_{i=1}^n \|\mathbf{x}_i - \mathbf{v}_{(\mathbf{x}_i)}\|^2$$

Apprentissage non-supervisé

15

- Codage de **canal** – correction d'erreur:

- probabilité d'erreur d'un bit: p

- distance de Hamming entre des mots de code: $d_{i,j} = d_H(c(\mathbf{v}_i), c(\mathbf{v}_j))$

- probabilité d'erreur de **code**: $p_{i,j} = p^{d_{i,j}}(1-p)^{d-d_{i,j}}$

- fonction d'erreur: $J_c = \sum_{i=1}^n \sum_{j=1}^c \|\mathbf{v}_{(\mathbf{x}_i)} - \mathbf{v}_j\|^2 p_{x_i,j}$

- Codage **conjoint de canal-source**

- fonction d'erreur: $J_{s+c} = \sum_{i=1}^n \sum_{j=1}^c \|\mathbf{x}_i - \mathbf{v}_j\|^2 p_{x_i,j}$

Apprentissage non-supervisé

16

- Problème générale: surfaces compliquées → **minima local**

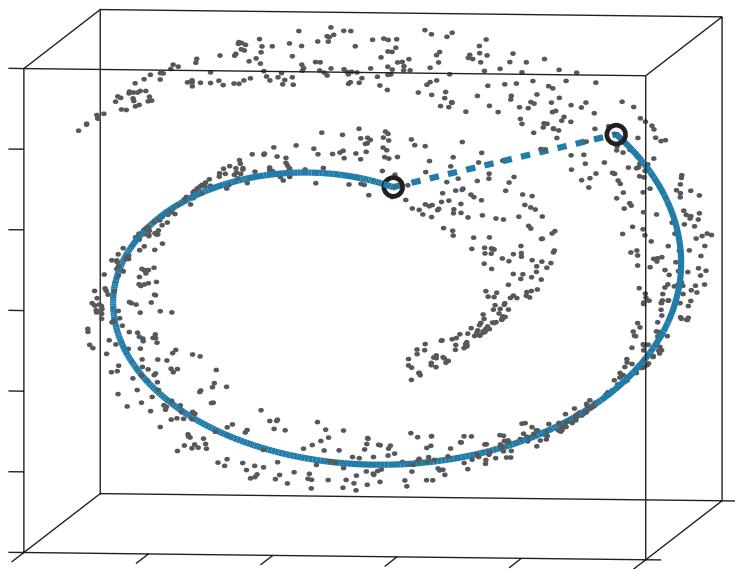
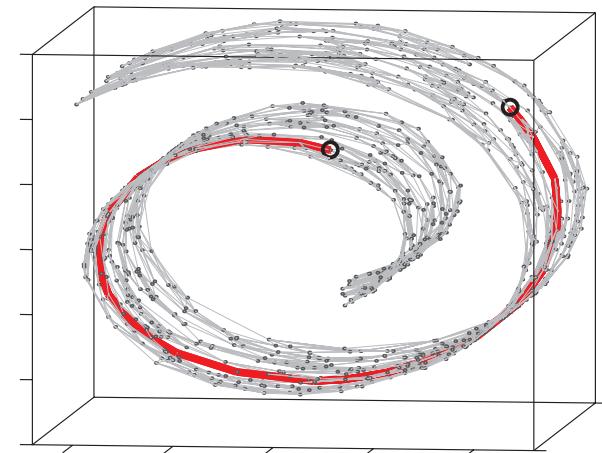
- Solution 1: ISOMAP

- **distance géodésique**: chemins plus courts dans le graphe de similitude

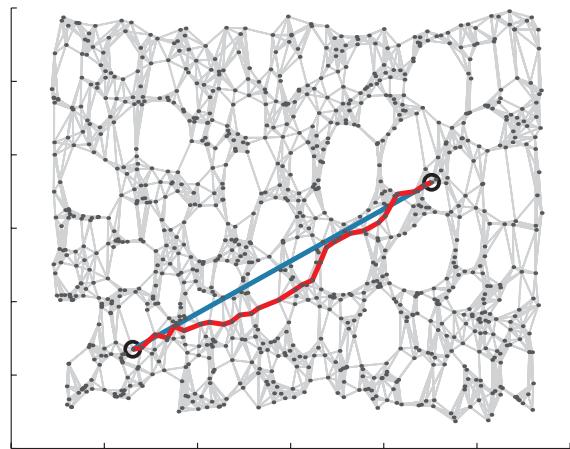
- MDS standard sur les distances géodésiques

18

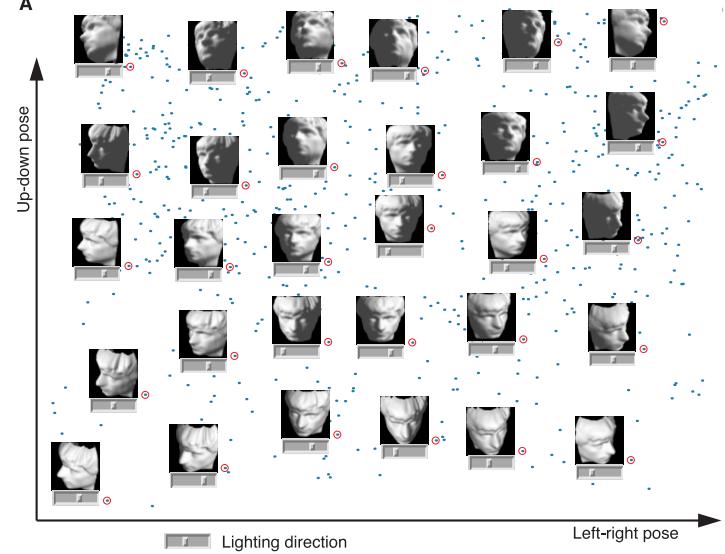
C

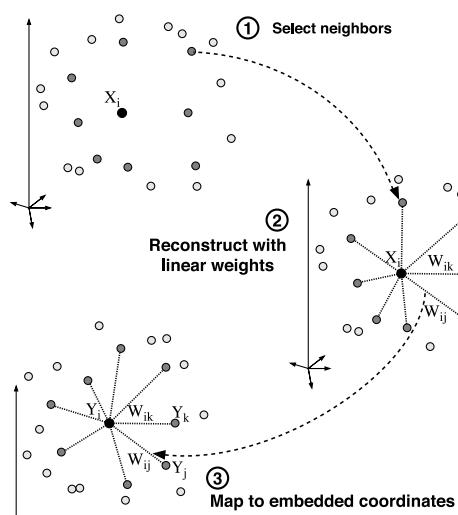
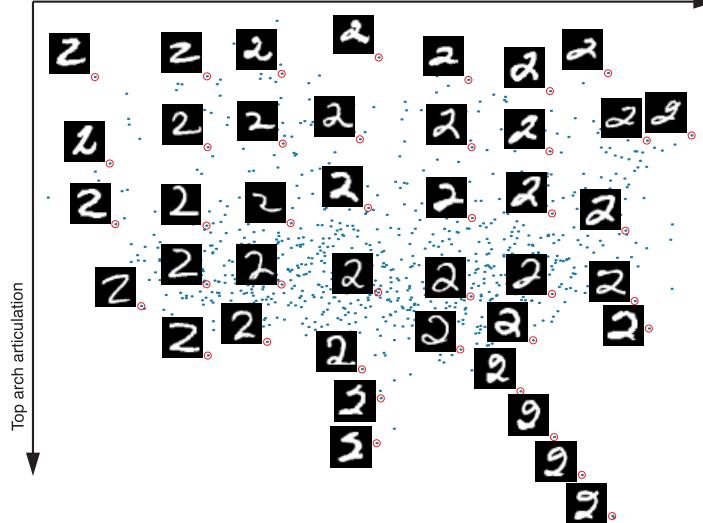


19



A





Apprentissage non-supervisé

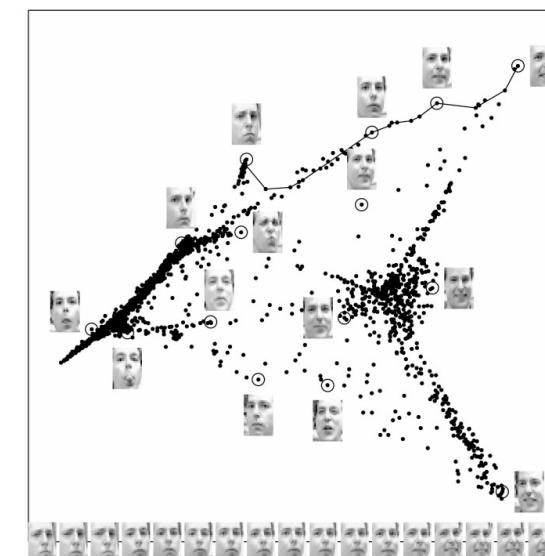
Solution 2: Local linear embedding (LLE)

- Étape 1: trouver l'ensemble des voisins V_{x_i}
- Étape 2: approximer les points avec une combinaison linéaire de leurs plus proches voisins:

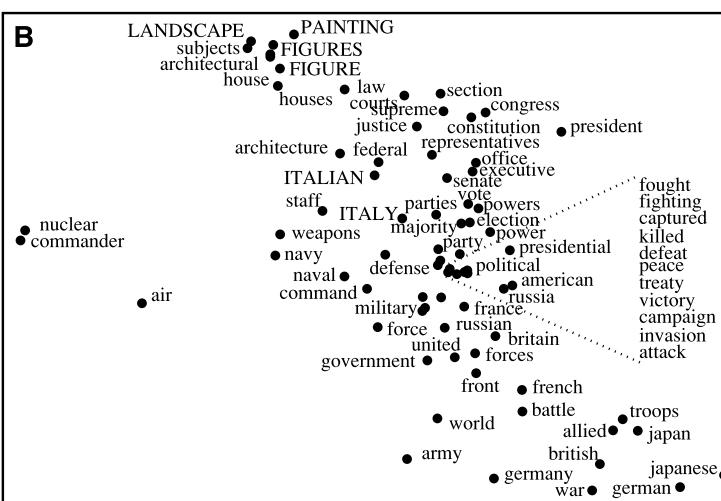
$$\min_w \sum_{i=1}^n \left\| \mathbf{x}_i - \sum_{j \in V_{x_i}} w_{i,j} \mathbf{x}_j \right\|^2$$

- Étape 3: reconstruire les points dans l'espace de projection en utilisant les mêmes poids:

$$\min_y \sum_{i=1}^n \left\| \mathbf{y}_i - \sum_{j \in V_{x_i}} w_{i,j} \mathbf{y}_j \right\|^2$$



This cost
based on
but here
minizing th
cost in E
vectors \mathbf{Y}
the prob
by solvin
lem (9),
tors prov
coordinat
Imple
straightfor
points we
est neigh
tance or



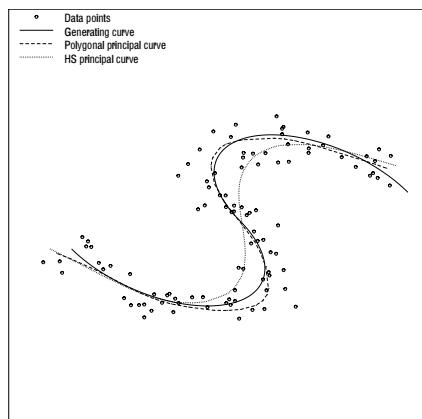
Apprentissage non-supervisé

- désavantage d'ISOMAP:

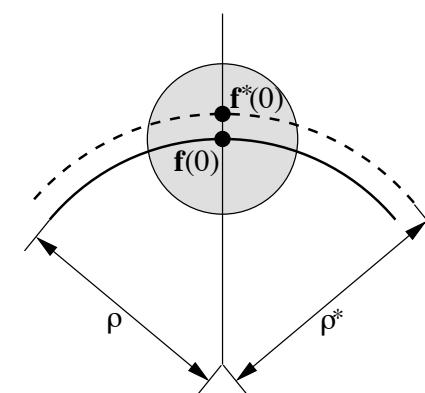
- temps d'exécution: $O(n^3)$
- projeter des nouveaux points
 - construire la fonction de projection explicitement
 - problème d'interpolation
- problème d'apprentissage supervisé (régression multidimensionnelle)

Apprentissage non-supervisé

- Problème: bruit



- Le biais du modèle

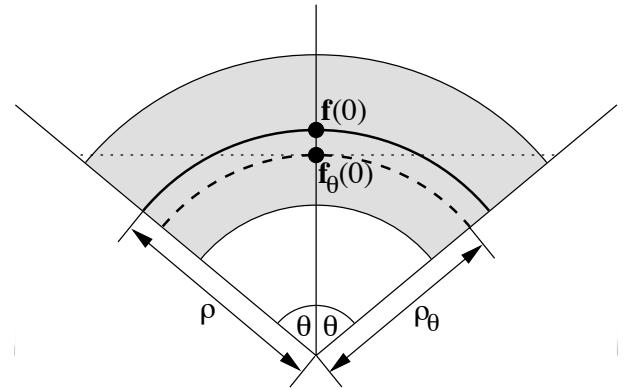


Apprentissage non-supervisé

Apprentissage non-supervisé

29

- Le biais de l'estimation

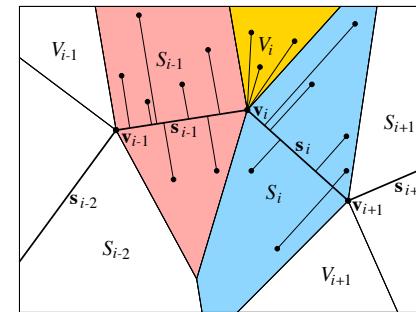


Apprentissage non-supervisé

30

- Solution: courbes principales polygonales

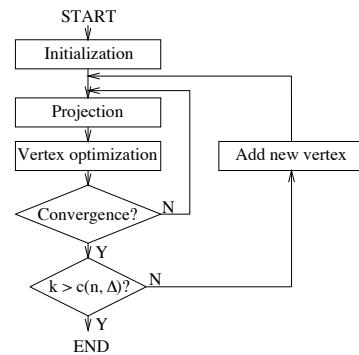
- Mesurer la distance de la courbe au lieu des sommets



Apprentissage non-supervisé

31

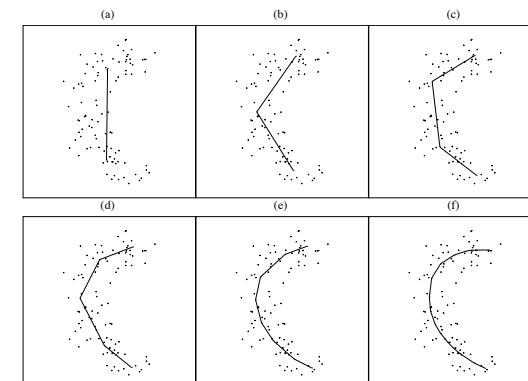
- Courbes principales polygonales



Apprentissage non-supervisé

32

- Courbes principales polygonales

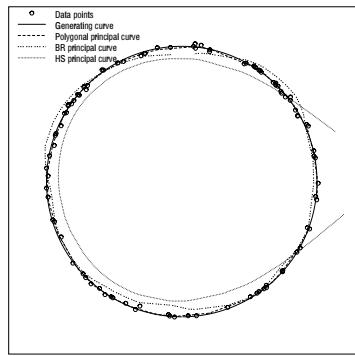


Apprentissage non-supervisé

33

- Courbes principales polygonales

- bruit réduit

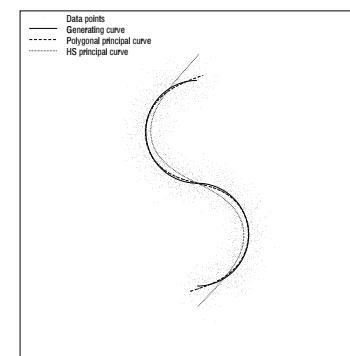


Apprentissage non-supervisé

34

- Courbes principales polygonales

- beaucoup de points

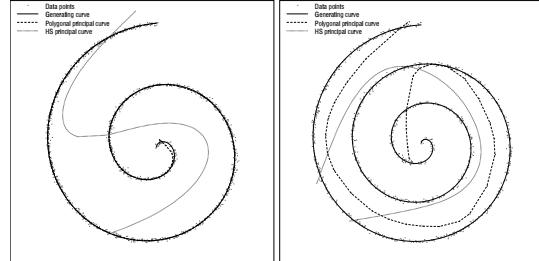


Apprentissage non-supervisé

35

- désavantages des courbes principales:

- minima locaux

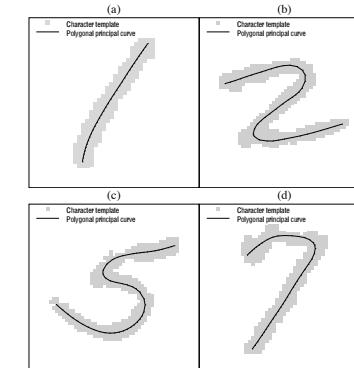


- extension aux surfaces n'est pas évident
→ la plupart des applications sont dans le traitement d'image

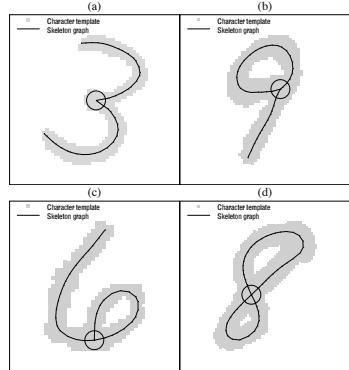
Apprentissage non-supervisé

36

- Skeletisation des caractères



- Skeletisation des caractères



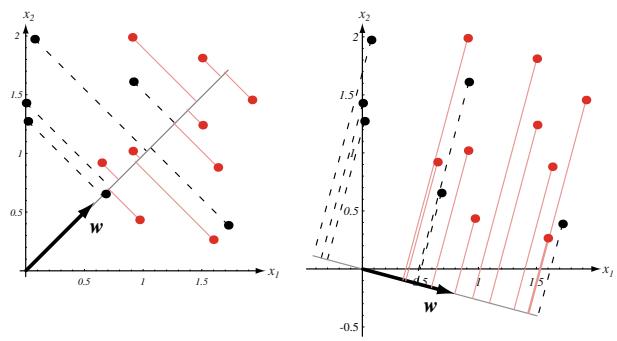
- Apprentissage non-supervisé pour la classification: analyse discriminante

- but: trouver la meilleure projection qui préserve l'information discriminante

- Discriminante de Fisher

- $y = \mathbf{w}^T \mathbf{x}$

- Analyse discriminante



- Idée 1: séparer les moyennes projetées

- $\bar{\mathbf{x}}_i = \frac{1}{n_i} \sum_{\mathbf{x} \in D_i} \mathbf{x}$

- $\tilde{\mathbf{m}}_i = \frac{1}{n_i} \sum_{y \in Y_i} y = \frac{1}{n_i} \sum_{\mathbf{x} \in D_i} \mathbf{w}^T \mathbf{x}$

- trouver \mathbf{w} qui maximise $|\tilde{\mathbf{m}}_1 - \tilde{\mathbf{m}}_2| = |\mathbf{w}^T (\bar{\mathbf{x}}_1 - \bar{\mathbf{x}}_2)|$

- Idée 2: séparer les moyennes projetées normalisées par les variances par classe

- $\hat{s}_i^2 = \sum_{y \in Y_i} (y - \tilde{\mathbf{m}}_i)^2$

- $J(\mathbf{w}) = \frac{(\tilde{\mathbf{m}}_1 - \tilde{\mathbf{m}}_2)^2}{\hat{s}_1^2 + \hat{s}_2^2}$

- Maximiser $J(\mathbf{w})$:

- $\mathbf{S}_i = \sum_{\mathbf{x} \in D_i} (\mathbf{x} - \mathbf{x}_{-i})(\mathbf{x} - \mathbf{x}_{-i})^t$

- $\mathbf{S}_W = \mathbf{S}_1 + \mathbf{S}_2$

- $\tilde{s}_i^2 = \sum_{\mathbf{x} \in D_i} (\mathbf{w}^t \mathbf{x} - \mathbf{w}_i^t)^2 = \sum_{\mathbf{x} \in D_i} \mathbf{w}^t (\mathbf{x} - \mathbf{x}_{-i}) (\mathbf{x} - \mathbf{x}_{-i})^t \mathbf{w} = \mathbf{w}^t S_i \mathbf{w}$

- $\tilde{s}_1^2 + \tilde{s}_2^2 = \mathbf{w}^t S_W \mathbf{w}$

- $\mathbf{S}_B = (\mathbf{1} - \mathbf{2})(\mathbf{1} - \mathbf{2})^t$

- $(\tilde{m}_1 - \tilde{m}_2)^2 = (\mathbf{w}_1^t - \mathbf{w}_2^t)^2 = \mathbf{w}^t (\mathbf{1} - \mathbf{2})(\mathbf{1} - \mathbf{2})^t \mathbf{w} = \mathbf{w}^t S_B \mathbf{w}$

- $J(\mathbf{w}) = \frac{\mathbf{w}^t S_B \mathbf{w}}{\mathbf{w}^t S_W \mathbf{w}}$

- $\mathbf{w}_{max} = S_W^{-1} (\mathbf{1} - \mathbf{2})$