

Apprentissage non-supervisé

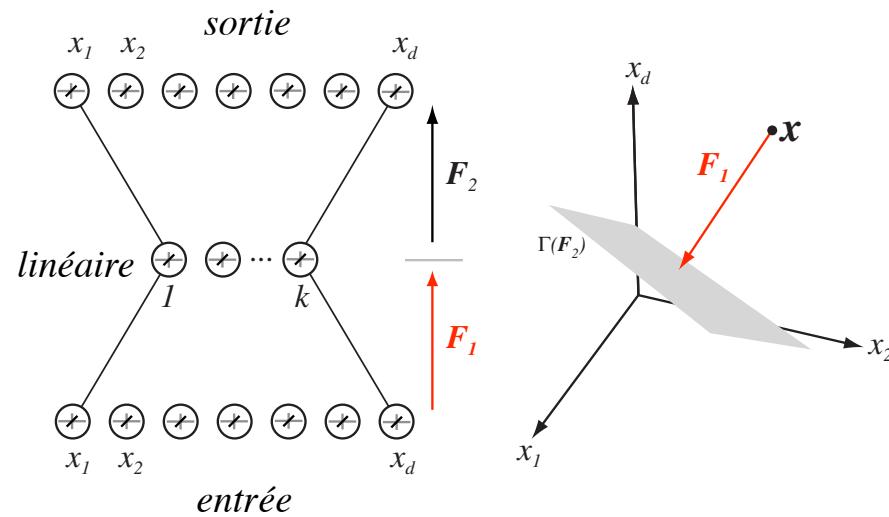
- Typologie de la réduction de dimension

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

Apprentissage non-supervisé

- ACP non-linéaire – [auto-encodage](#)

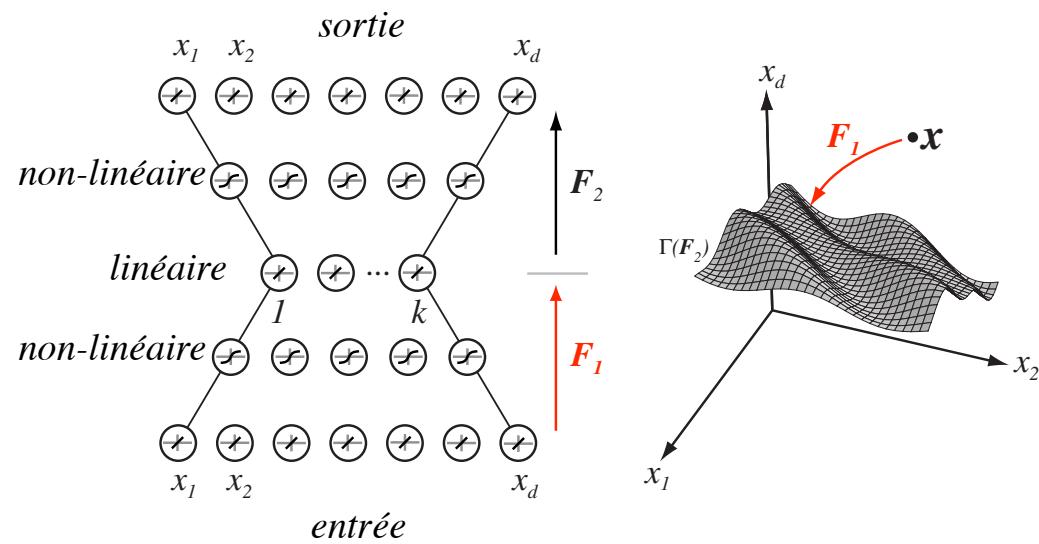
 - modèle de réseau de ACP



Apprentissage non-supervisé

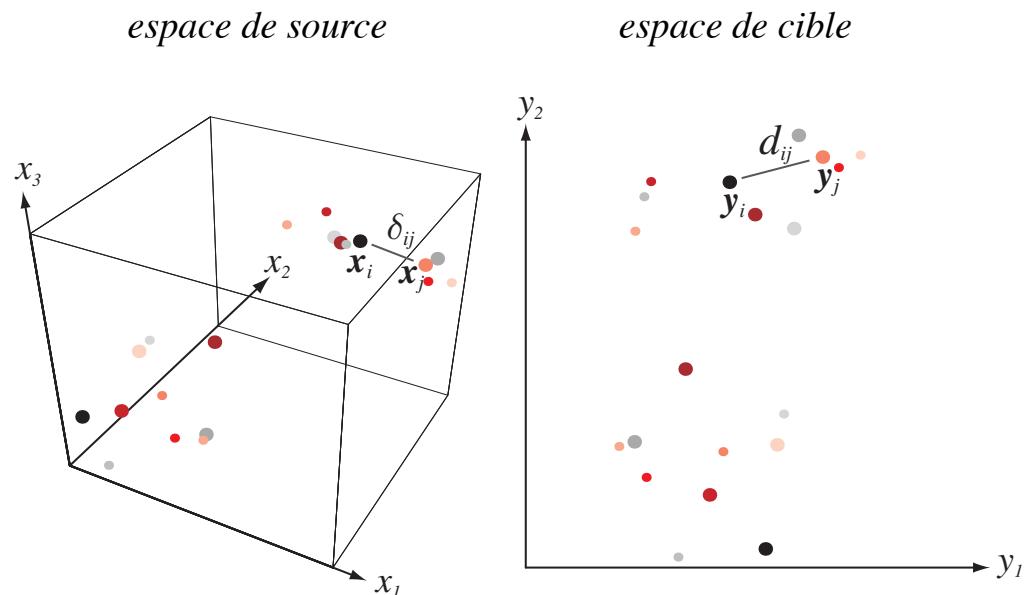
- ACP non-linéaire – auto-encodage

 - extension non-linéaire



Apprentissage non-supervisé

- Échelonnement multidimensionnel (MDS)
 - représentation de dimension réduite qui préserve les distances



Apprentissage non-supervisé

- Échelonnement multidimensionnel (MDS)

- fonctions d'erreur

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

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

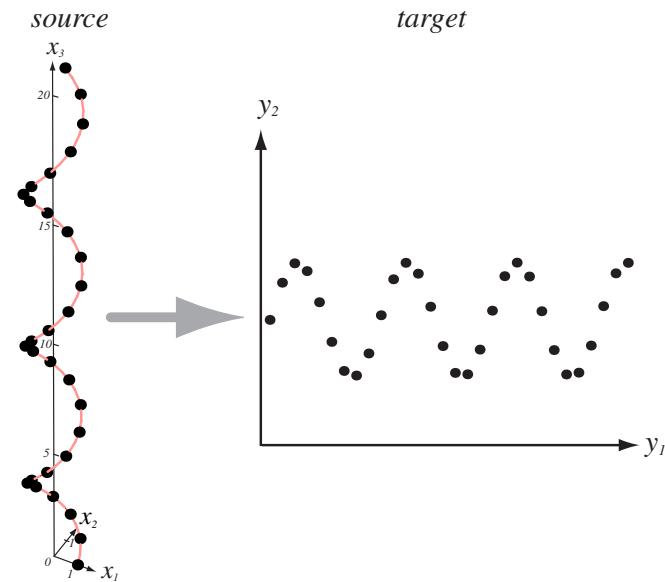
$$\bullet J_{ef} = \frac{1}{\sum_{i < j} \delta_{ij}} \sum_{i < j} \frac{(d_{ij} - \delta_{ij})^2}{\delta_{ij}}$$

Apprentissage non-supervisé

- Échelonnement multidimensionnel (MDS)
 - minimisation
 - descente de gradient standard
 - initialisation
 - les d' coordonnées avec les variances plus grandes
 - ACP avec d' composantes

Apprentissage non-supervisé

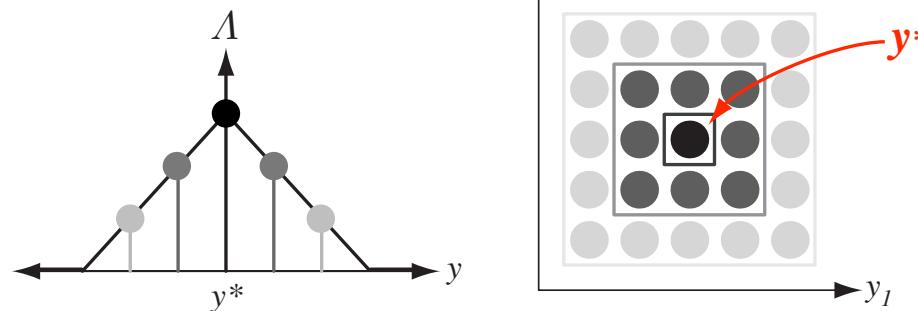
- Échelonnement multidimensionnel (MDS)



Apprentissage non-supervisé

- Cartes auto-organisatrices (SOM)

- \mathbf{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 $\mathbf{v}_{(\mathbf{x}_i)}$**
- **fonction de fenêtre** typique



Apprentissage non-supervisé

- 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

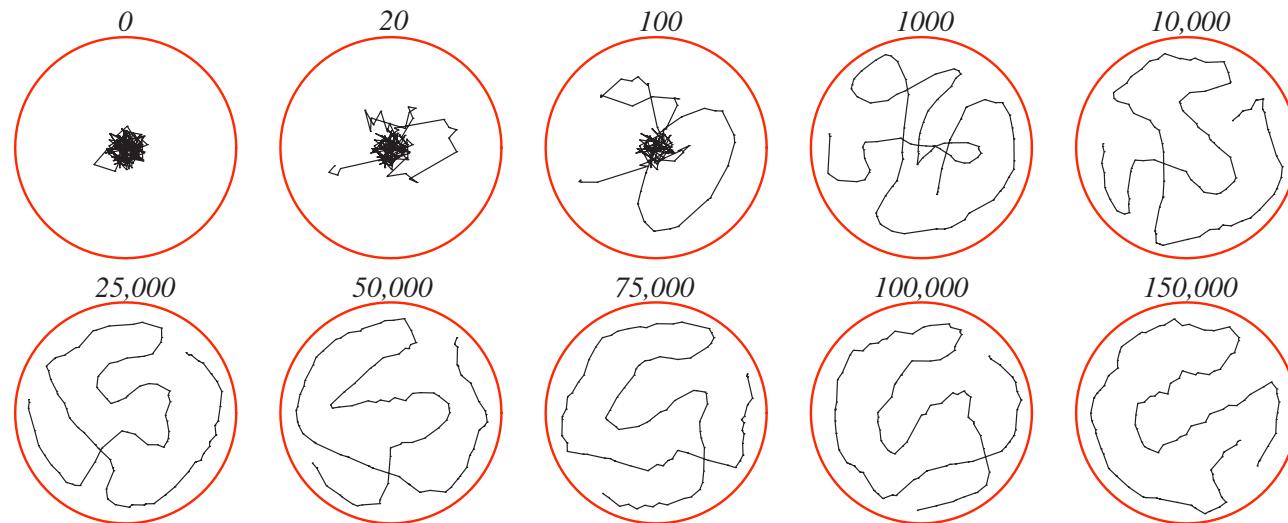
```

Apprentissage non-supervisé

10

- Cartes auto-organisatrices (SOM)

- 2 dimensions → 1 dimension

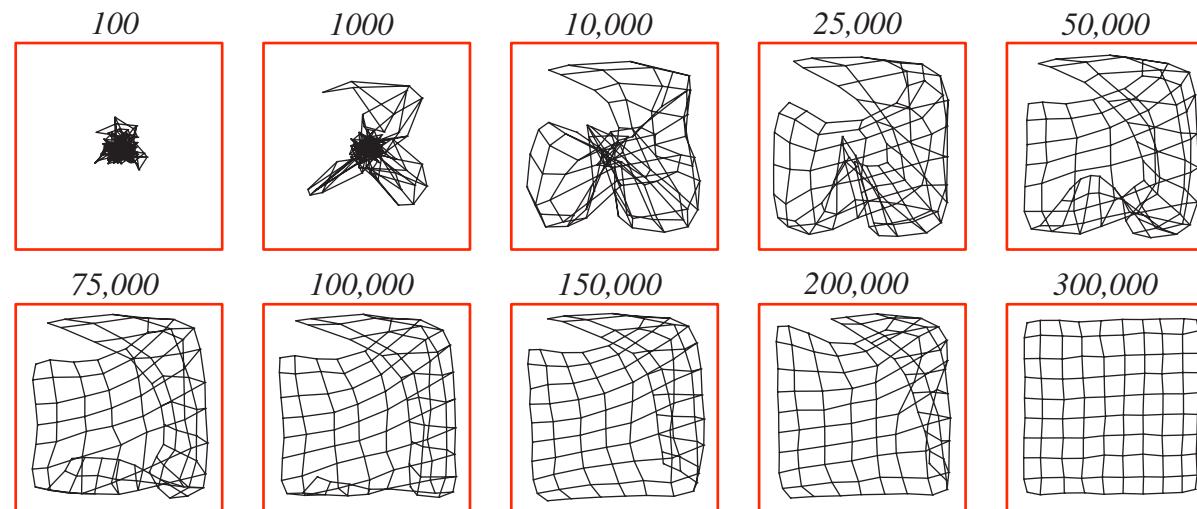


Apprentissage non-supervisé

11

- Cartes auto-organisatrices (SOM)

- 2 dimensions → 2 dimensions

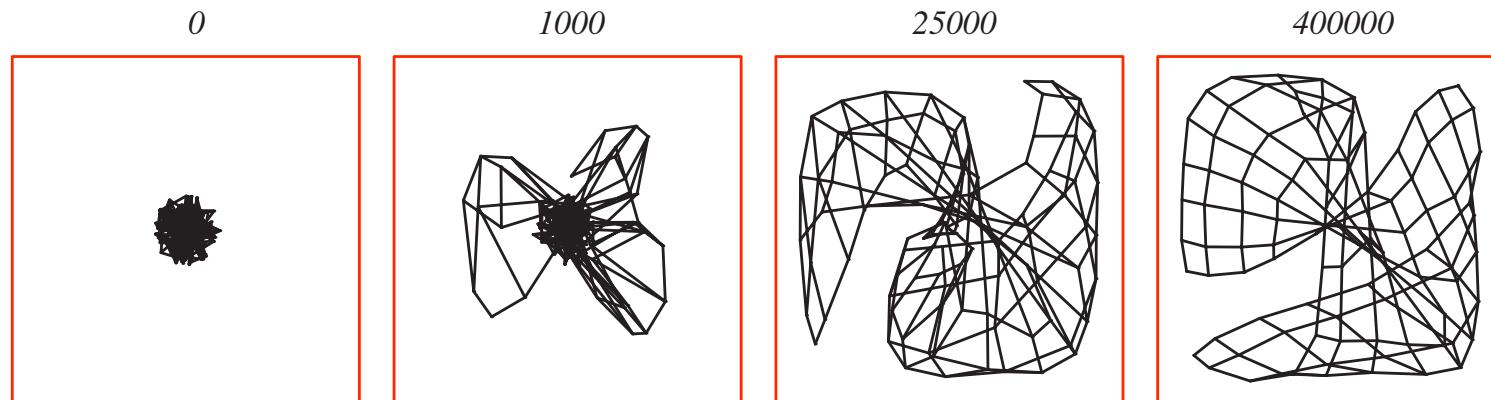


Apprentissage non-supervisé

12

- Cartes auto-organisatrices (SOM)

- problème: **minimum local**

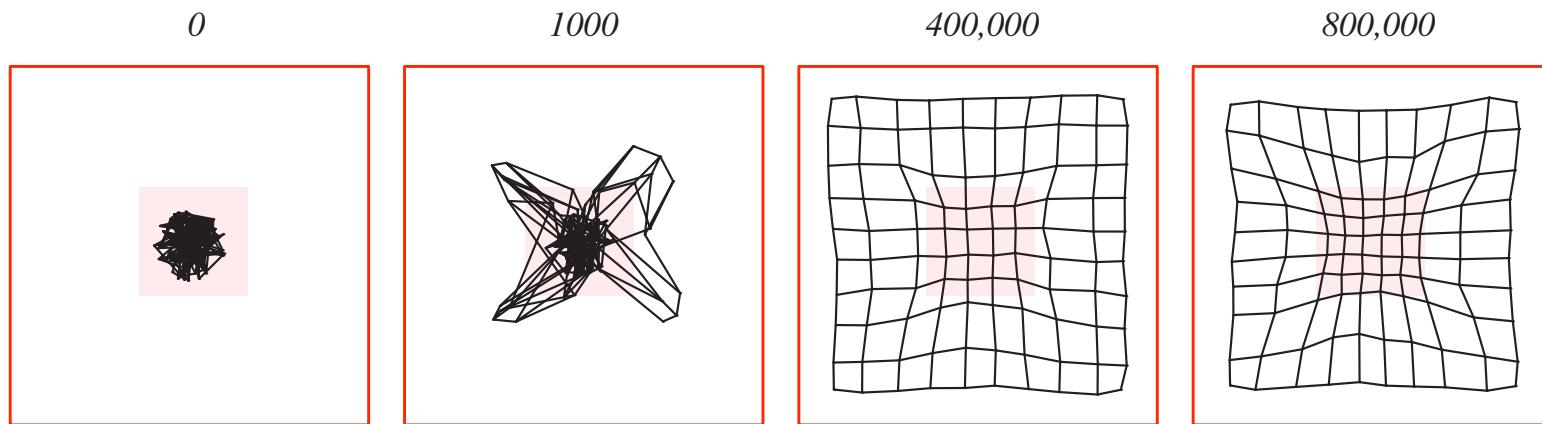


Apprentissage non-supervisé

13

- Cartes auto-organisatrices (SOM)

- estimation de densité



Apprentissage non-supervisé

14

- Cartes auto-organis. (SOM) – théorie de communication
- Codage de source – quantification vectorielle:

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

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

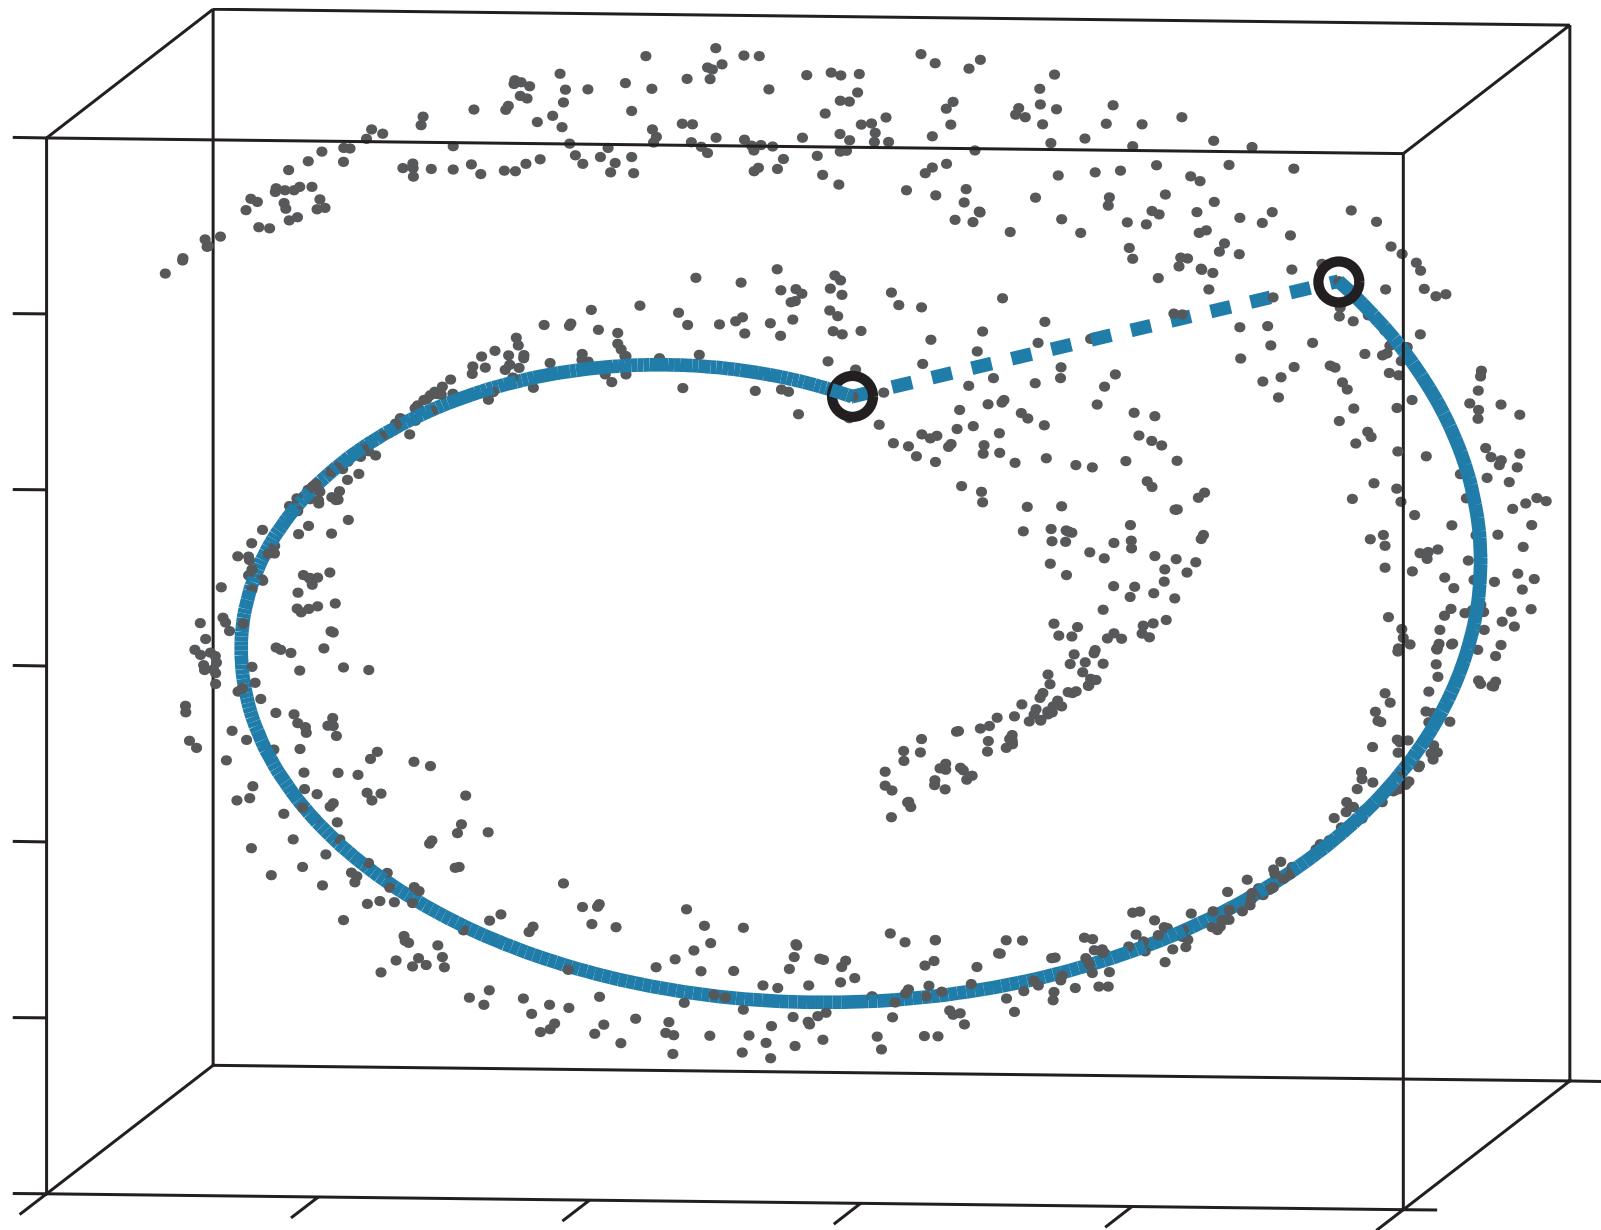
- Codage conjoint de canal-source

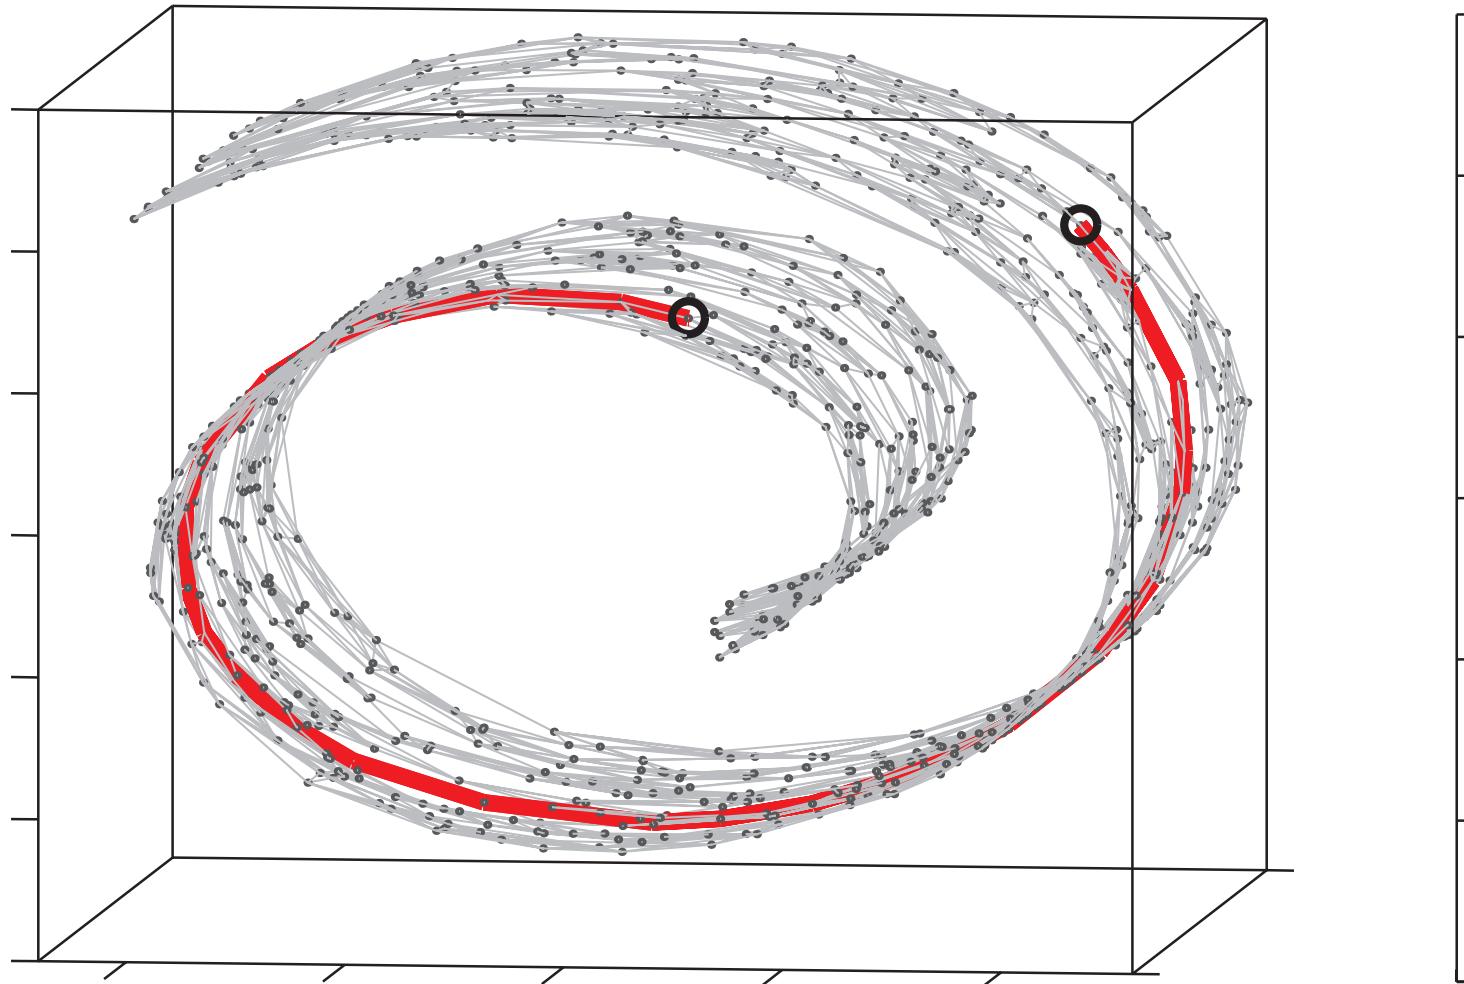
- fonction d'erreur: $J_{s+c} = \sum_{i=1}^n \sum_{j=1}^c \|\mathbf{x}_i - \mathbf{v}_j\|^2 p_{x_i,j}$

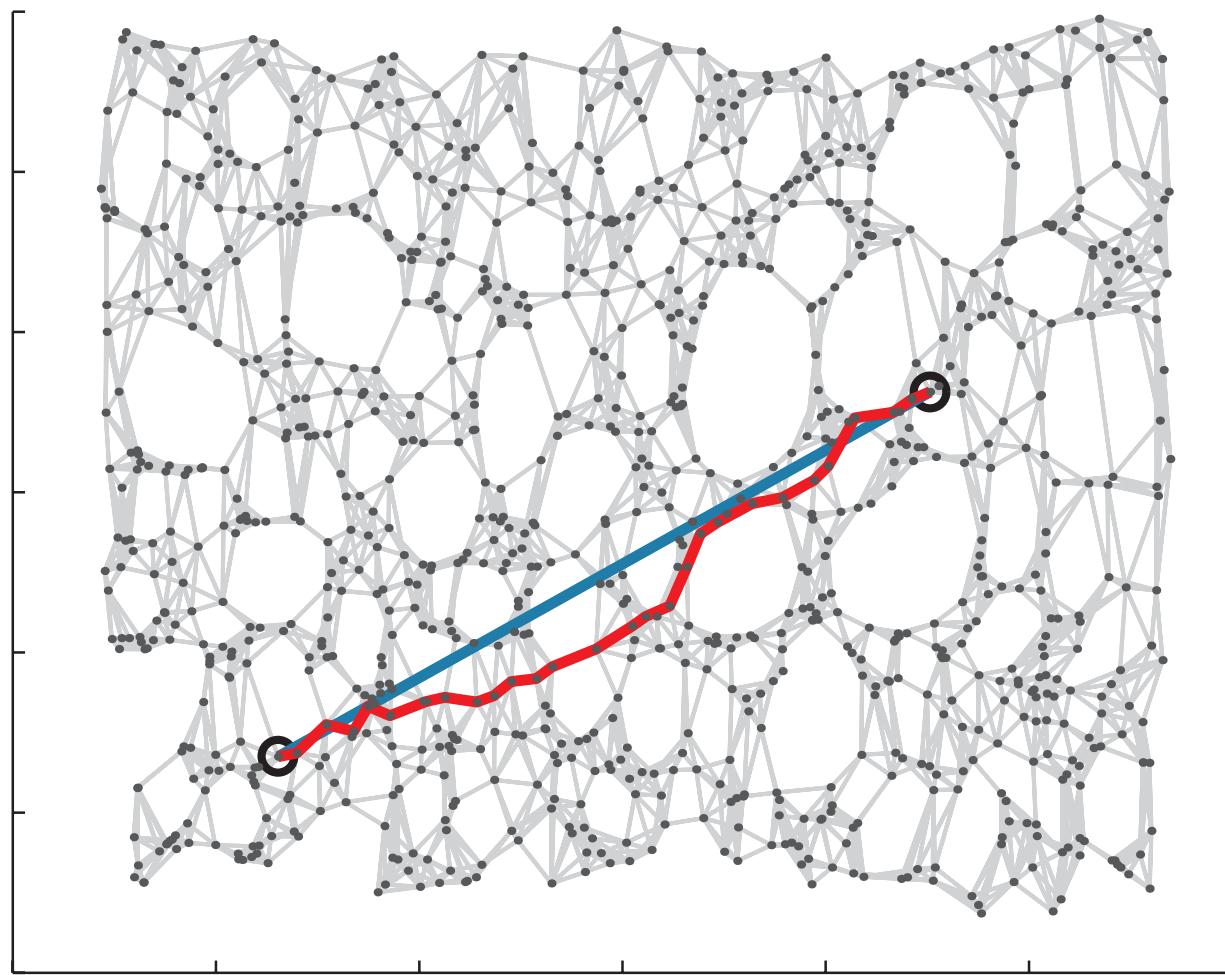
Apprentissage non-supervisé

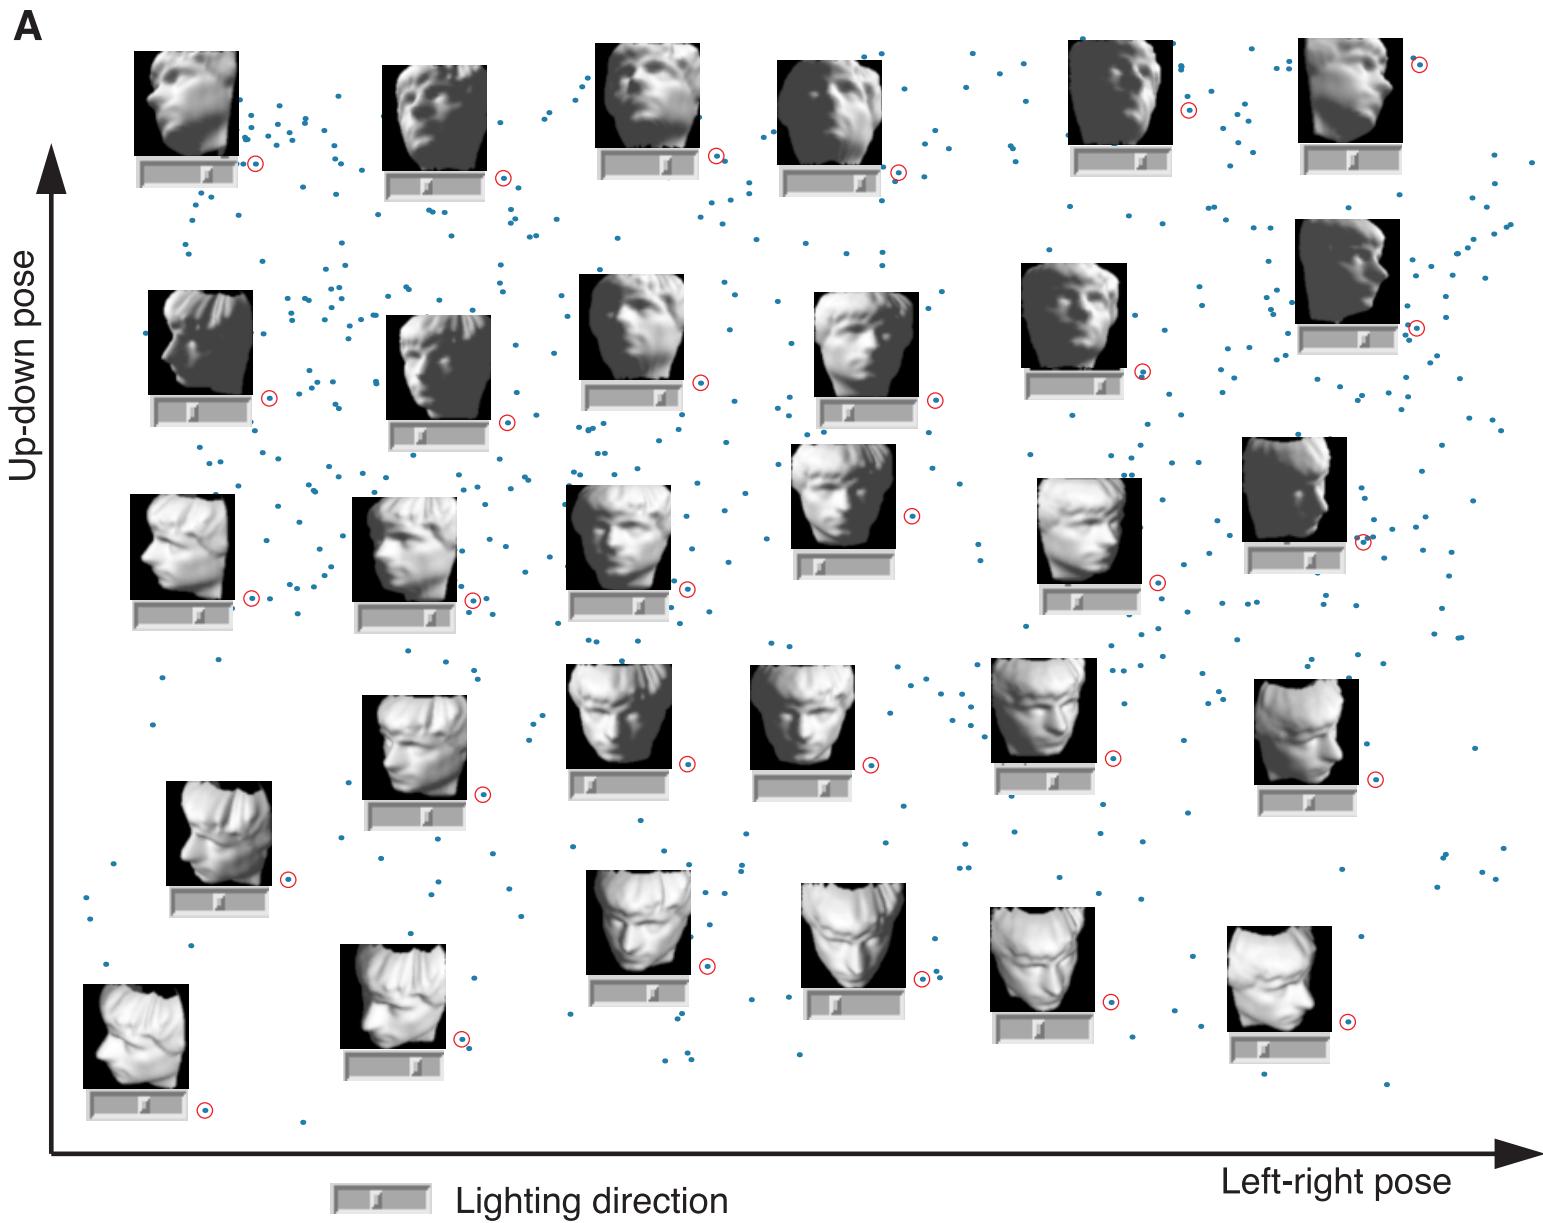
16

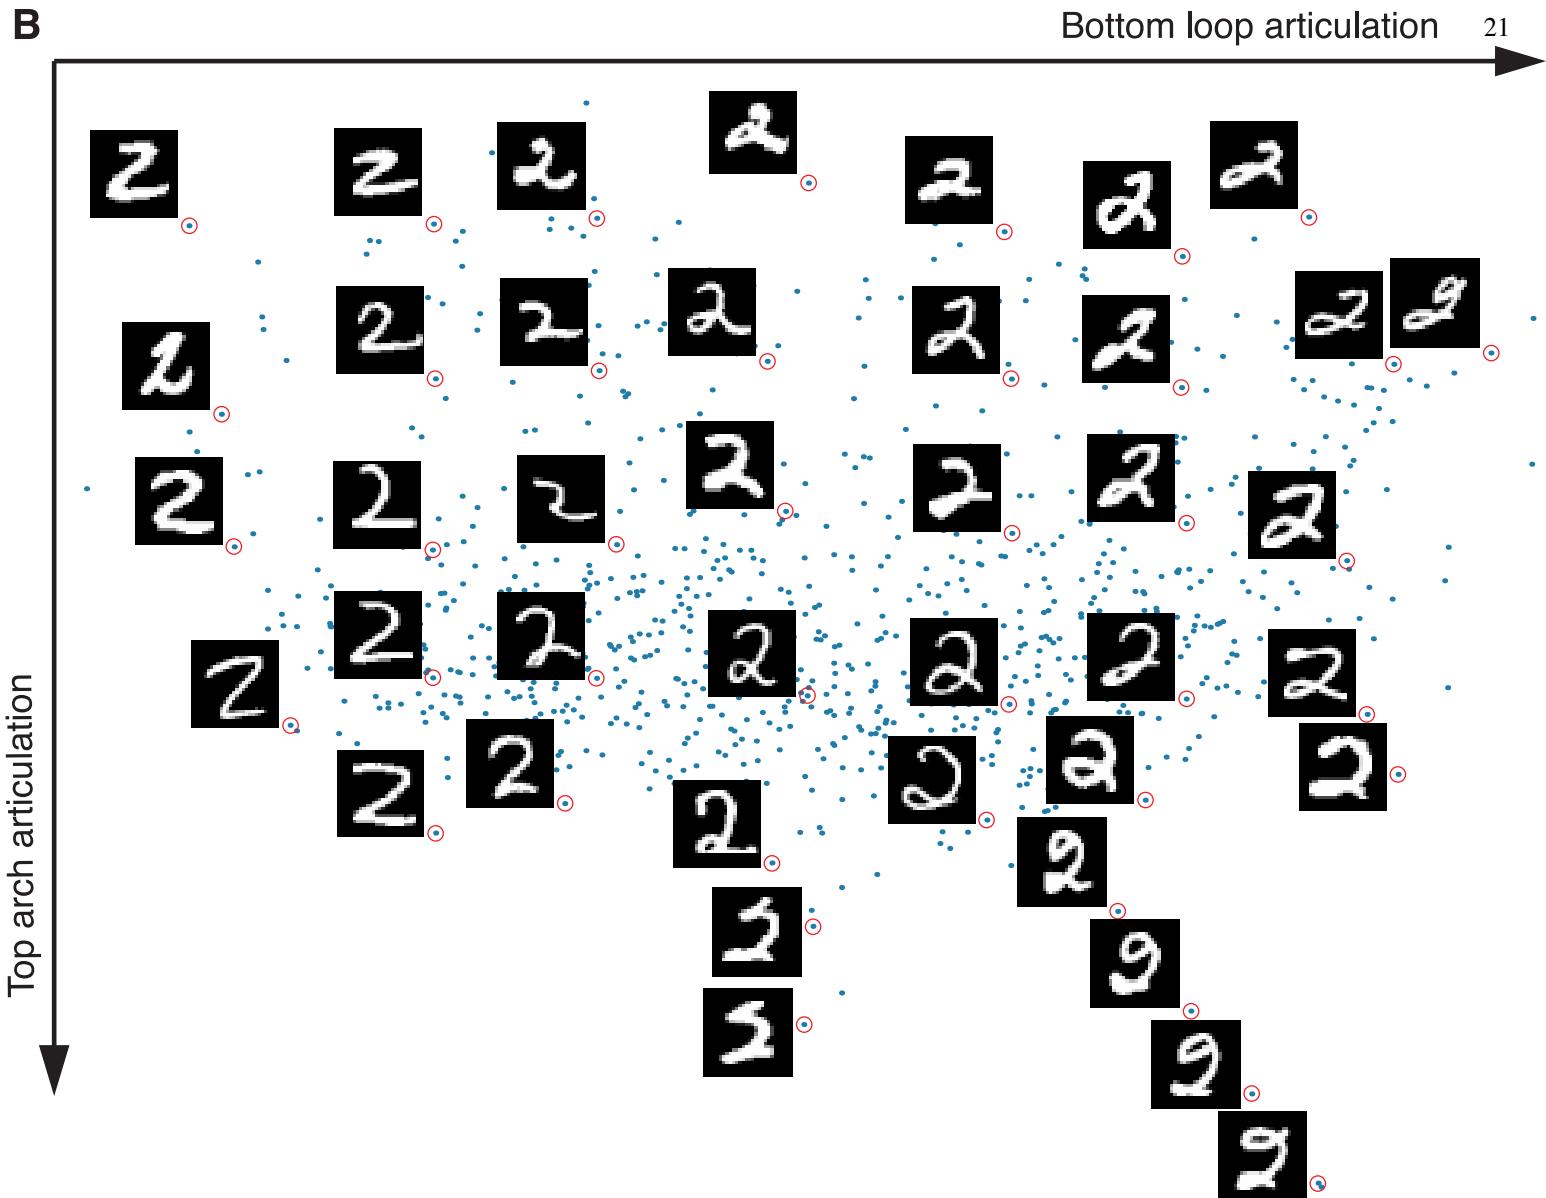
- Problème générale: surfaces compliquées → minima local
- Solution 1: ISOMAP
 - **distance géodésique**: chemins plus courts dans le graphe de similarité
 - MDS standard sur les distances géodésiques



C







Apprentissage non-supervisé

22

- Solution 2: Local linear embedding (LLE)

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

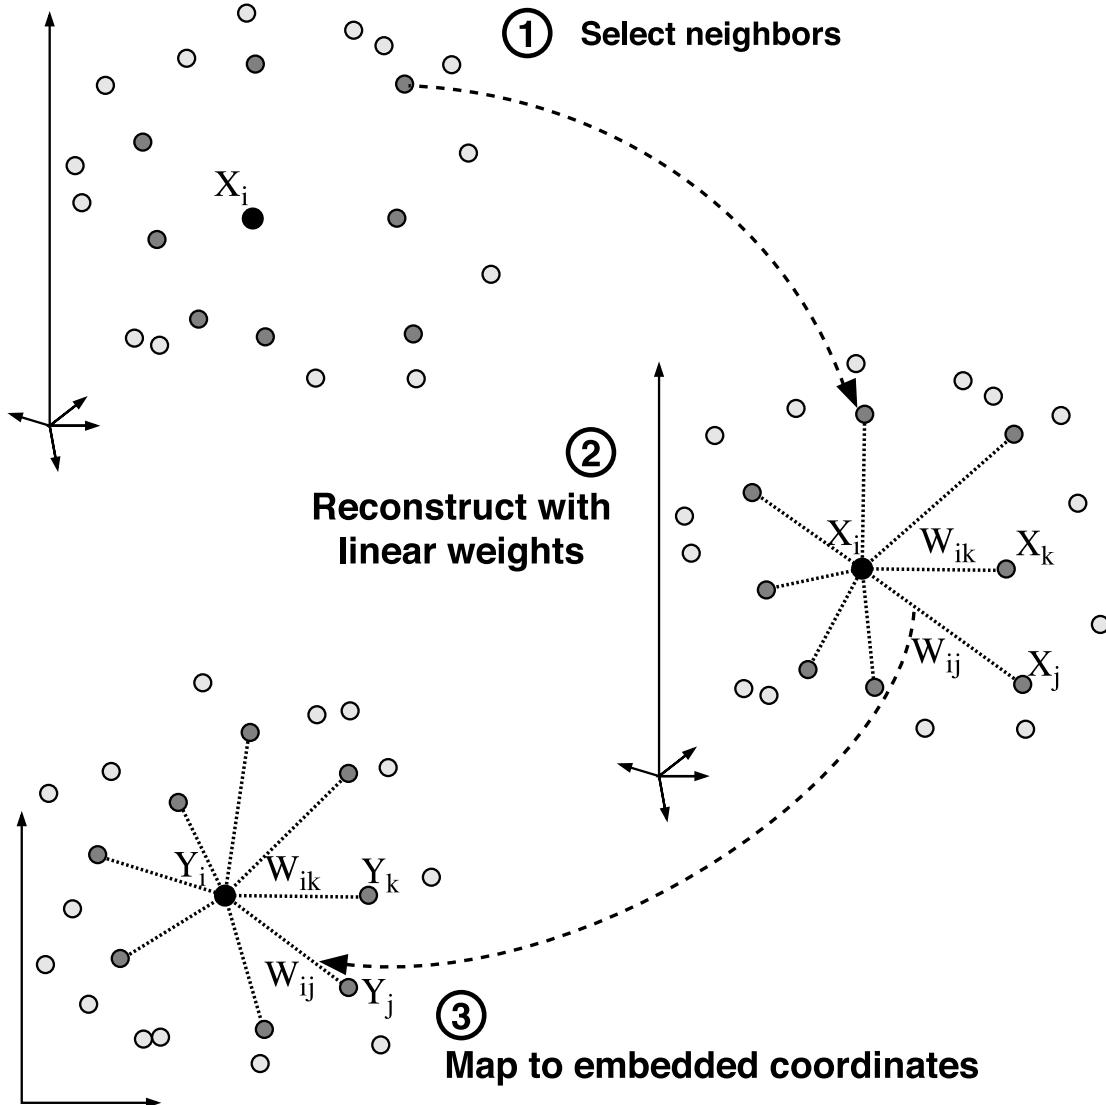
$$\min_{\mathbf{w}} \sum_{i=1}^n \left\| \mathbf{x}_i - \sum_{\mathbf{x}_j \in V_{\mathbf{x}_i}} w_{i,j} \mathbf{x}_j \right\|^2$$

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

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

The con²³ these recons symmetry: 1 are invariant translations bors. By symmetrization we opposed to particular frame invariance that is forced by the rows of the

Suppose nonlinear mapping $\ll D$. To ε exists a linear translation, maps the local neighborhood on the construction we can expect their trv in the c



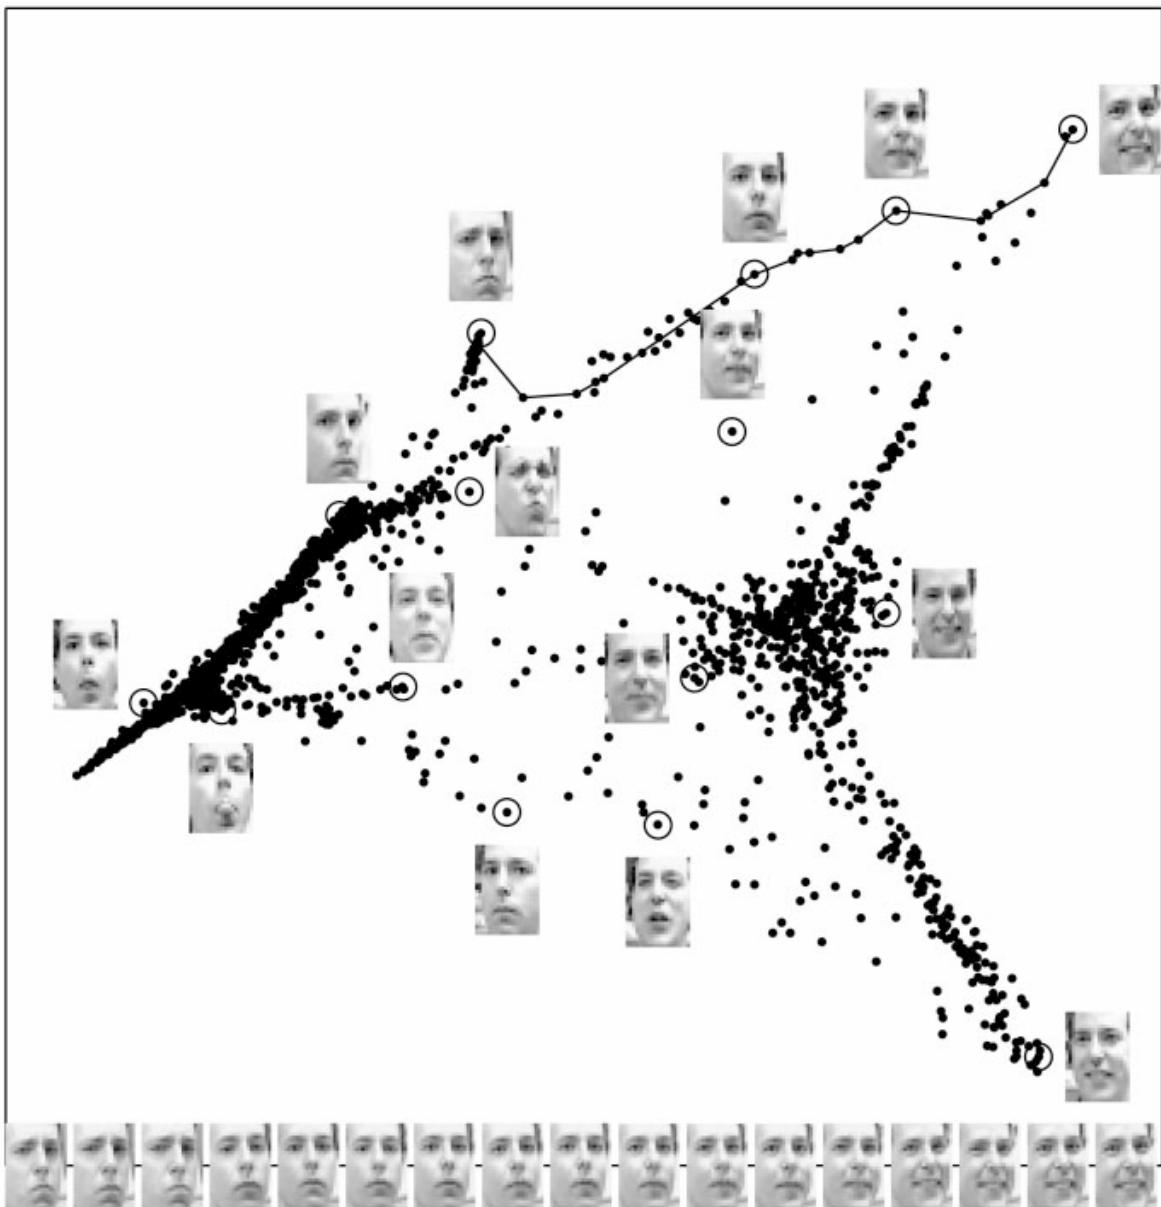
valid for
particular
struct the
should al
fold coor

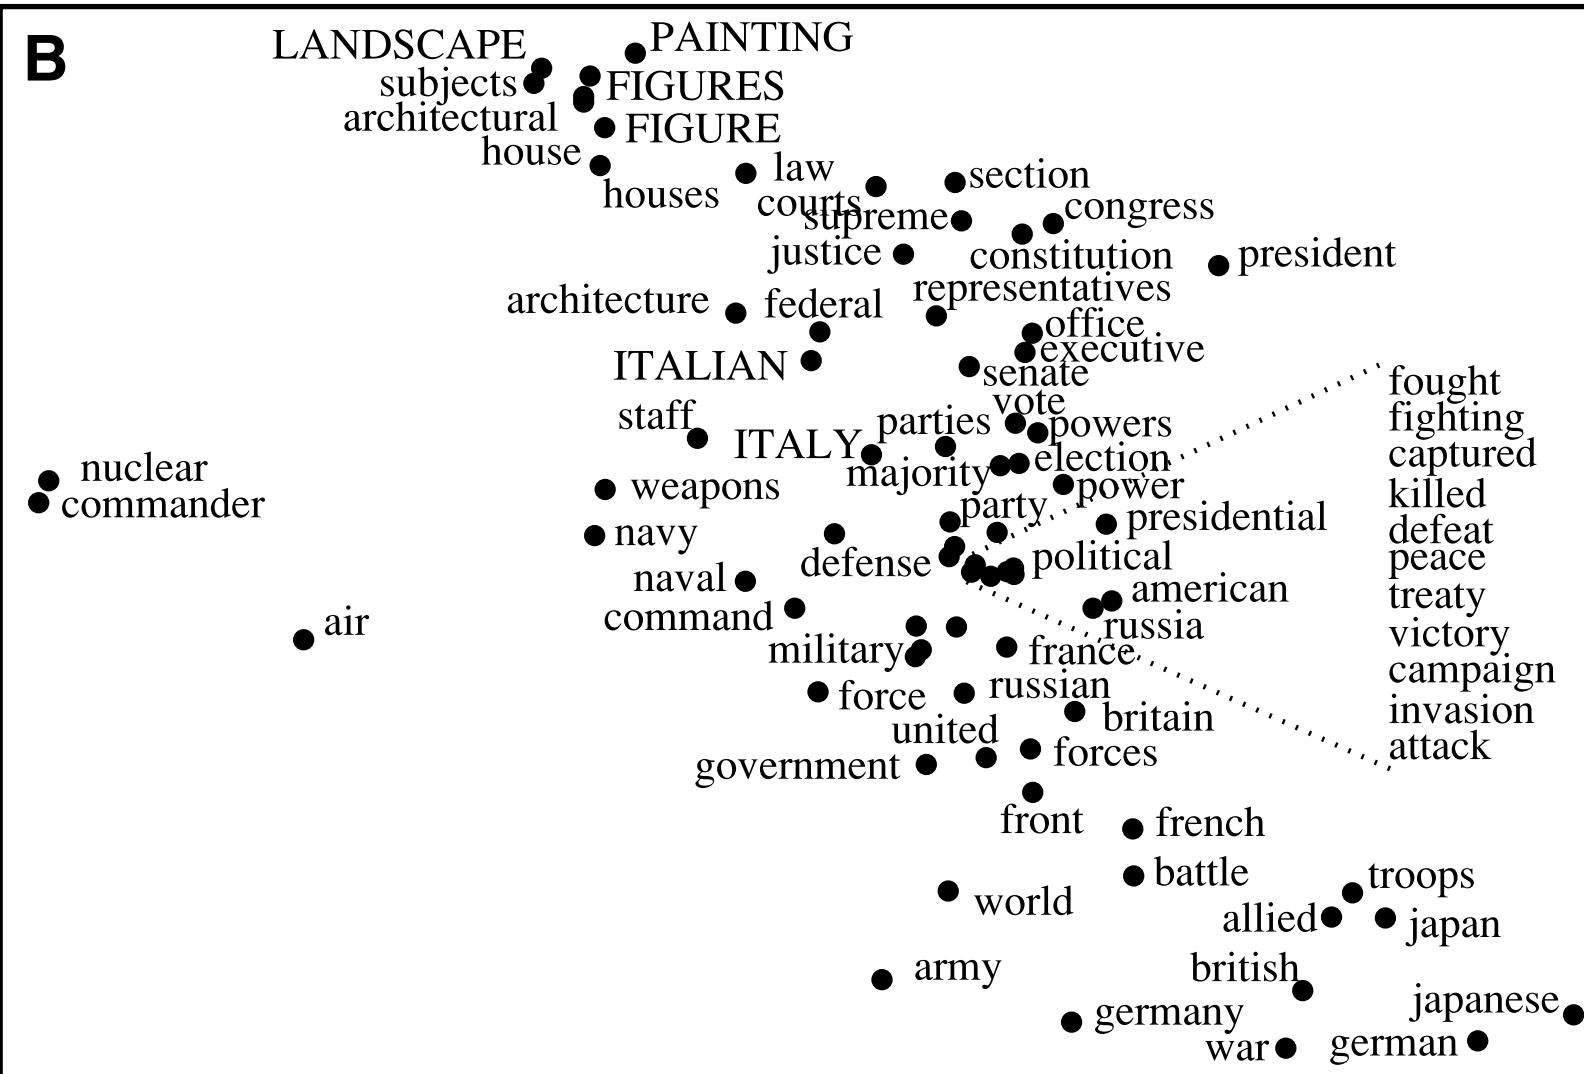
LLE c
mapping
step of th
observatio
vector \tilde{Y}_i
nates on t
 d -dimensi
embeddin

Φ

This cost
based on
but here
mizing tl
cost in E
vectors \tilde{Y}
the proble
by solvin
lem (9),
tors prov
coordinat

Imple
straightfo
points we
est neighb
tance or





Apprentissage non-supervisé

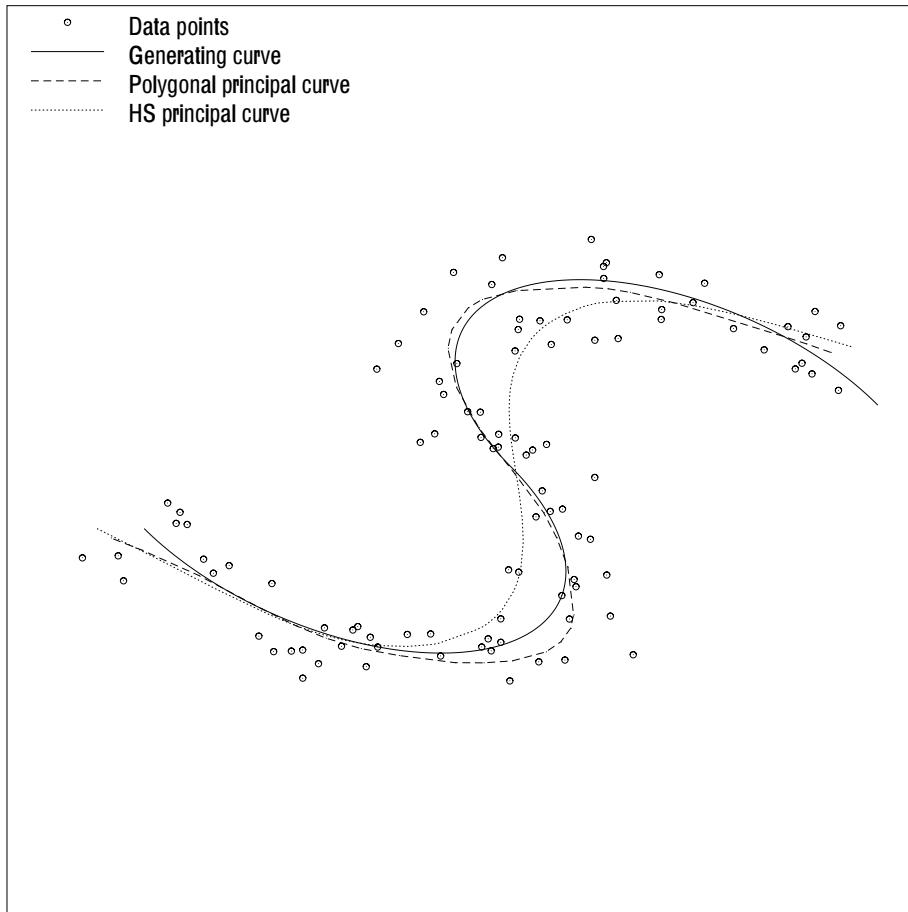
26

- 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

27

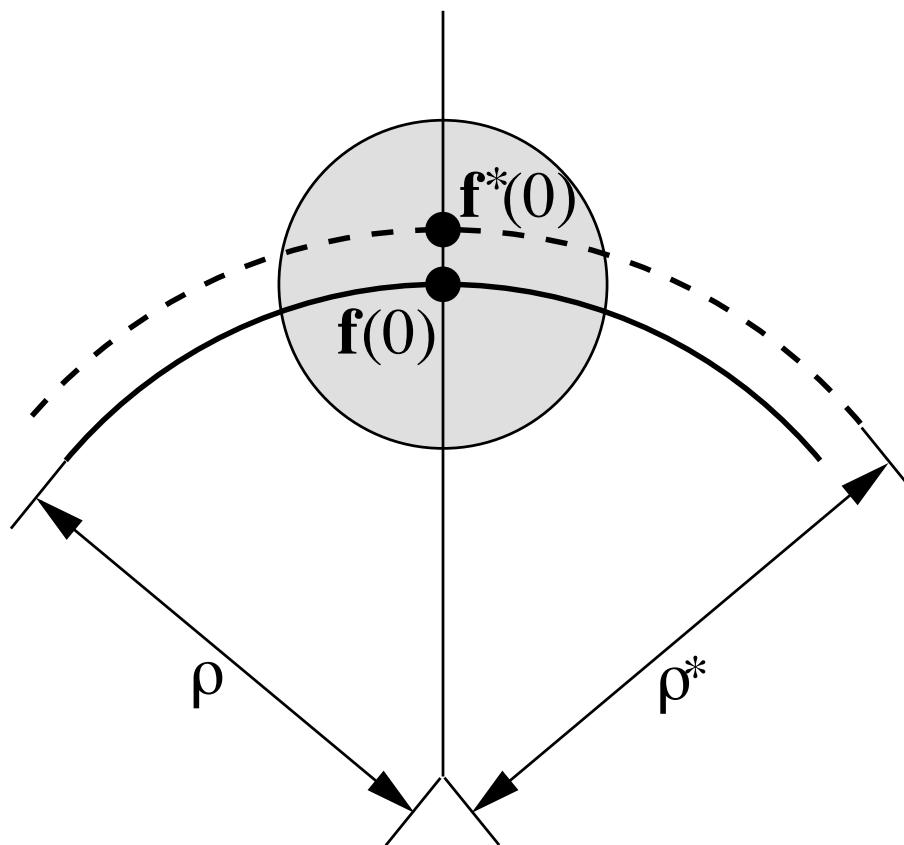
- Problème: **bruit**



Apprentissage non-supervisé

28

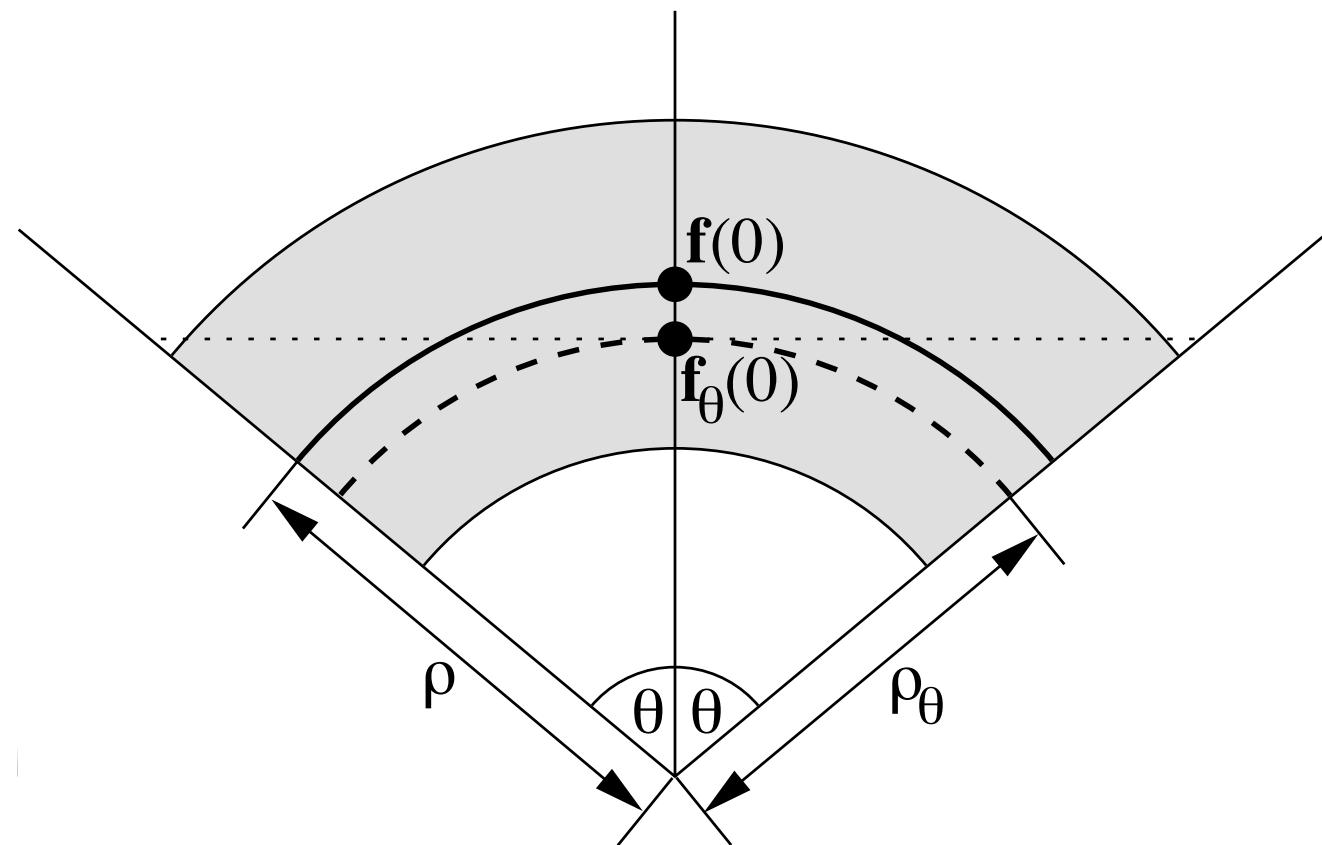
- Le biais du modèle



Apprentissage non-supervisé

29

- Le biais de l'estimation

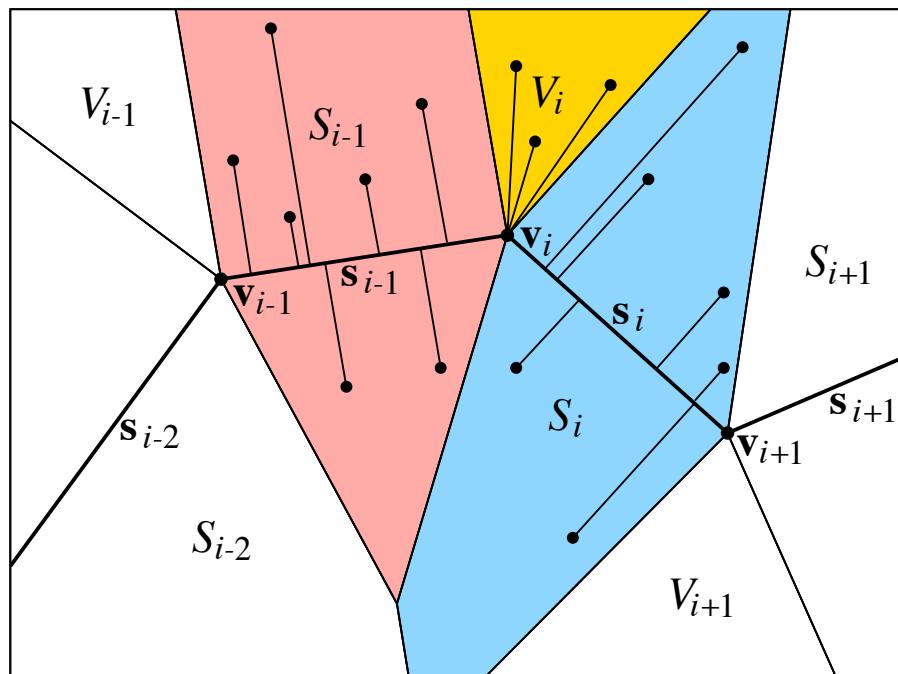


Apprentissage non-supervisé

30

- Solution: courbes principales polygonales

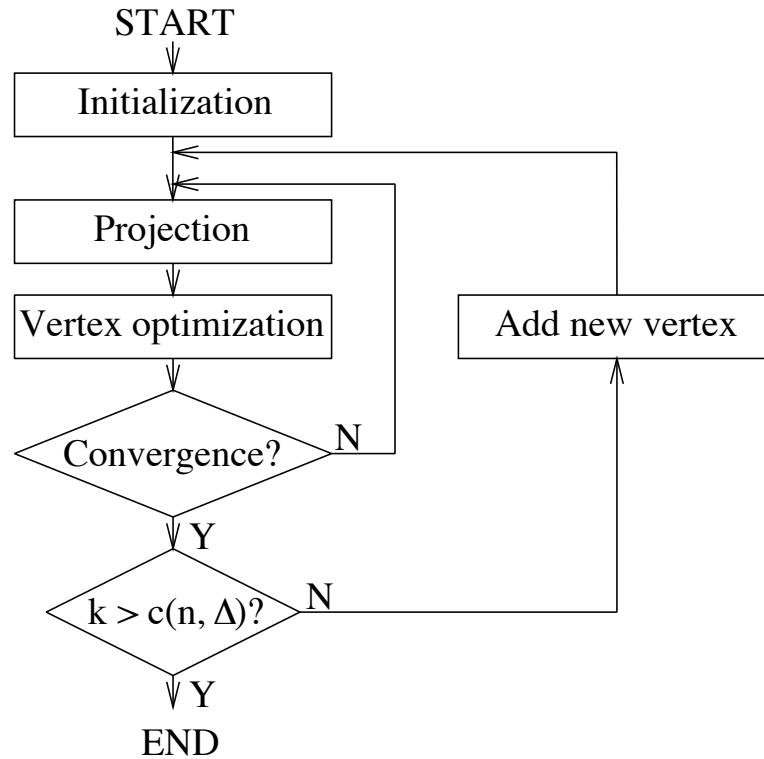
- Mesurer la distance de la courbe au lieu des sommets



Apprentissage non-supervisé

31

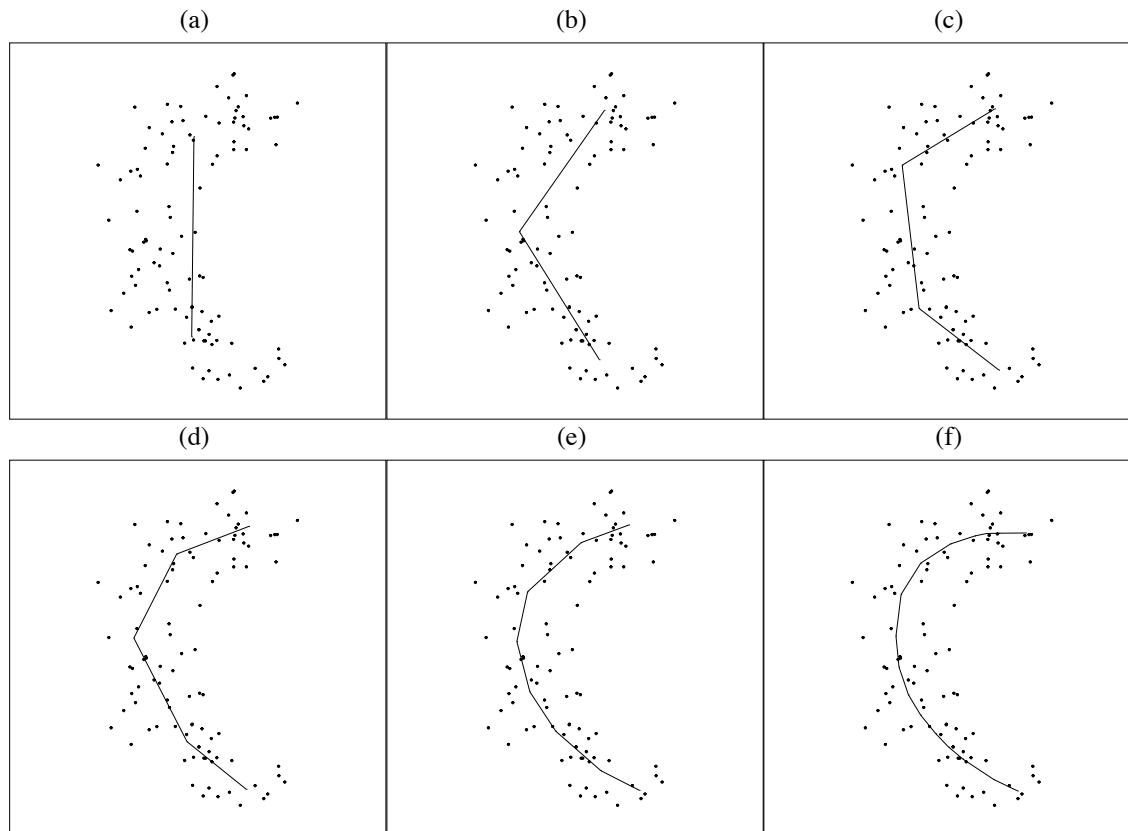
- Courbes principales polygonales



Apprentissage non-supervisé

32

- Courbes principales polygonales

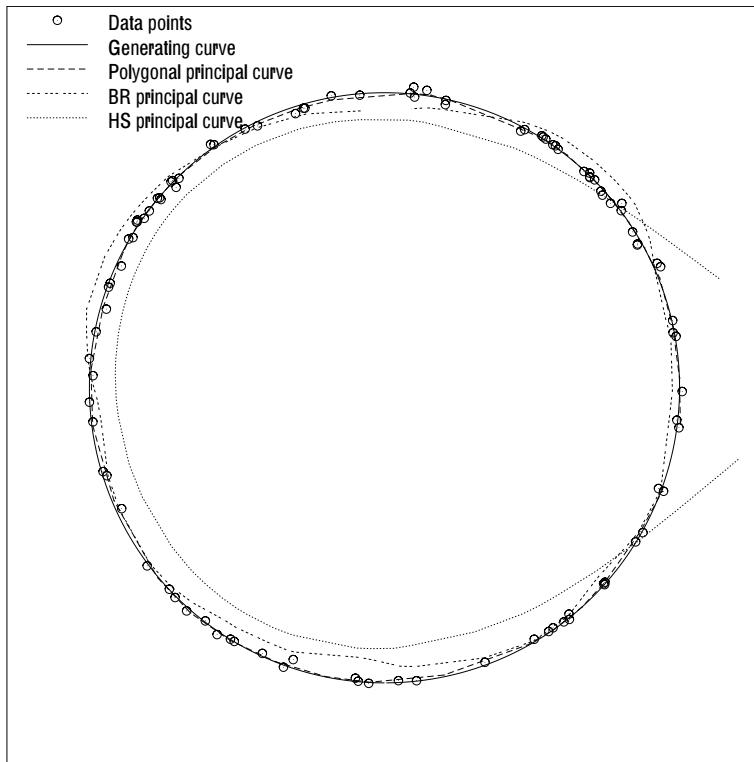


Apprentissage non-supervisé

33

- Courbes principales polygonales

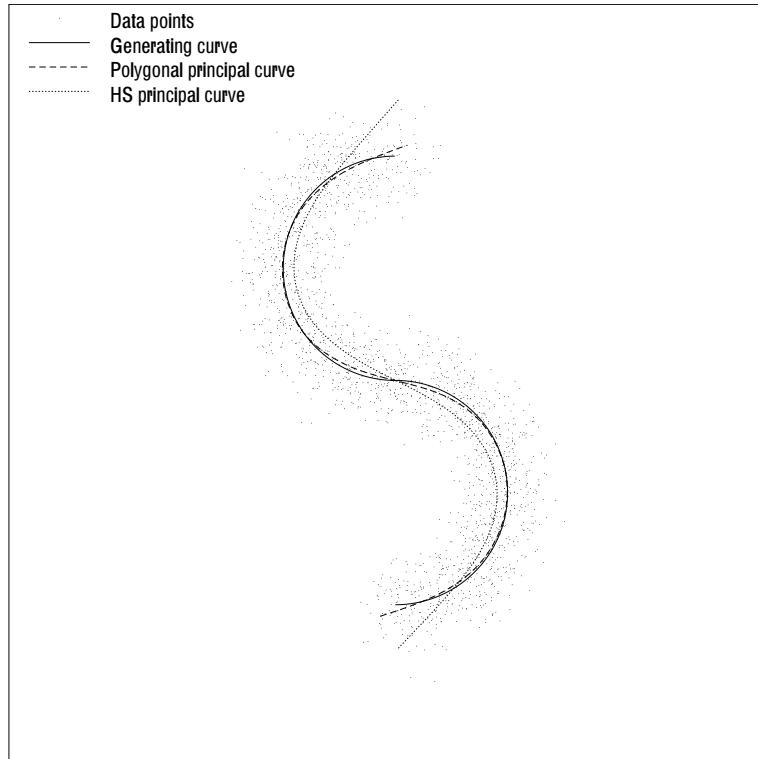
- bruit réduit



Apprentissage non-supervisé

34

- Courbes principales polygonales
 - beaucoup de points

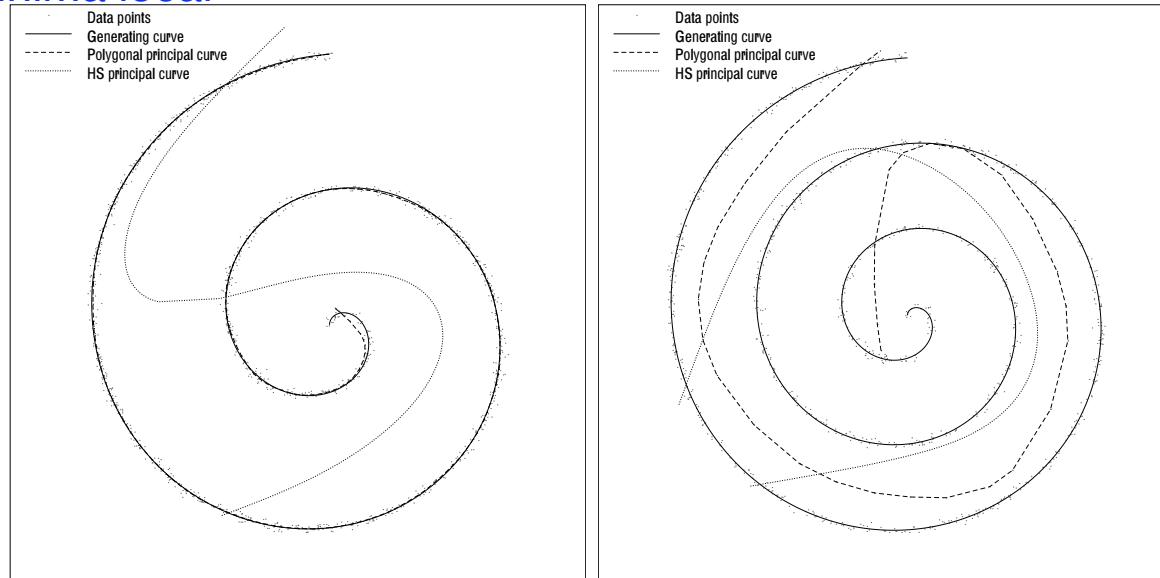


Apprentissage non-supervisé

35

- désavantages des courbes principales:

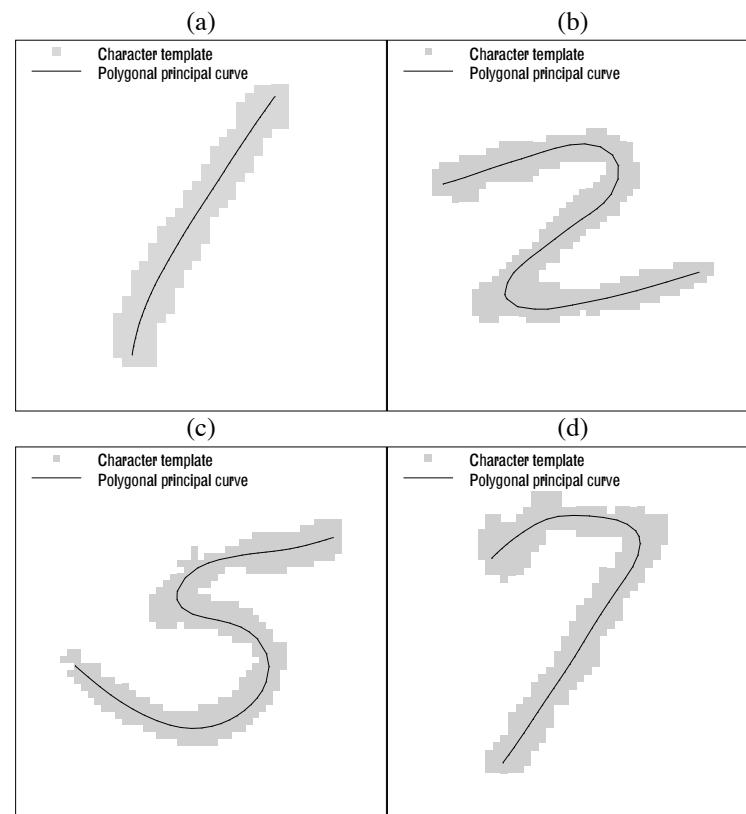
- minima local



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

Apprentissage non-supervisé

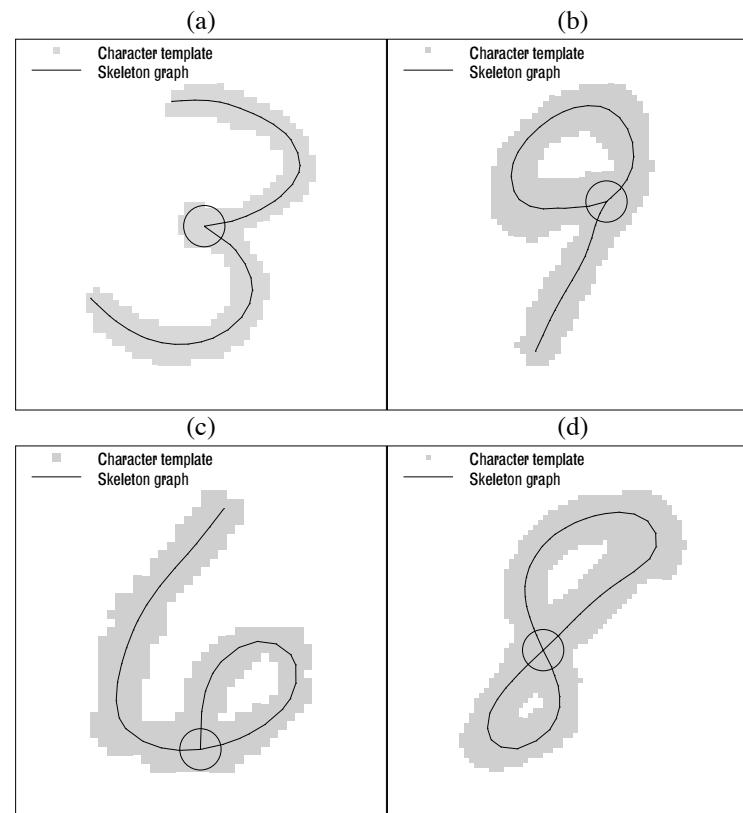
- **Skeletisation des caractères**



Apprentissage non-supervisé

37

- **Skeletisation des caractères**



Apprentissage non-supervisé

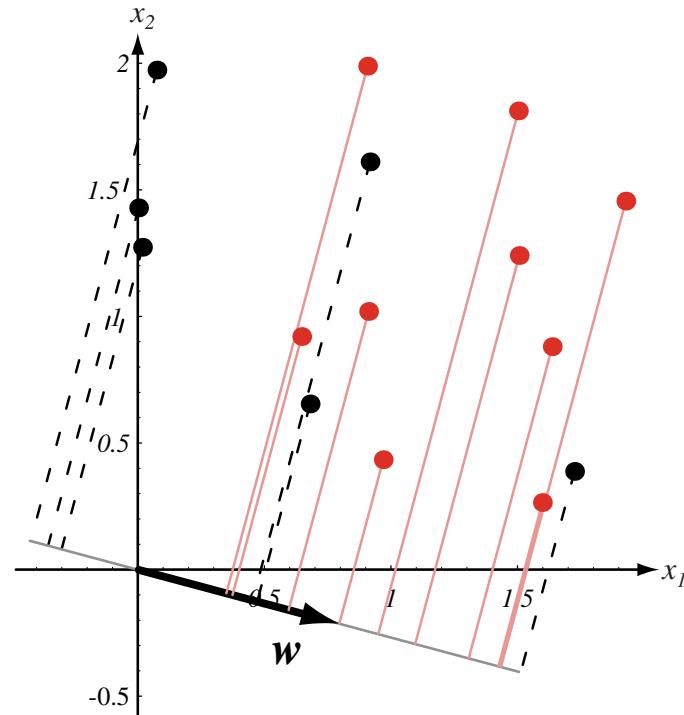
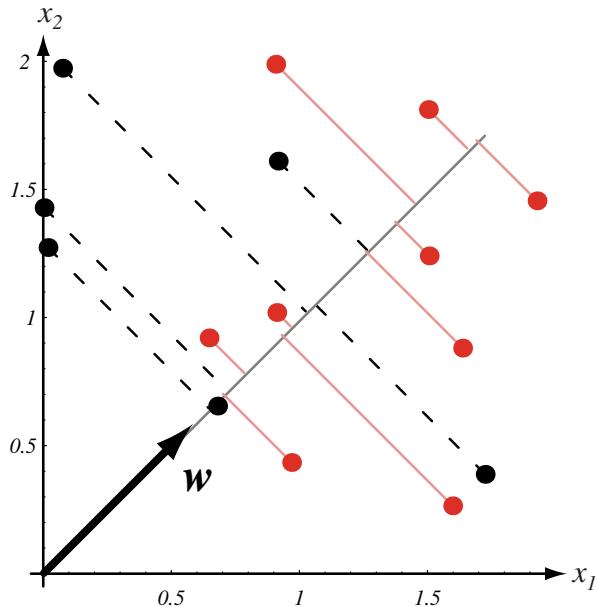
38

- Apprentissage non-supervisé pour la classification: analyse discriminante
 - but: trouver la meilleure projection qui préserve l'information discriminante
- Discriminante de Fisher
 - $y = \mathbf{w}^t \mathbf{x}$

Apprentissage non-supervisé

39

- Analyse discriminante



Apprentissage non-supervisé

40

- Idée 1: séparer les moyennes projetées

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

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

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

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

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

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

Apprentissage non-supervisé

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

- $\mathbf{S}_i = \sum_{\mathbf{x} \in D_i} (\mathbf{x} - \mathbf{x}_i)(\mathbf{x} - \mathbf{x}_i)^t$
- $\mathbf{S}_W = \mathbf{S}_1 + \mathbf{S}_2$
- $\tilde{s}_i^2 = \sum_{\mathbf{x} \in D_i} (\mathbf{w}^t \mathbf{x} - \mathbf{w}_i^t)^2 = \sum_{\mathbf{x} \in D_i} \mathbf{w}^t (\mathbf{x} - \mathbf{x}_i)(\mathbf{x} - \mathbf{x}_i)^t \mathbf{w} = \mathbf{w}^t S_i \mathbf{w}$
- $\tilde{s}_1^2 + \tilde{s}_2^2 = \mathbf{w}^t S_W \mathbf{w}$
- $\mathbf{S}_B = (\mathbf{1} - \mathbf{2})(\mathbf{1} - \mathbf{2})^t$
- $(\tilde{m}_1 - \tilde{m}_2)^2 = (\mathbf{w}_1^t - \mathbf{w}_2^t)^2 = \mathbf{w}^t (\mathbf{1} - \mathbf{2})(\mathbf{1} - \mathbf{2})^t \mathbf{w} = \mathbf{w}^t S_B \mathbf{w}$
- $J(\mathbf{w}) = \frac{\mathbf{w}^t S_B \mathbf{w}}{\mathbf{w}^t S_W \mathbf{w}}$
- $\mathbf{w}_{max} = S_W^{-1} (\mathbf{1} - \mathbf{2})$