

# Segmentation non supervisée d'image hyperspectrale par mélange de gaussienne spatialisé

E. Le Pennec

(SELECT - INRIA Saclay / Université Paris Sud)

et

S. Cohen (IPANEMA - CNRS / Soleil)

GRETSI 11

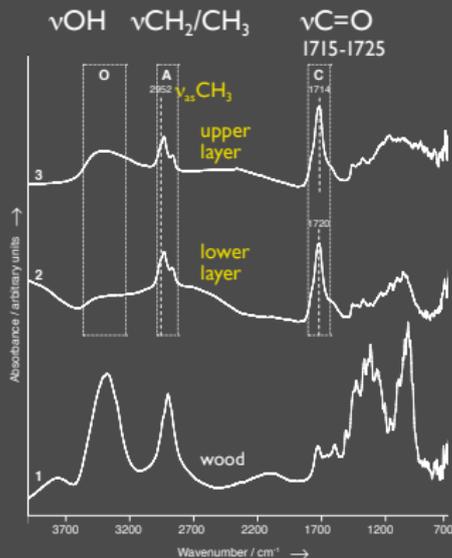
07 septembre 2011

# A. Stradivari (1644 - 1737)

Provigny (1716)



A. Giordan © Cité de la Musique



SOLEIL  
SYNCHROTRON

4 / 8  $\text{cm}^{-1}$  resolution  
64 / 128 scans  
typ. 1 min/sp, 400sp

very simple process  
no protein (amide I, amide II)  
no gums, nor waxes  
@SOLEIL: SMIS



J.-P. Echard, L. Bertrand, A. von Bohlen, A.-S. Le Hô, C. Paris, L. Bellot-Gurlet, B. Soulier, A. Lattuati-Derieux, S. Thao, L. Robinet, B. Lavédrine, and S. Vaiedelich. *Angew. Chem. Int. Ed.*, 49(1), 197-201, 2010.



# Segmentation d'images hyperspectrales

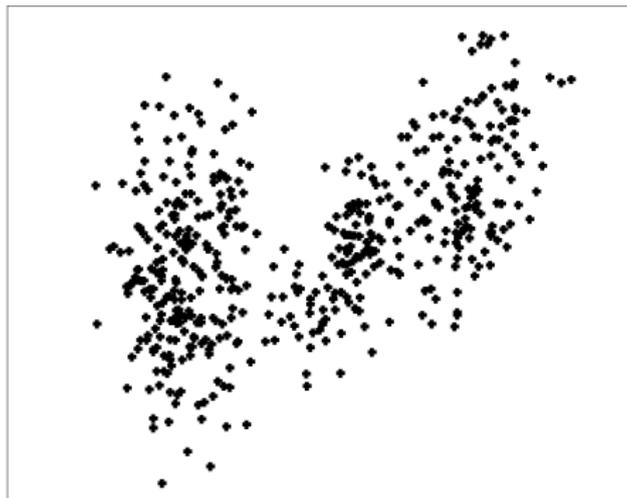
- Données :
  - image de taille  $N$  comprise entre  $\sim 1000$  et  $\sim 100000$  pixels,
  - spectres  $\mathcal{S}$  de  $\sim 1024$  points,
  - très bonne résolution spatiale,
  - possibilité de mesurer de très nombreux spectres par minute...
- Objectifs immédiats :
  - segmentation automatique de ces images,
  - sans intervention humaine,
  - aide à l'analyse des résultats.
- Objectifs lointains :
  - classification automatique,
  - interprétation...

# Segmentation d'images hyperspectrales

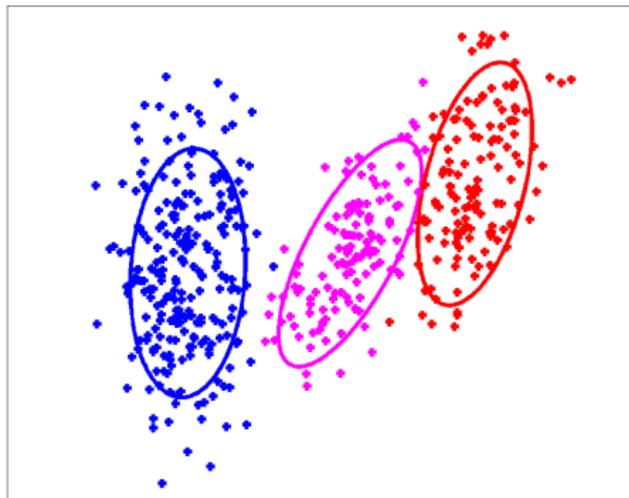
- Données :
  - image de taille  $N$  comprise entre  $\sim 1000$  et  $\sim 100000$  pixels,
  - spectres  $\mathcal{S}$  de  $\sim 1024$  points,
  - très bonne résolution spatiale,
  - possibilité de mesurer de très nombreux spectres par minute...
- Objectifs immédiats :
  - segmentation automatique de ces images,
  - sans intervention humaine,
  - aide à l'analyse des résultats.
- Objectifs lointains :
  - classification automatique,
  - interprétation...

# Un problème “jouet”

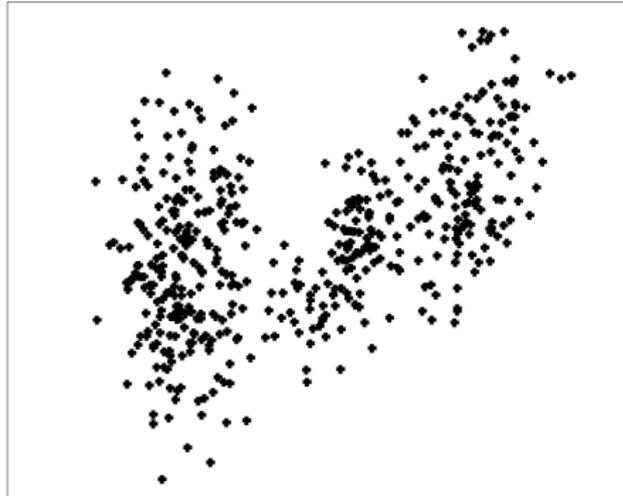
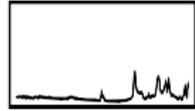
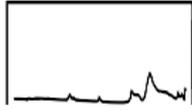
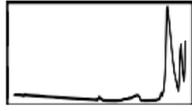
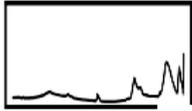
# Un problème “jouet”



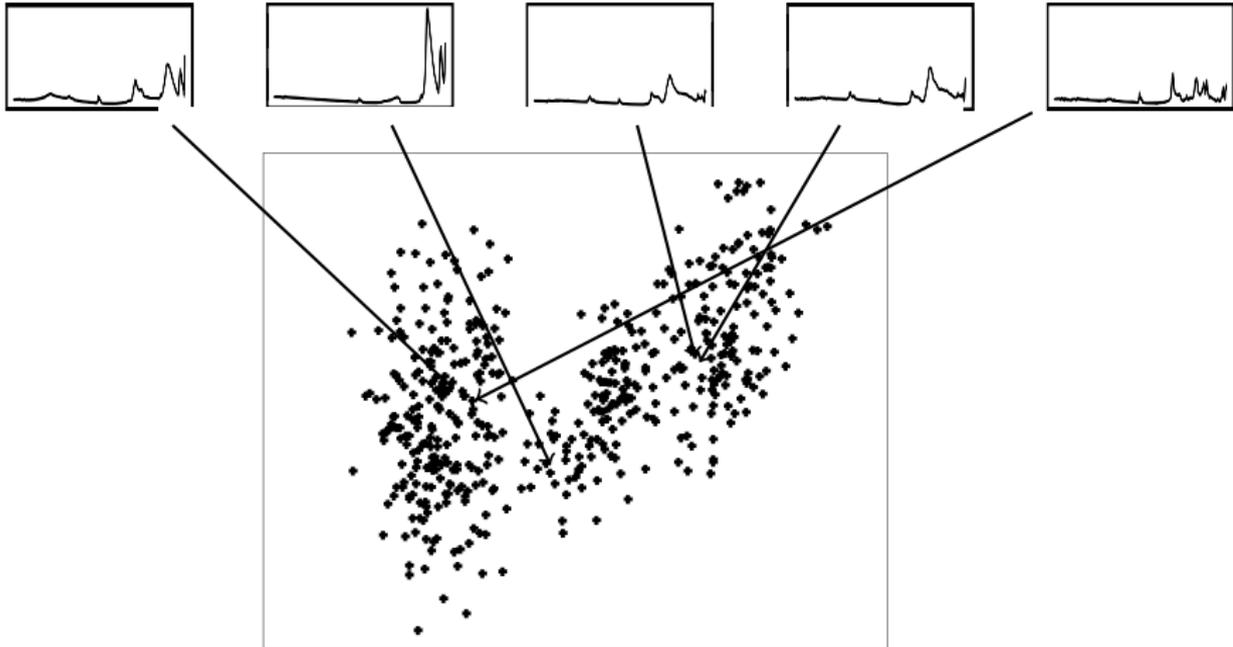
# Un problème “jouet”



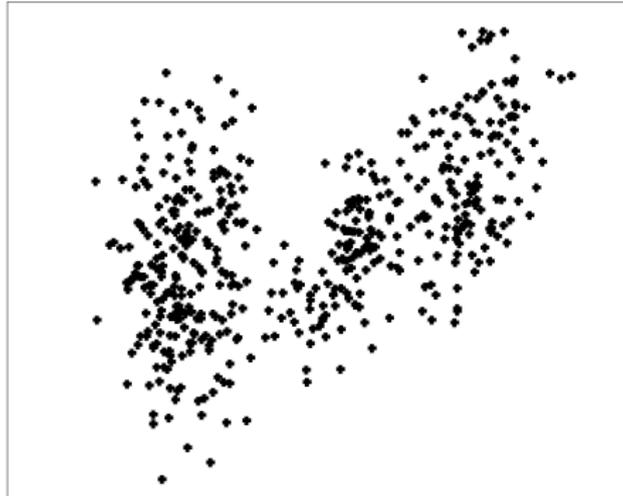
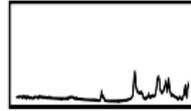
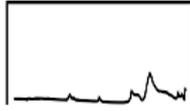
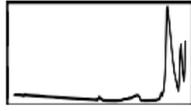
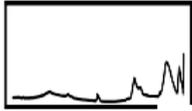
# Un problème “jouet”



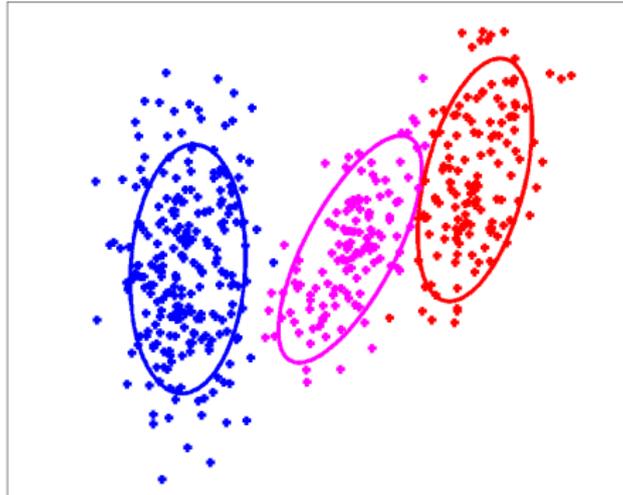
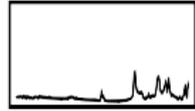
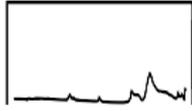
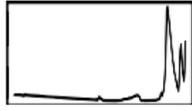
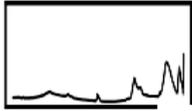
# Un problème “jouet”



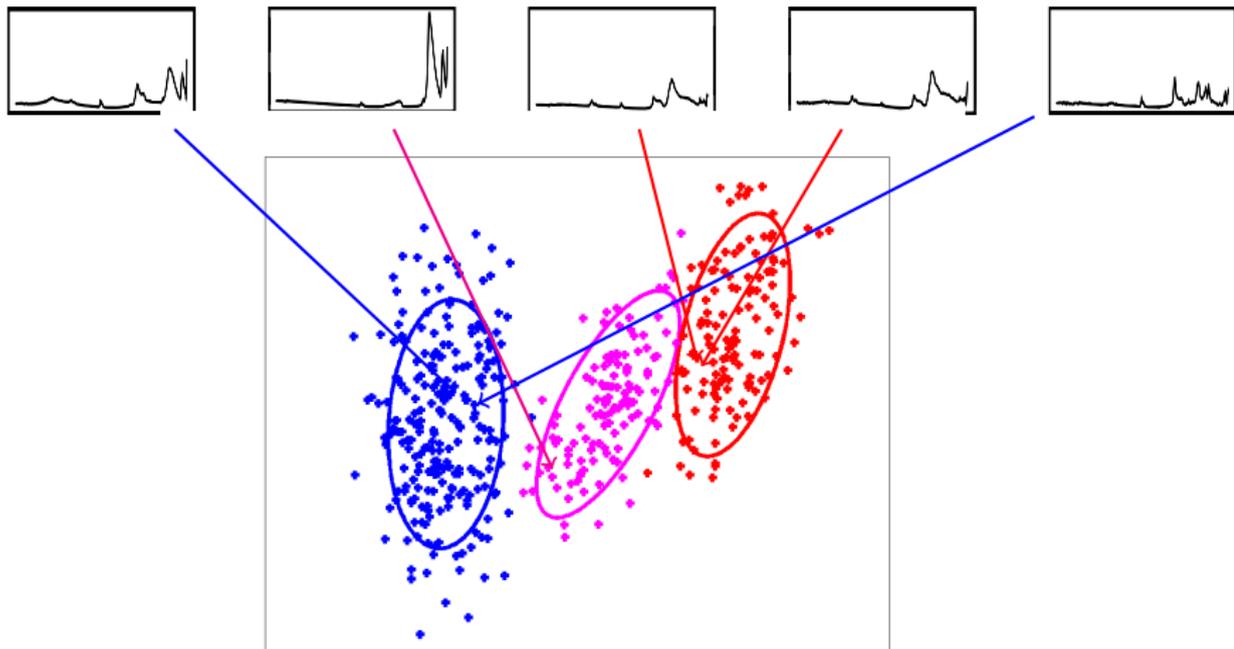
# Un problème “jouet”



# Un problème “jouet”



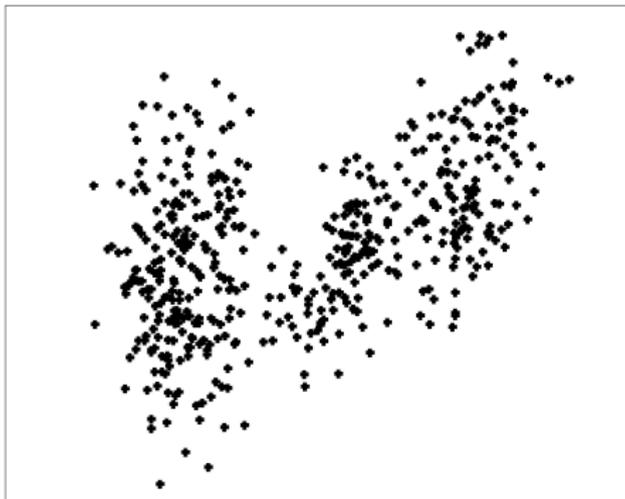
# Un problème “jouet”



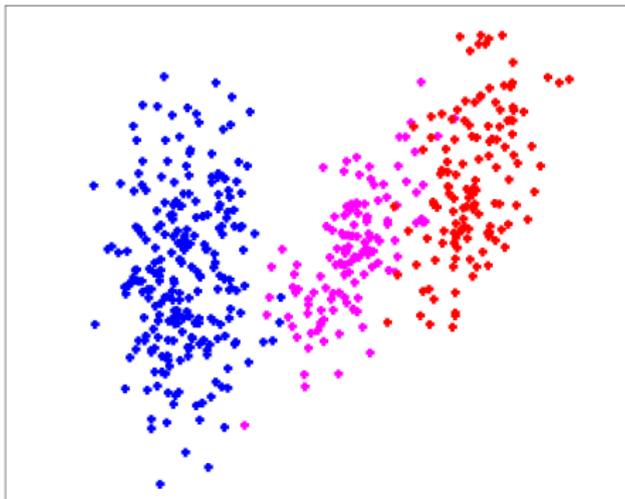
- Représentation : correspondance entre les spectres et des points dans un espace de grande dimension.
- Méthode spectrale.

# Modélisation “stochastique”

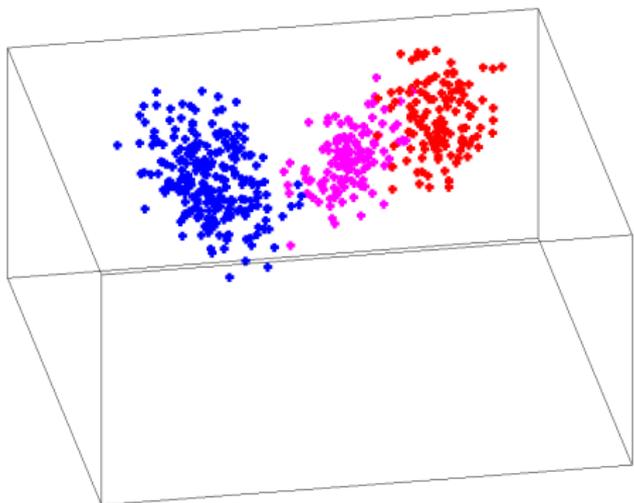
# Modélisation “stochastique”



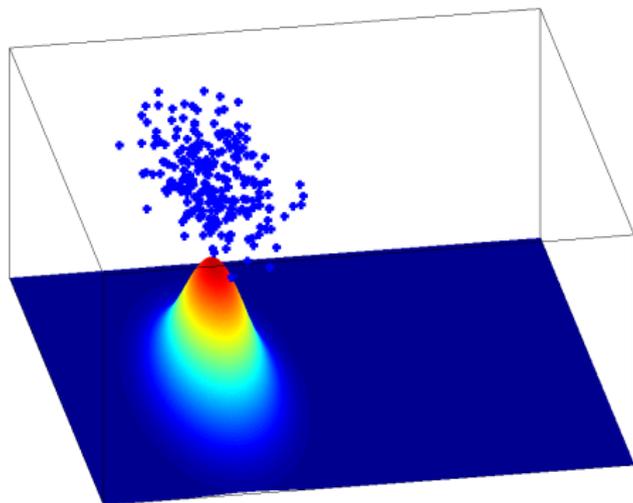
# Modélisation “stochastique”



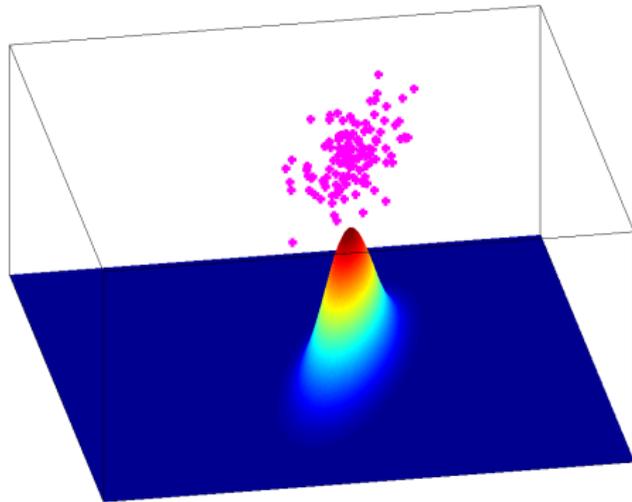
# Modélisation “stochastique”



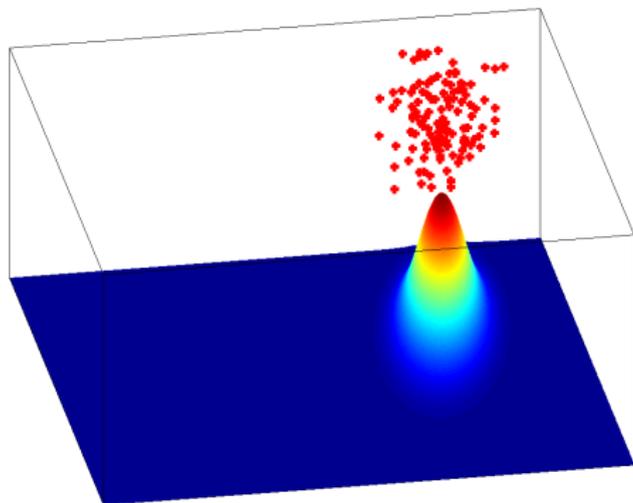
# Modélisation “stochastique”



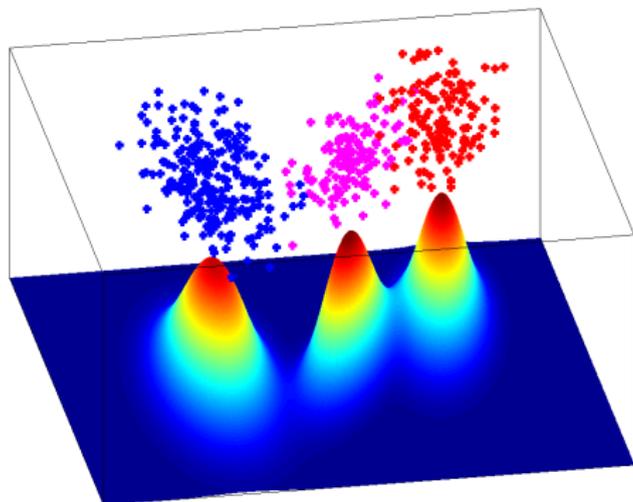
# Modélisation “stochastique”



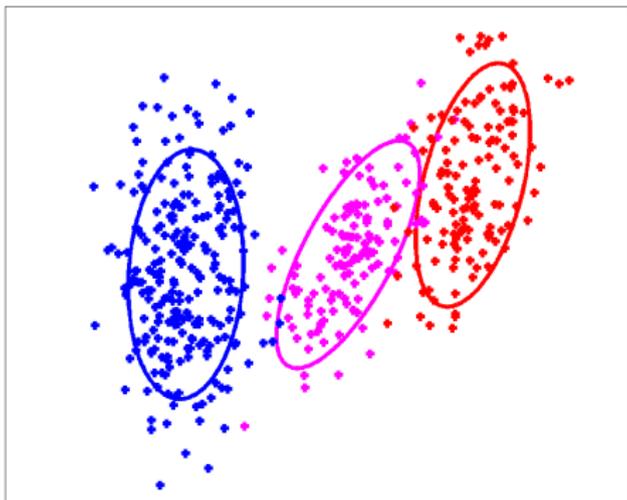
# Modélisation “stochastique”



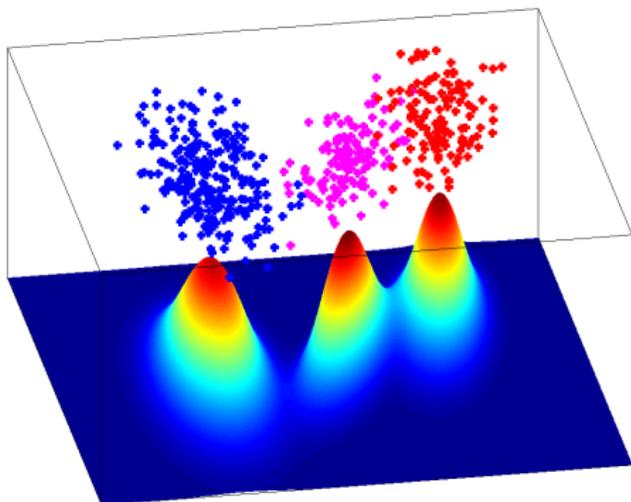
# Modélisation “stochastique”



# Modélisation “stochastique”



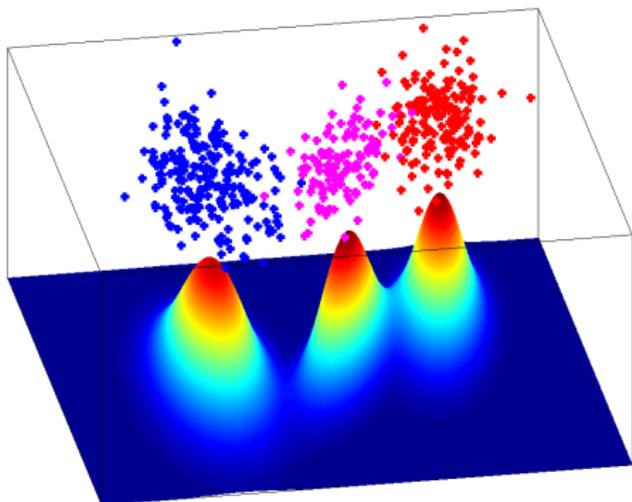
# Modélisation “stochastique”



- Modèle : mélange de gaussiennes à  $K$  classes.
- Densité du mélange :

$$\begin{aligned} s_{K,\pi,\mu,\Sigma}(S) &= \sum_{k=1}^K \pi_k \frac{1}{\sqrt{(2\pi)^d |\Sigma_k|}} e^{-\frac{1}{2}(S-\mu_k)^t \Sigma_k^{-1} (S-\mu_k)} \\ &= \sum_{k=1}^K \pi_k \mathcal{N}_{\mu_k, \Sigma_k}(S) \end{aligned}$$

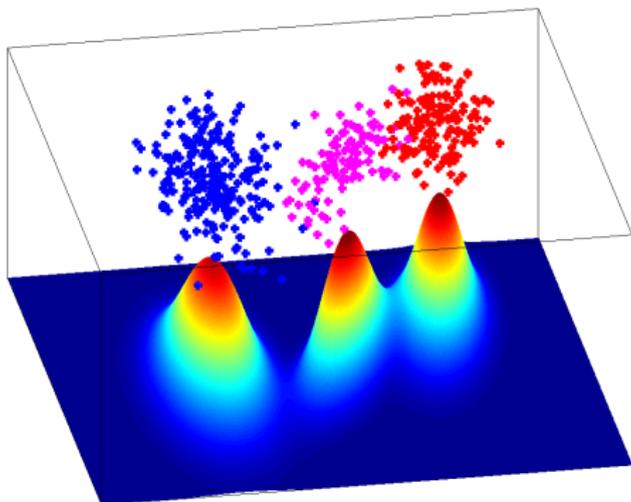
# Modélisation “stochastique”



- Modèle : mélange de gaussiennes à  $K$  classes.
- Densité du mélange :

$$\begin{aligned} s_{K,\pi,\mu,\Sigma}(S) &= \sum_{k=1}^K \pi_k \frac{1}{\sqrt{(2\pi)^d |\Sigma_k|}} e^{-\frac{1}{2}(S-\mu_k)^t \Sigma_k^{-1} (S-\mu_k)} \\ &= \sum_{k=1}^K \pi_k \mathcal{N}_{\mu_k, \Sigma_k}(S) \end{aligned}$$

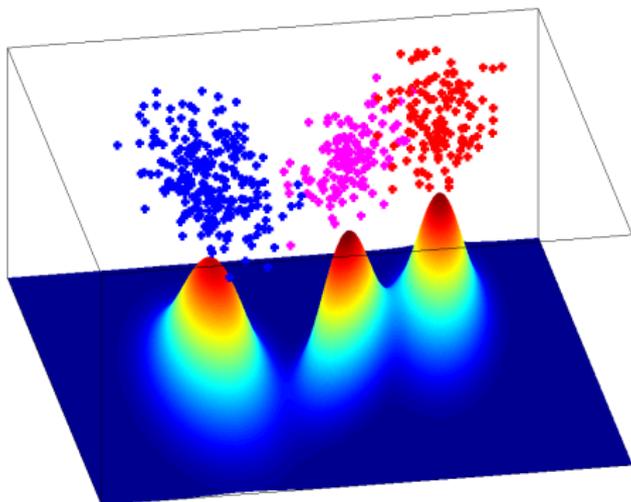
# Modélisation “stochastique”



- Modèle : mélange de gaussiennes à  $K$  classes.
- Densité du mélange :

$$\begin{aligned} s_{K,\pi,\mu,\Sigma}(S) &= \sum_{k=1}^K \pi_k \frac{1}{\sqrt{(2\pi)^d |\Sigma_k|}} e^{-\frac{1}{2}(S-\mu_k)^t \Sigma_k^{-1} (S-\mu_k)} \\ &= \sum_{k=1}^K \pi_k \mathcal{N}_{\mu_k, \Sigma_k}(S) \end{aligned}$$

# Modélisation “stochastique”

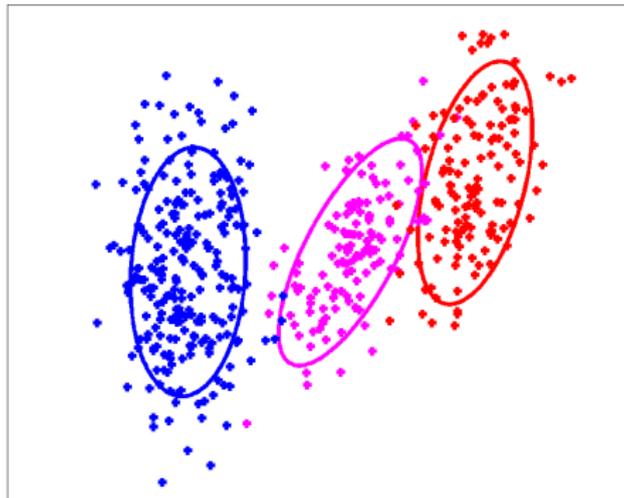


- Modèle : mélange de gaussiennes à  $K$  classes.
- Densité du mélange :

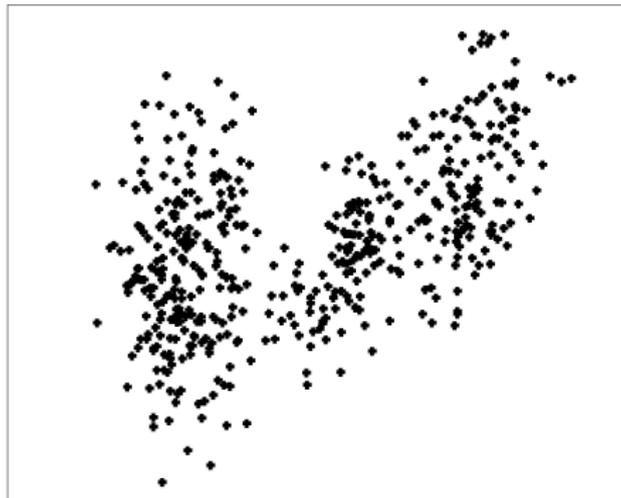
$$\begin{aligned} s_{K,\pi,\mu,\Sigma}(S) &= \sum_{k=1}^K \pi_k \frac{1}{\sqrt{(2\pi)^d |\Sigma_k|}} e^{-\frac{1}{2}(S-\mu_k)^t \Sigma_k^{-1} (S-\mu_k)} \\ &= \sum_{k=1}^K \pi_k \mathcal{N}_{\mu_k, \Sigma_k}(S) \end{aligned}$$

# Estimation “statistique”

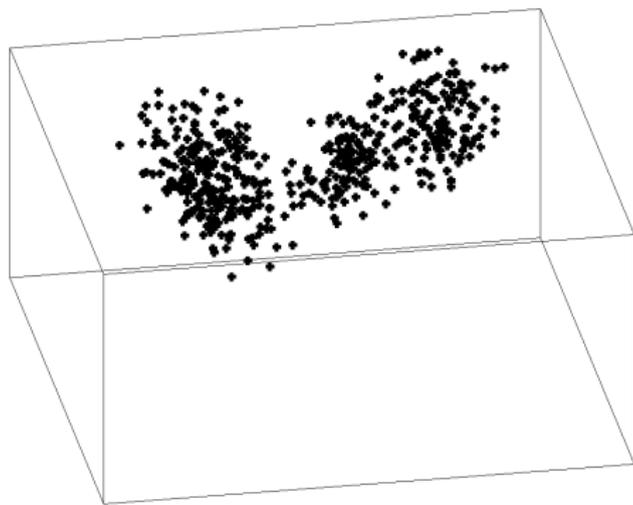
# Estimation “statistique”



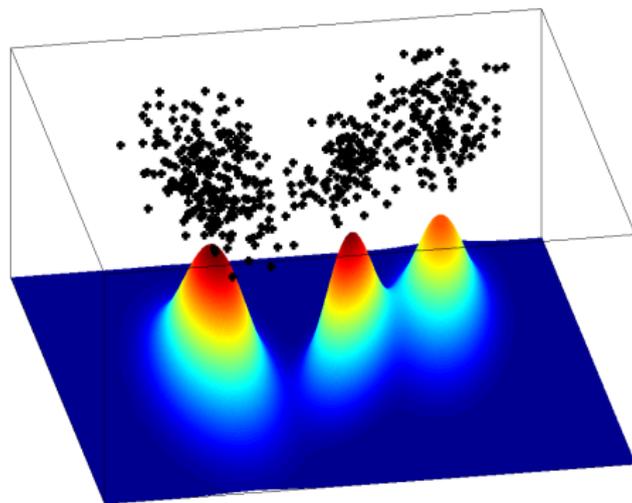
# Estimation “statistique”



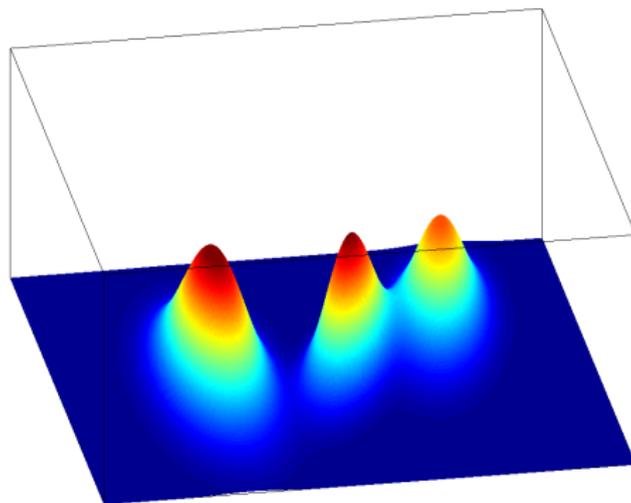
# Estimation “statistique”



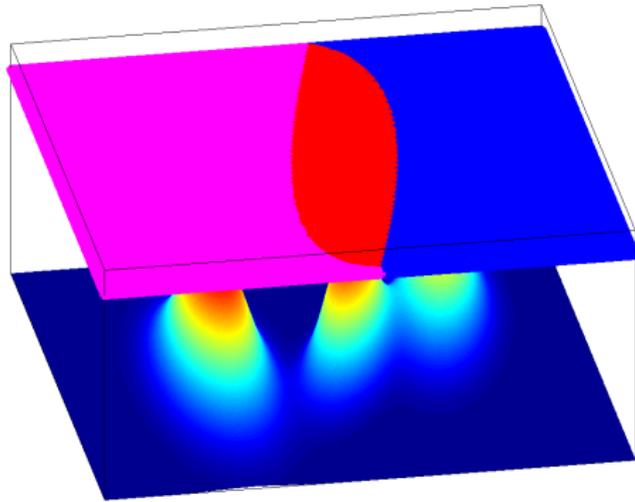
# Estimation “statistique”



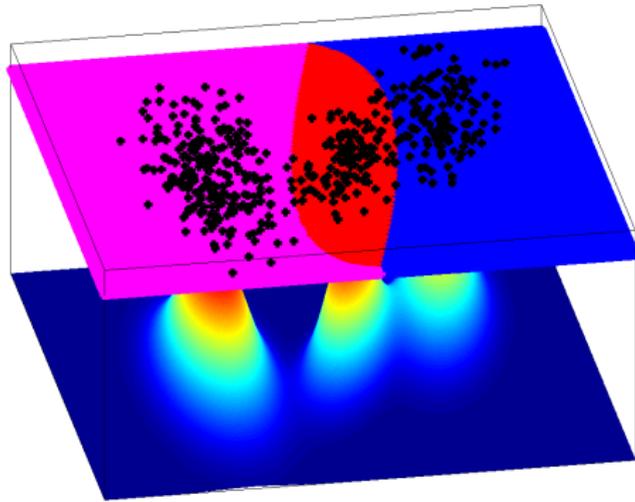
# Estimation “statistique”



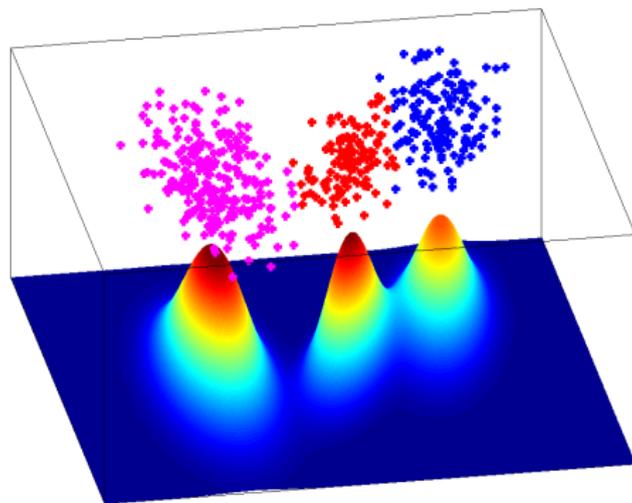
# Estimation “statistique”



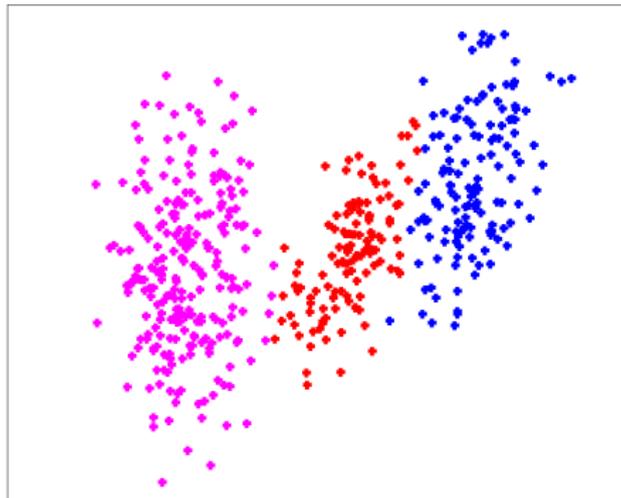
# Estimation “statistique”



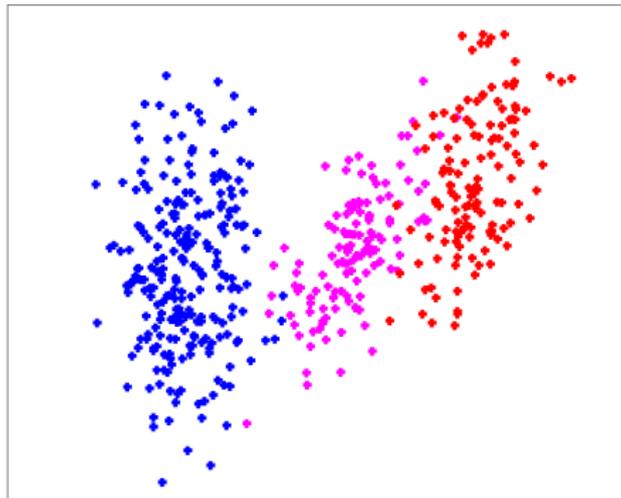
# Estimation “statistique”



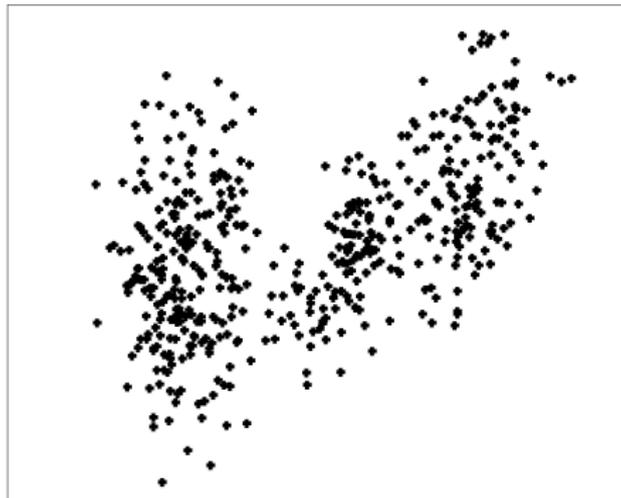
# Estimation “statistique”



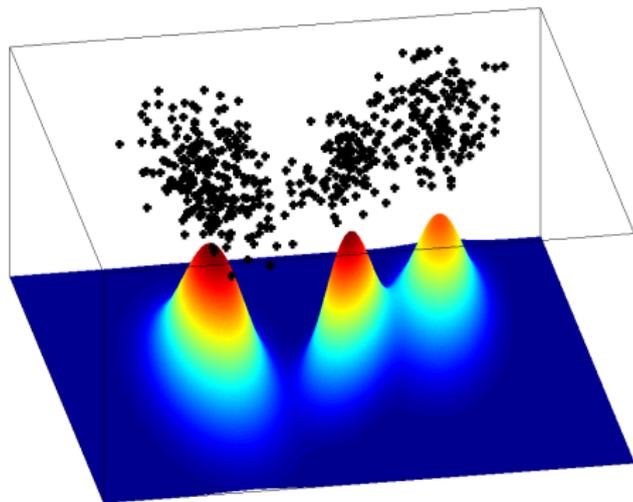
# Estimation “statistique”



# Estimation “statistique”



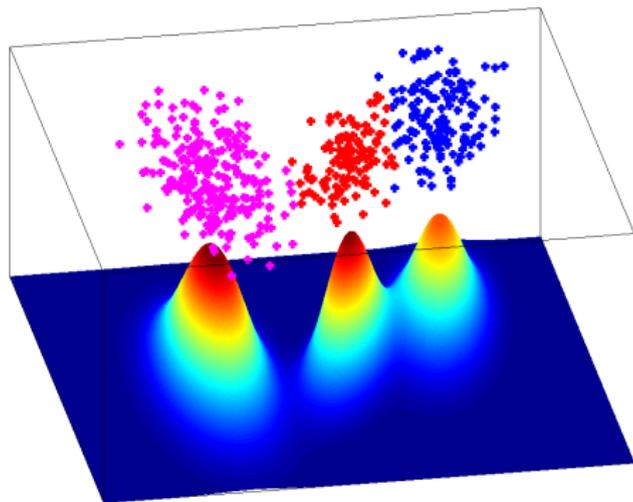
# Estimation “statistique”



- Estimation des  $\pi_k$ ,  $\hat{\mu}_k$  et  $\hat{\Sigma}_k$  par maximum de vraisemblance :

$$(\hat{\pi}_k, \hat{\mu}_k, \hat{\Sigma}_k) = \operatorname{argmax} \sum_{i=1}^N \log s_{K, (\pi_k, \mu_k, \Sigma_k)}(\mathcal{S}_i)$$

# Estimation “statistique”



- Estimation des  $\pi_k$ ,  $\hat{\mu}_k$  et  $\hat{\Sigma}_k$  par maximum de vraisemblance :

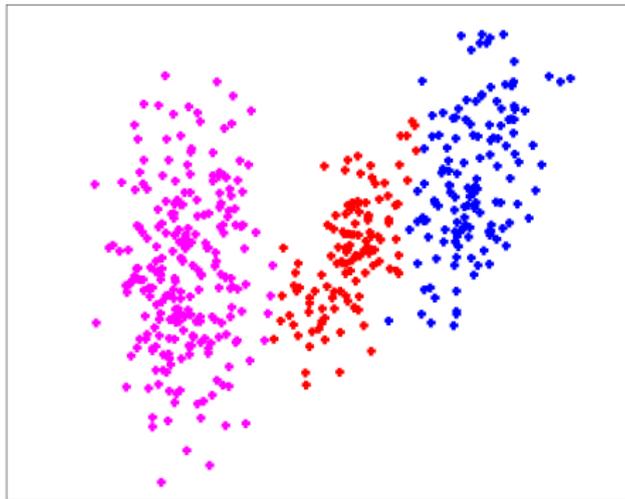
$$(\hat{\pi}_k, \hat{\mu}_k, \hat{\Sigma}_k) = \operatorname{argmax} \sum_{i=1}^N \log s_{K, (\pi_k, \mu_k, \Sigma_k)}(S_i)$$

- Estimation de  $\hat{k}(S)$  par maximum à posteriori :

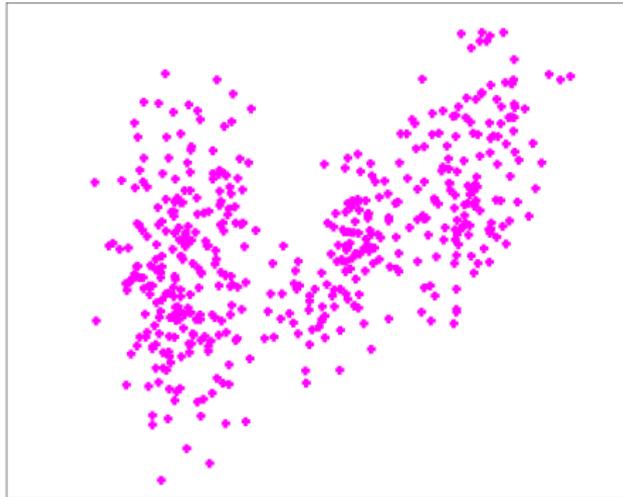
$$\hat{k}(S) = \operatorname{argmax} \hat{\pi}_k \mathcal{N}_{\mu_k, \Sigma_k}(S)$$

Combien de classes ?

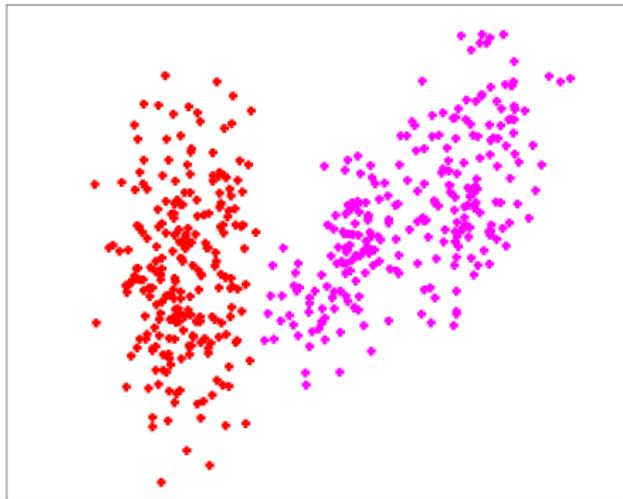
# Combien de classes ?



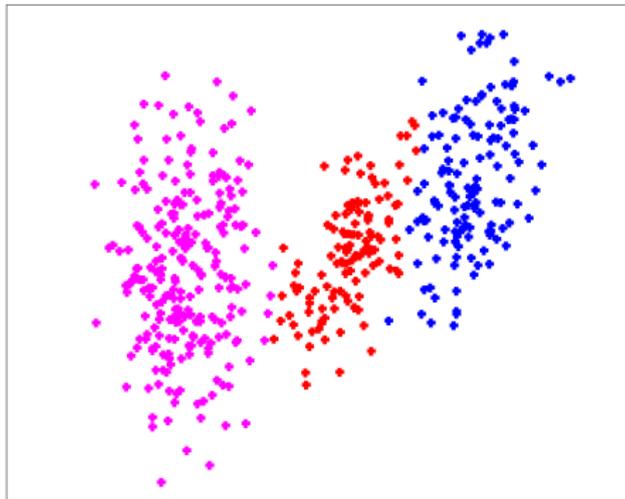
# Combien de classes ?



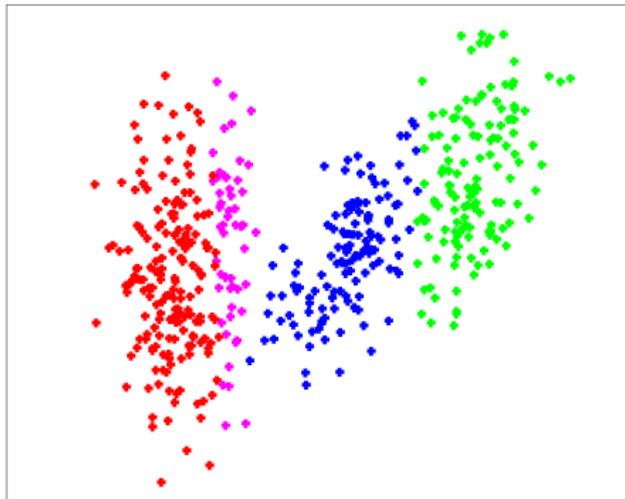
# Combien de classes ?



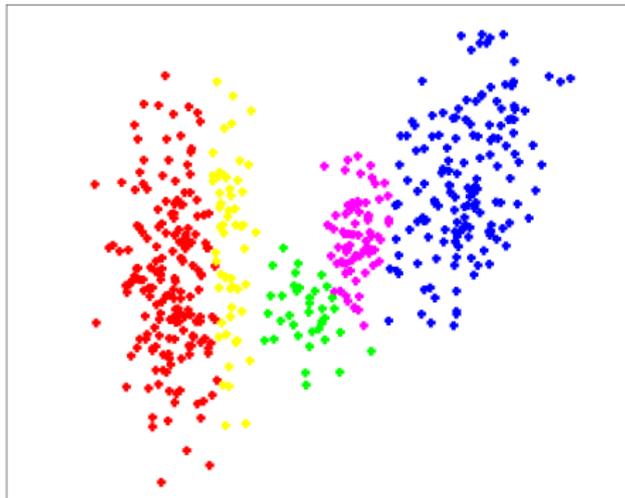
# Combien de classes ?



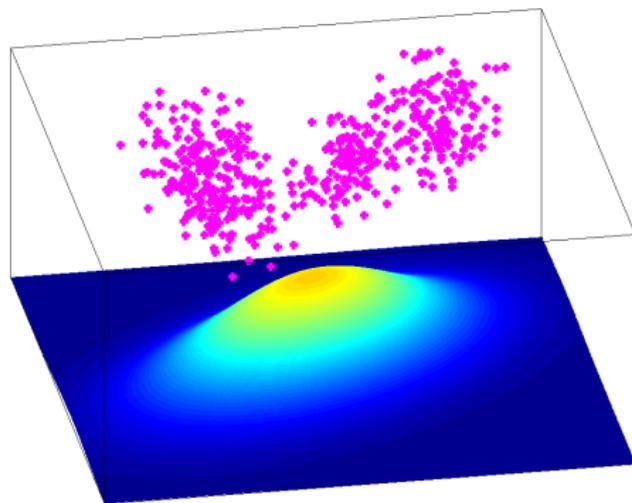
# Combien de classes ?



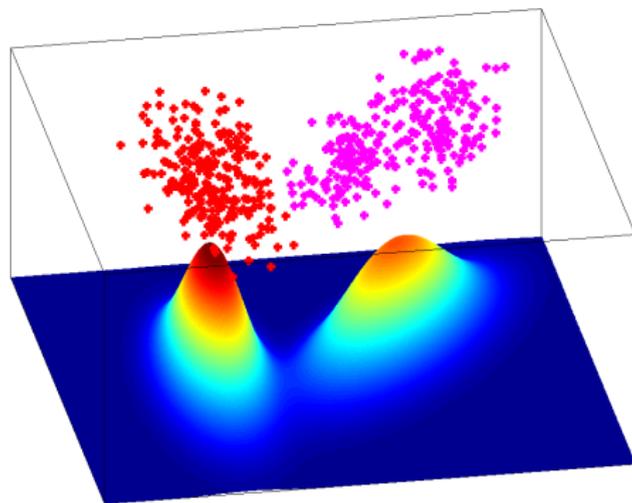
# Combien de classes ?



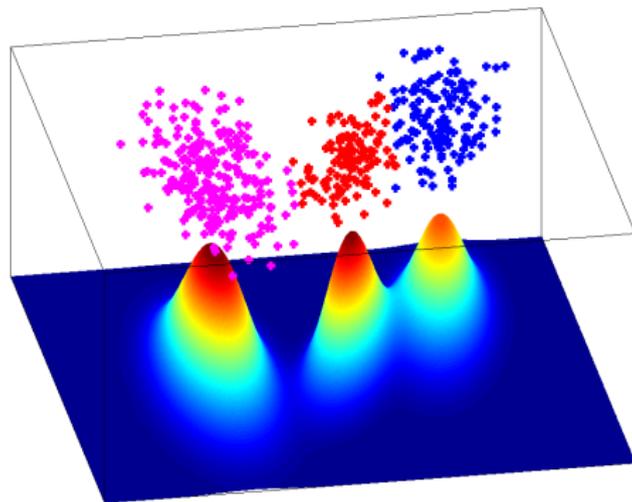
Combien de classes ?



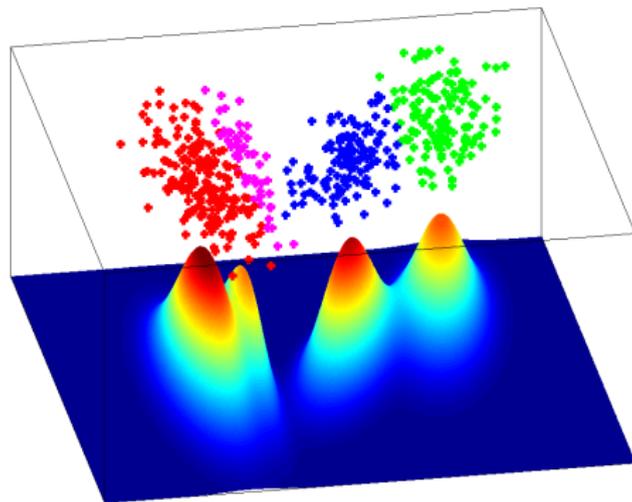
Combien de classes ?



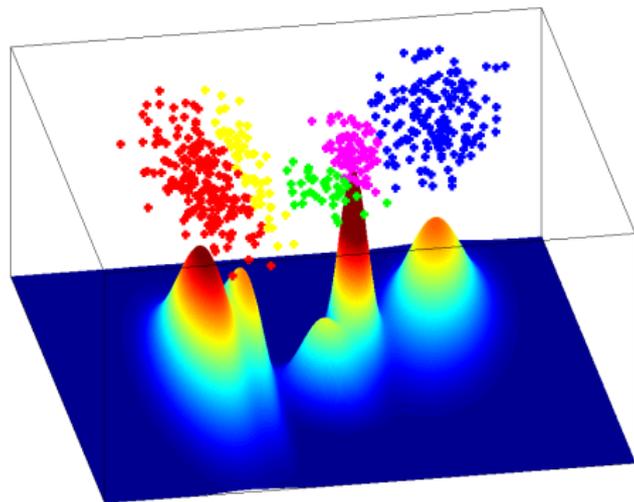
Combien de classes ?



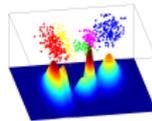
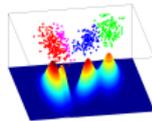
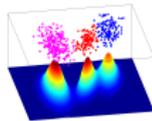
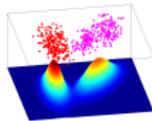
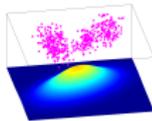
Combien de classes ?



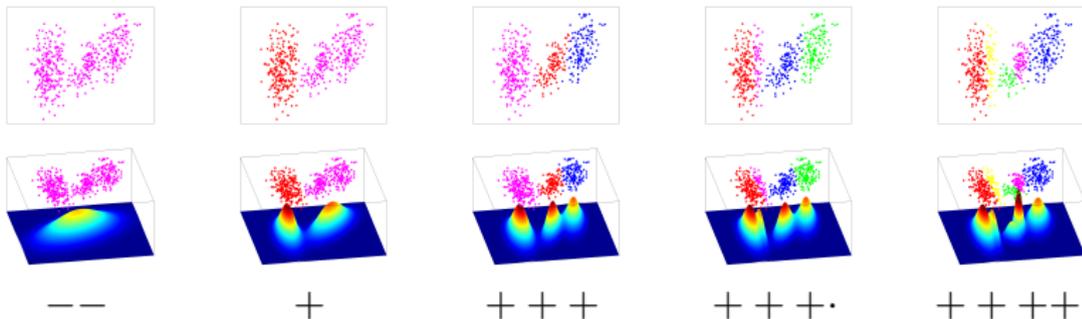
Combien de classes ?



# Combien de classes ?

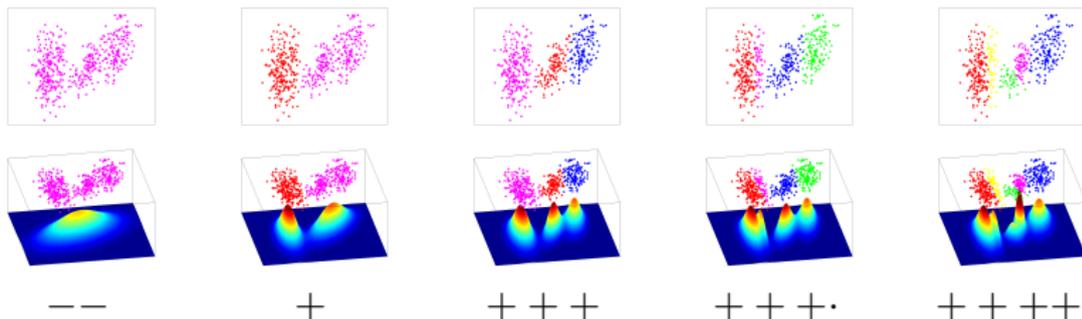


# Combien de classes ?



Fidélité

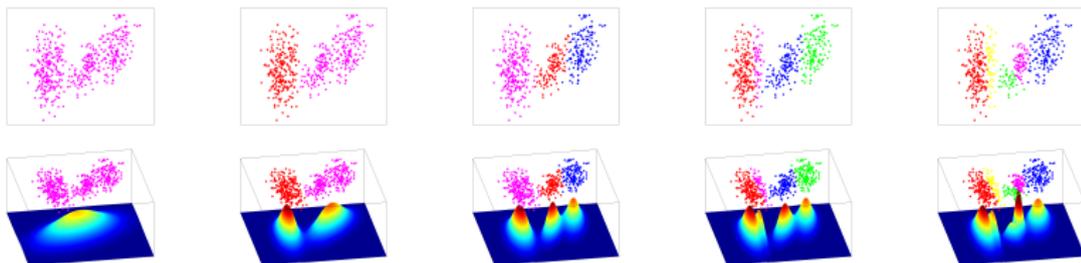
# Combien de classes ?



Fidélité

- Question difficile où la vraisemblance (la fidélité) ne suffit pas !

# Combien de classes ?



Fidélité

--

+

+++

+++.

++++

Simplicité

++++

+++

++

+

-

- Question difficile où la vraisemblance (la fidélité) ne suffit pas !
- Prise en compte de la complexité du modèle ?

# Le rasoir d'Ockham

# Le rasoir d'Ockham



*Les multiples ne doivent pas être utilisés sans nécessité.*

Guillaume d'Ockham (~ 1285 - 1347)

# Le rasoir d'Ockham



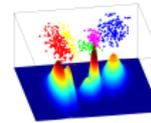
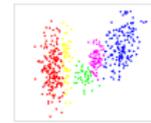
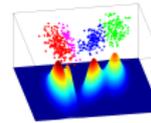
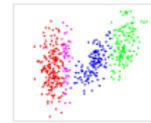
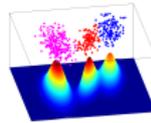
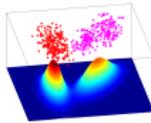
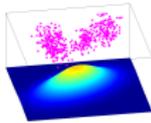
*Les multiples ne doivent pas être utilisés sans nécessité.*

Guillaume d'Ockham (~ 1285 - 1347)

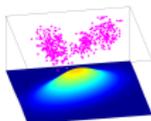
- Rasoir d'Ockham (principe de simplicité) : il ne faut pas ajouter des hypothèses, si celles utilisées suffisent déjà !
- Compromis entre pouvoir d'explication et simplicité.

# Sélection par pénalisation

# Sélection par pénalisation

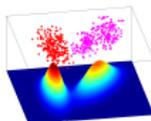


# Sélection par pénalisation

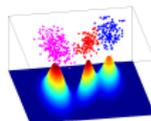


Vraisemblance

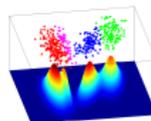
--



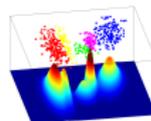
+



+ + +



+ + + .



+ + + +

Simplicité

+ + + +

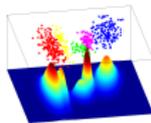
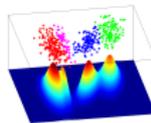
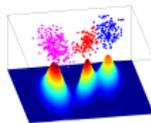
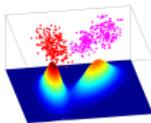
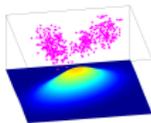
+ + +

+ +

+

-

# Sélection par pénalisation



Vraisemblance

--

+

+++

+++.

++++

+ Simplicité

++++

+++

++

+

-

= Compromis

++

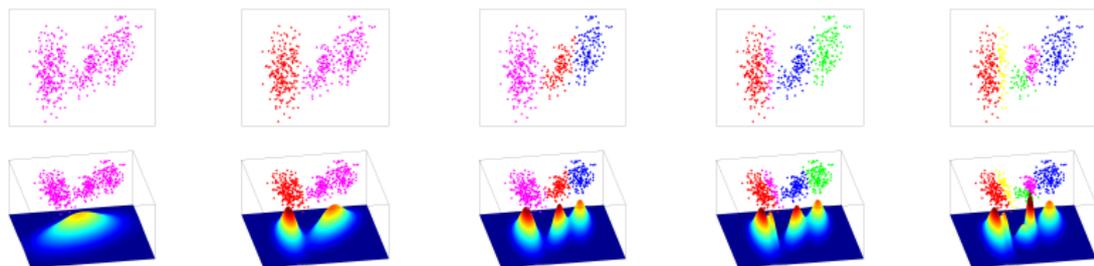
++++

+++++

++++.

+++

# Sélection par pénalisation



Vraisemblance

--

+

+++

+++.

++++

+ Simplicité

++++

+++

++

+

-

= Compromis

++

++++

+++++

++++.

+++

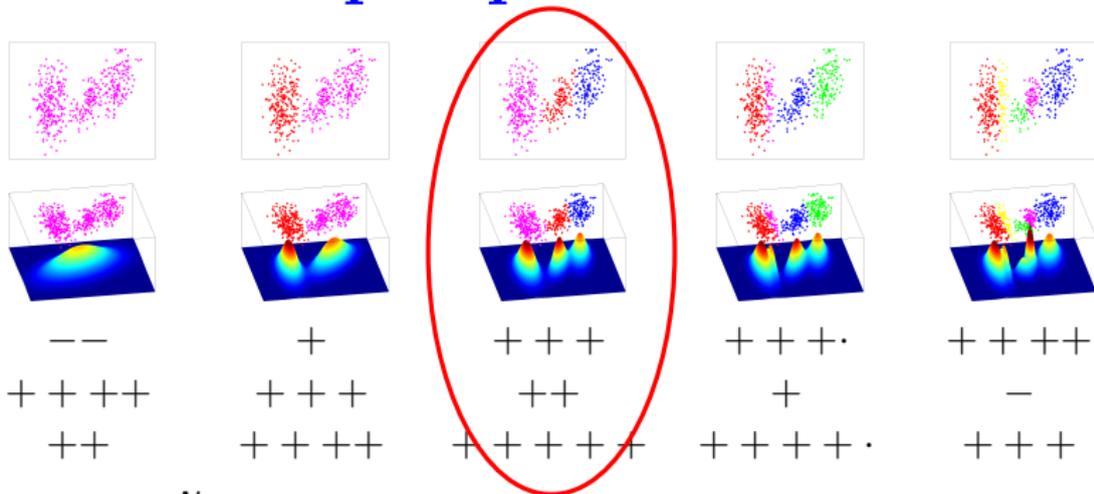
● Vraisemblance :  $\sum_{i=1}^N \log \hat{s}_K(X_i)$ .

● Simplicité :  $-\lambda \text{Dim}(S_K)$  (beaucoup de théorie derrière).

● Estimateur pénalisé :

$$\text{argmin} - \underbrace{\sum_{i=1}^N \log \hat{s}_K(X_i)}_{\text{Vraisemblance}} + \underbrace{\lambda \text{Dim}(S_K)}_{\text{Pénalité}}$$

# Sélection par pénalisation



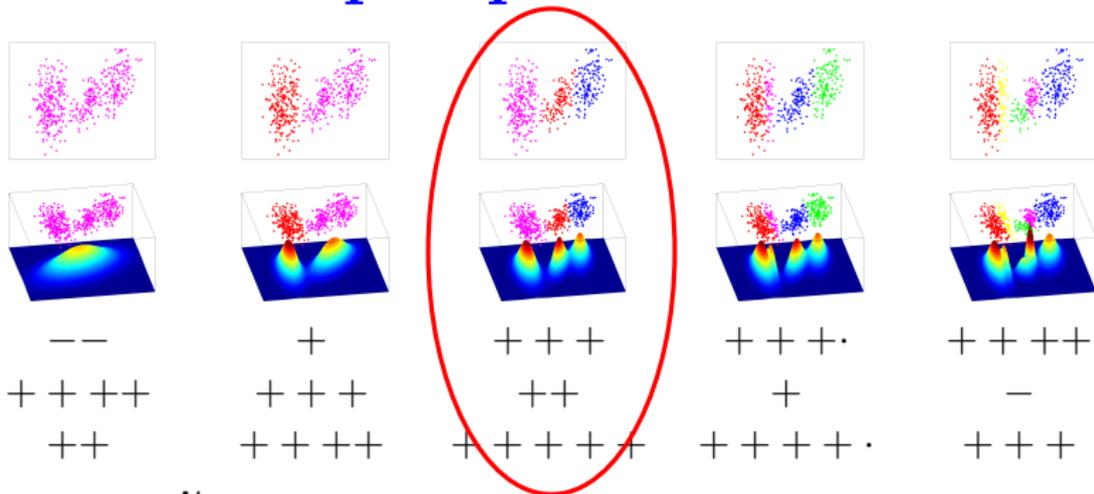
● Vraisemblance :  $\sum_{i=1}^N \log \hat{s}_K(X_i)$ .

● Simplicité :  $-\lambda \text{Dim}(S_K)$  (beaucoup de théorie derrière).

● Estimateur pénalisé :

$$\text{argmin} - \underbrace{\sum_{i=1}^N \log \hat{s}_K(X_i)}_{\text{Vraisemblance}} + \underbrace{\lambda \text{Dim}(S_K)}_{\text{Pénalité}}$$

# Sélection par pénalisation



● Vraisemblance :  $\sum_{i=1}^N \log \hat{s}_K(X_i)$ .

● Simplicité :  $-\lambda \text{Dim}(S_K)$  (beaucoup de théorie derrière).

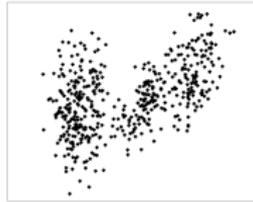
● Estimateur pénalisé :

$$\text{argmin} - \underbrace{\sum_{i=1}^N \log \hat{s}_K(X_i)}_{\text{Vraisemblance}} + \underbrace{\lambda \text{Dim}(S_K)}_{\text{Pénalité}}$$

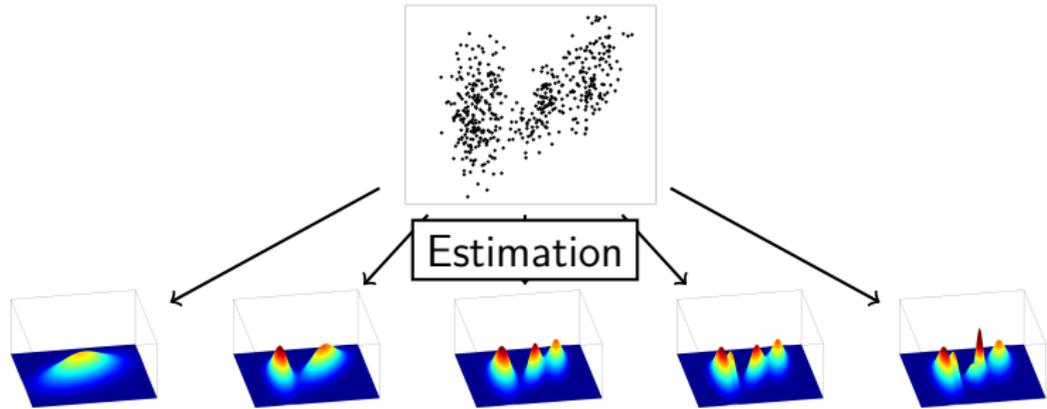
● Optimisation en  $K$  par exploration exhaustive !

# Méthodologie

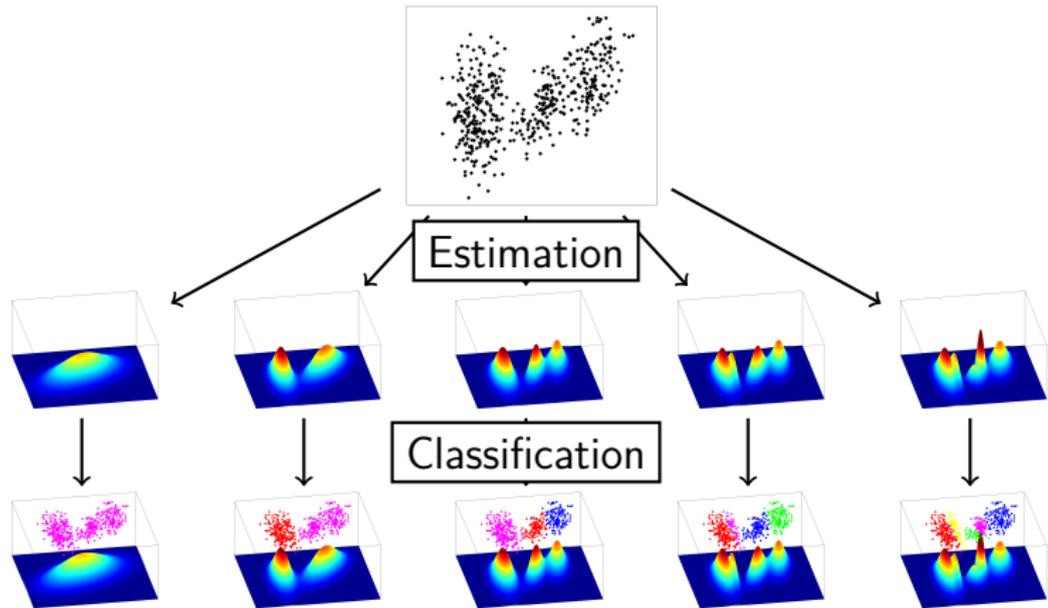
# Méthodologie



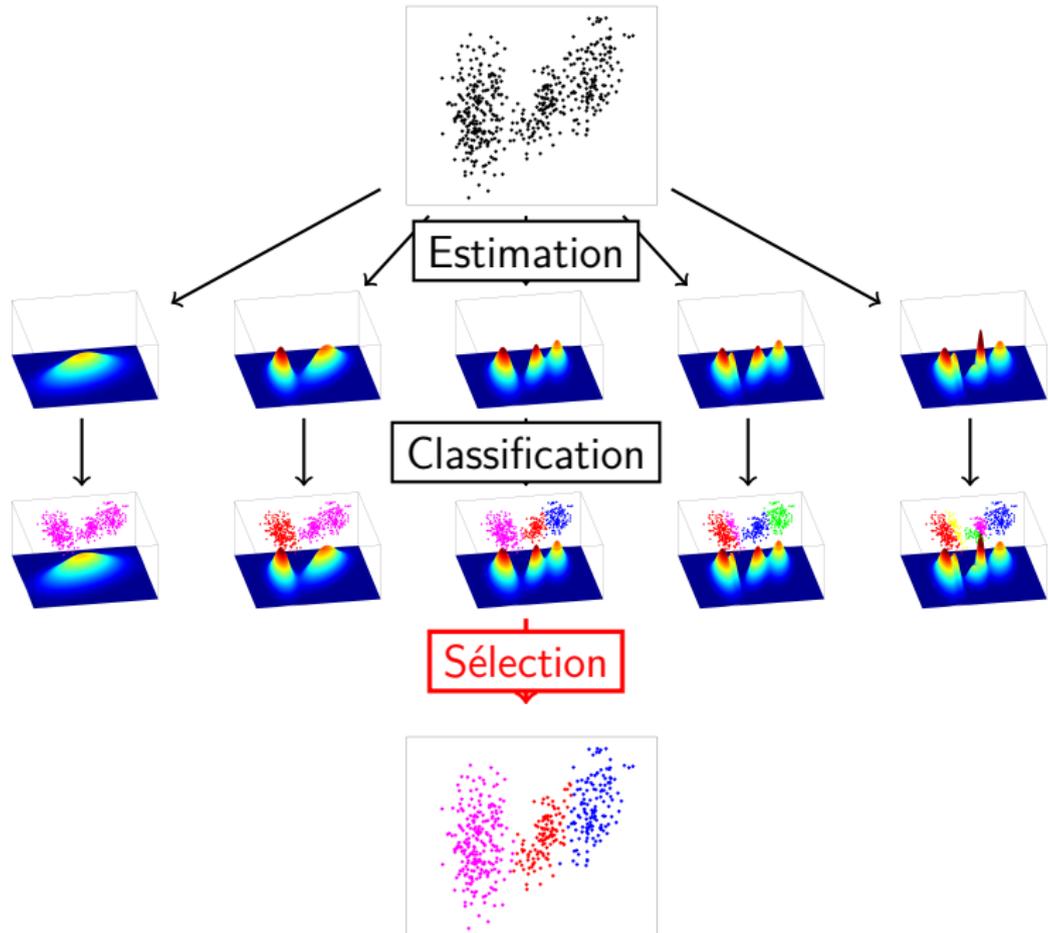
# Méthodologie



# Méthodologie

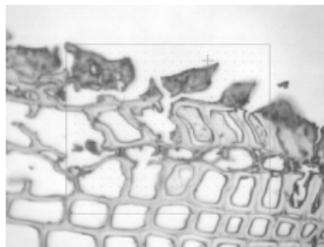


# Méthodologie



Retour à nos violons

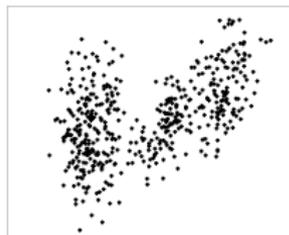
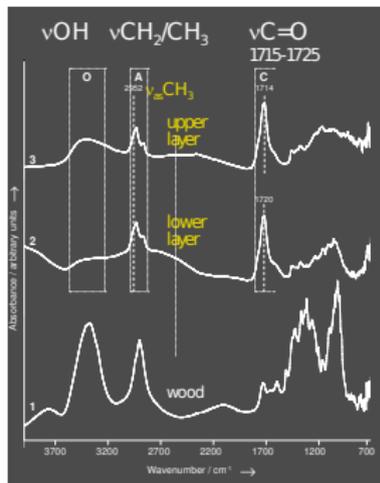
# Retour à nos violons



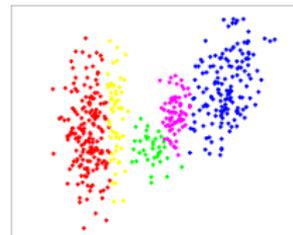
Segmentation



Représentation

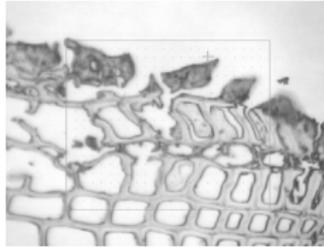


Classification

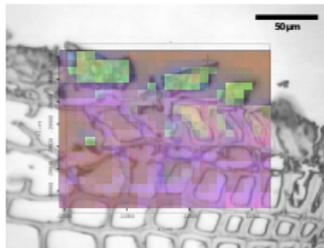


Info. Spatiale

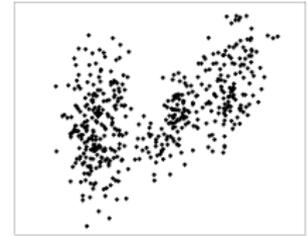
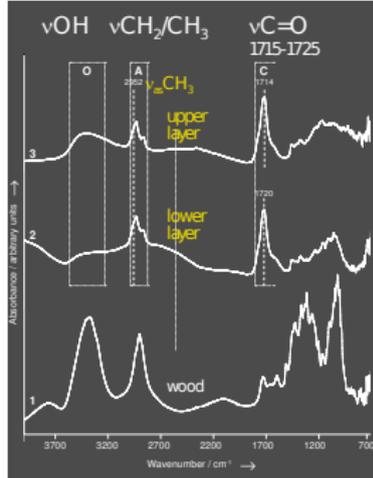
# Retour à nos violons



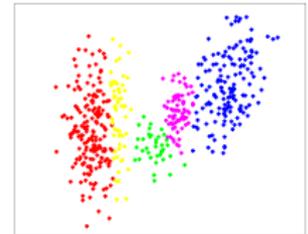
Segmentation



Représentation



Classification



Info. Spatiale

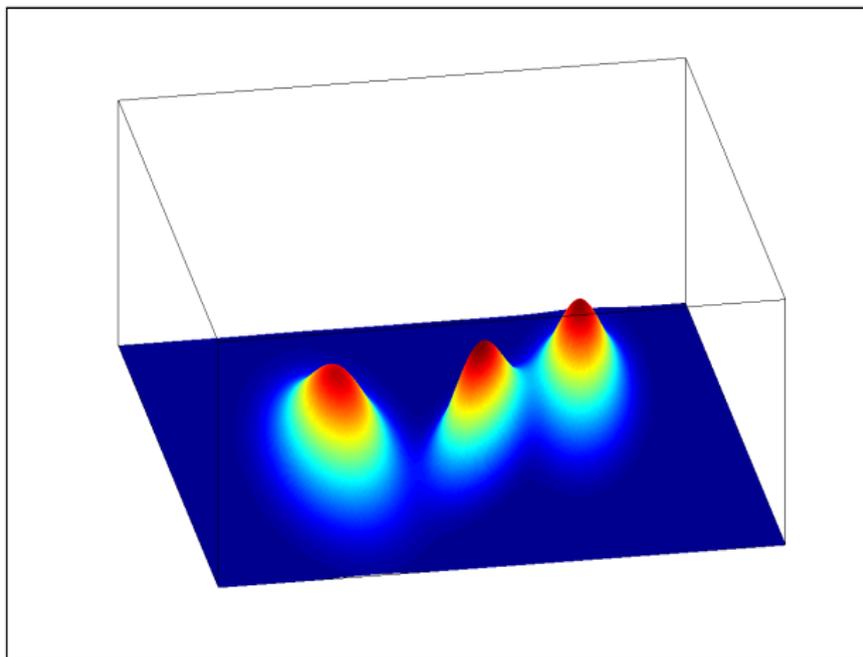
- Pb : classification  $\neq$  segmentation !

# Mélange de gaussien spatialisé

# Mélange de gaussien spatialisé

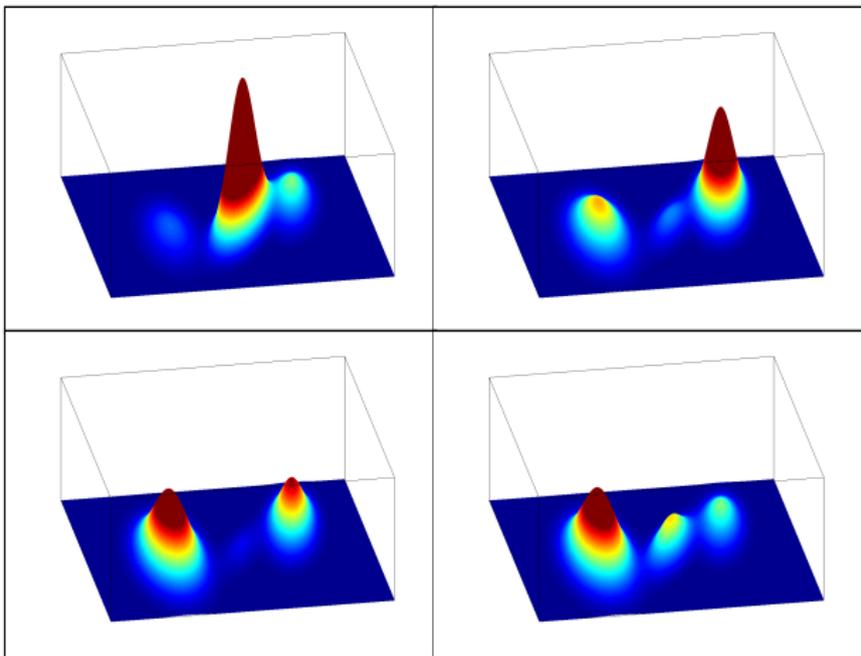
- Prise en compte du caractère spatial à travers un partitionnement récursif.

# Mélange de gaussien spatialisé



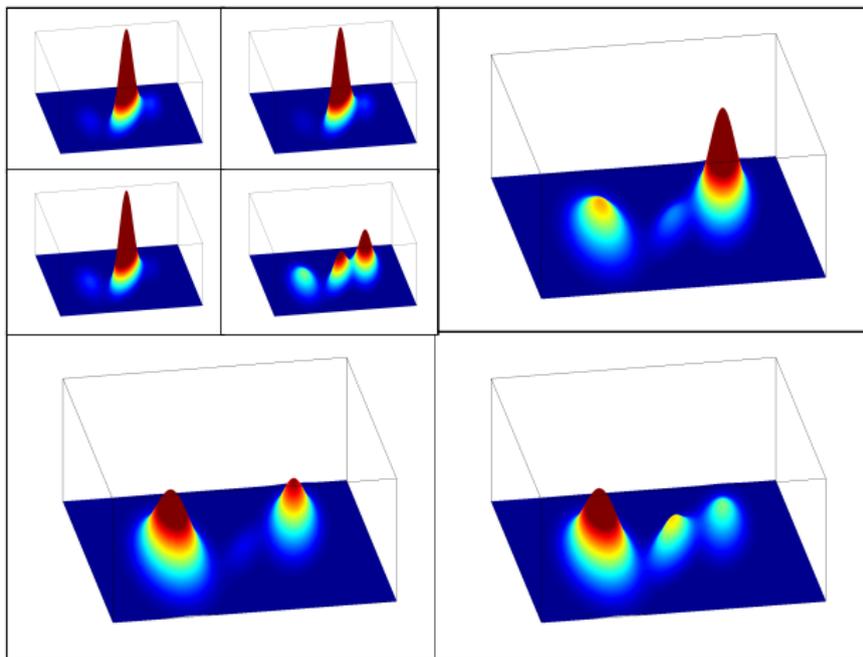
- Prise en compte du caractère spatial à travers un partitionnement récursif.

# Mélange de gaussien spatialisé



- Prise en compte du caractère spatial à travers un partitionnement récursif.

# Mélange de gaussien spatialisé



- Prise en compte du caractère spatial à travers un partitionnement récursif.
- Sélection de la partition (et du nombre de classes) par pénalisation.

# Mélange de gaussiennes et partition hiérarchique

- Prise en compte de la position spatiale  $x$  du spectre à travers les proportions du mélange (Kolaczyk et al) : modèle de densités conditionnelles

$$\sum_{k=1}^K \left( \sum_{\mathcal{R} \in \mathcal{P}} \pi_k[\mathcal{R}] \chi_{\{x \in \mathcal{R}\}} \right) \mathcal{N}_{\mu_k, \Sigma_k}(S).$$

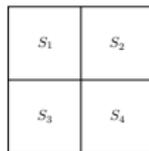
- constant par morceau sur une partition "hiérarchique",
- optimisation efficace possible,
- performance d'approximation raisonnable.
- $\dim(S_{K, \mathcal{P}}) = |\mathcal{P}|(K - 1) + \dim(S_K)$ .
- Pénalité  $\kappa \ln(n) \dim(S_{K, \mathcal{P}})$  suffisante pour
  - le contrôle théorique en terme d'estimation de densité,
  - l'optimisation numérique (EM + programmation dynamique).

# Mélange de gaussiennes et partition hiérarchique

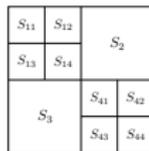
- Prise en compte de la position spatiale  $x$  du spectre à travers les proportions du mélange (Kolaczyk et al) : modèle de densités conditionnelles

$$\sum_{k=1}^K \left( \sum_{\mathcal{R} \in \mathcal{P}} \pi_k[\mathcal{R}] \chi_{\{x \in \mathcal{R}\}} \right) \mathcal{N}_{\mu_k, \Sigma_k}(\mathcal{S}).$$

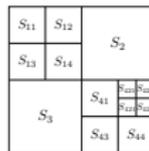
- constant par morceau sur une partition “hiérarchique”,
- optimisation efficace possible,
- performance d'approximation raisonnable.



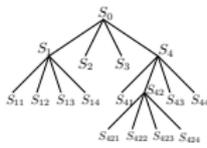
Etape 1



Etape 2



Etape 3



Arbre quaternaire

- $\dim(\mathcal{S}_{K, \mathcal{P}}) = |\mathcal{P}|(K - 1) + \dim(\mathcal{S}_K)$ .
- Pénalité  $\kappa \ln(n) \dim(\mathcal{S}_{K, \mathcal{P}})$  suffisante pour
  - le contrôle théorique en terme d'estimation de densité,
  - l'optimisation numérique (EM + programmation dynamique).

# Segmentation automatique

- Résultat numérique selon la prise en compte du caractère spatial :

Sans

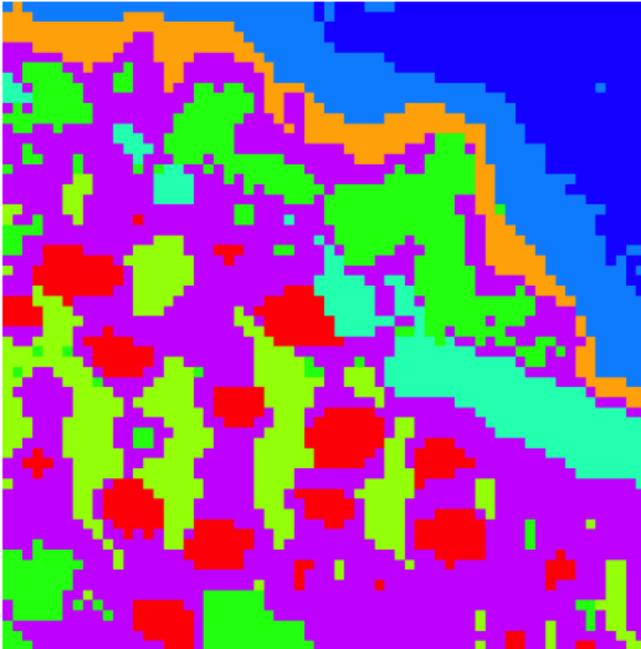
Avec

- $K = 8$ ,  $[L_k D B]^K$  et partition optimale.
- Calibration de la pénalité par heuristique de pente.
- Réduction de dimension par (simple) ACP...

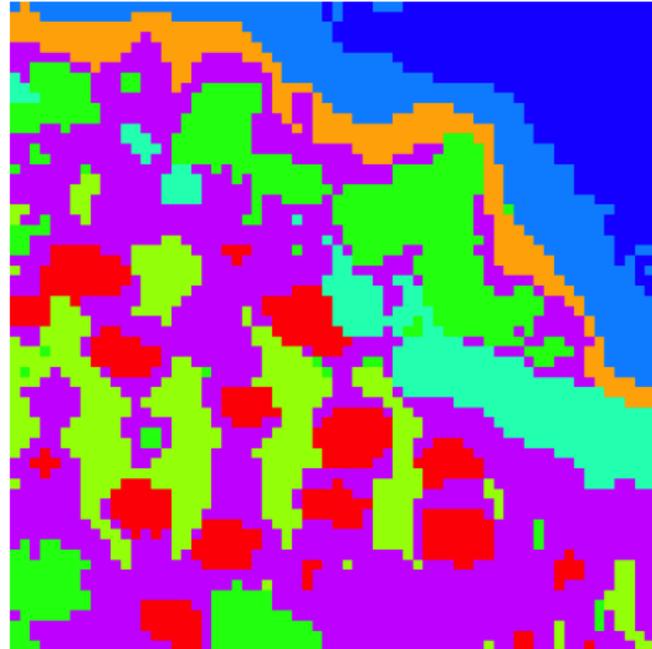
# Segmentation automatique

- Résultat numérique selon la prise en compte du caractère spatial :

Sans



Avec

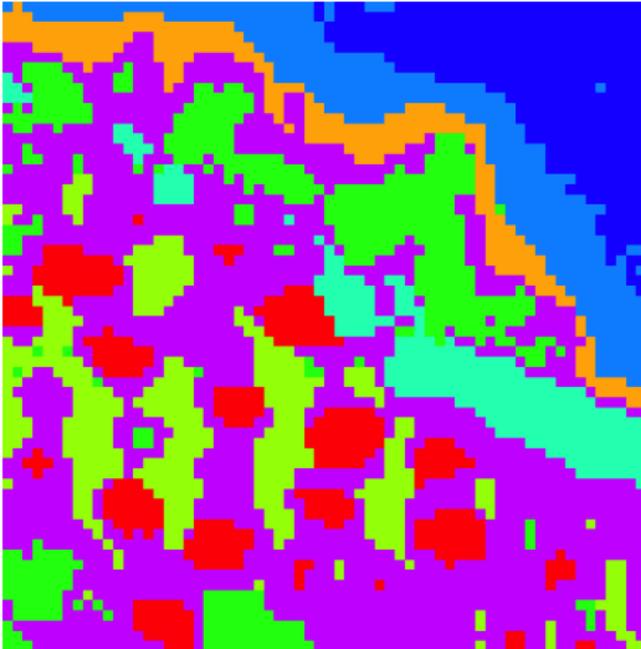


- $K = 8$ ,  $[L_k DB]^K$  et partition optimale.
- Calibration de la pénalité par heuristique de pente.
- Réduction de dimension par (simple) ACP...

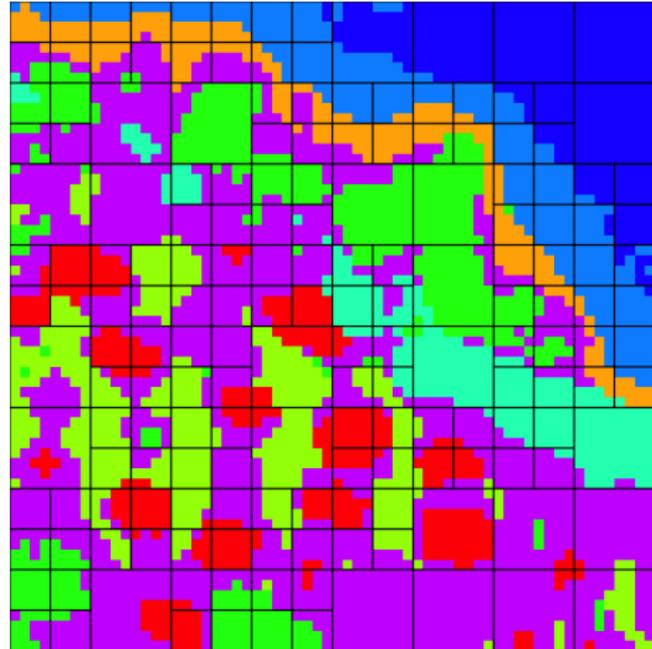
# Segmentation automatique

- Résultat numérique selon la prise en compte du caractère spatial :

Sans



Avec



- $K = 8$ ,  $[L_k DB]^K$  et partition optimale.
- Calibration de la pénalité par heuristique de pente.
- Réduction de dimension par (simple) ACP...

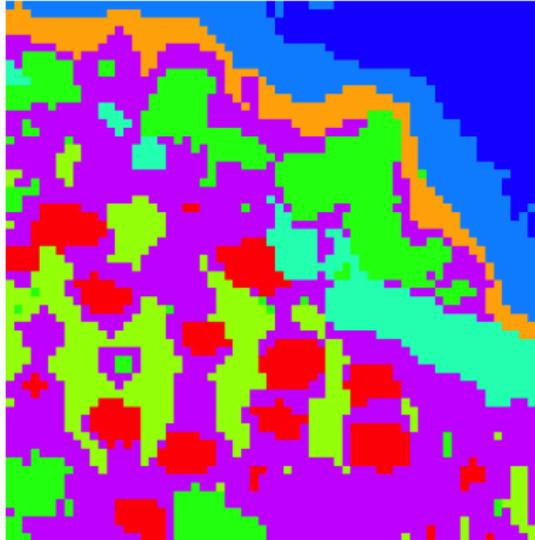
# Segmentation et classification

# Le secret de Stradivarius



- Deux couches fines de vernis :
  - une première couche d'huile simple, similaire à celle des peintres, pénétrant légèrement le bois,
  - une seconde d'un mélange huile, résine de pin, pigments donnant cette couleur rouge caractéristique.
- Technique classique pour l'époque.
- Le secret de Stradivarius n'est pas dans le vernis !

# Le secret de Stradivarius



- Deux couches fines de vernis :
  - une première couche d'huile simple, similaire à celle des peintres, pénétrant légèrement le bois,
  - une seconde d'un mélange huile, résine de pin, pigments donnant cette couleur rouge caractéristique.
- Technique classique pour l'époque.
- Le secret de Stradivarius n'est pas dans le vernis !

# Conclusion

- Cadre :
  - Problème de segmentation non supervisée.
  - Utilisation d'un modèle de mélange de gaussiennes localisé.
  - Localisation d'une méthode spectrale.
- Résultats :
  - Algorithme automatisé de segmentation non supervisée.
  - Algorithme efficace pour la minimisation (EM + Programmation dynamique).
  - Justification théorique à travers un problème d'estimation de densités conditionnelles.
- Perspectives :
  - Comparaison fine avec les méthodes *spectrales*, les méthodes *spatiales* et leurs combinaisons !
  - Lien précis entre l'estimation de densités conditionnelles et les performances de segmentation.
  - Calibration par heuristique de pente des deux problèmes.
  - Robustesse au bruit d'acquisition améliorée ?
  - Réduction de dimension adaptée à la classification non supervisée...

# Conclusion

- Cadre :
  - Problème de segmentation non supervisée.
  - Utilisation d'un modèle de mélange de gaussiennes localisé.
  - Localisation d'une méthode spectrale.
- Résultats :
  - Algorithme automatisé de segmentation non supervisée.
  - Algorithme efficace pour la minimisation (EM + Programmation dynamique).
  - Justification théorique à travers un problème d'estimation de densités conditionnelles.
- Perspectives :
  - Comparaison fine avec les méthodes *spectrales*, les méthodes *spatiales* et leurs combinaisons!
  - Lien précis entre l'estimation de densités conditionnelles et les performances de segmentation.
  - Calibration par heuristique de pente des deux problèmes.
  - Robustesse au bruit d'acquisition améliorée?
  - Réduction de dimension adaptée à la classification non supervisée...