

# Analyse de Données – ID Centres Mobiles

Philippe LERAY

`philippe.leray@univ-nantes.fr`

Equipe CONnaissances et Décision

Laboratoire d'Informatique de Nantes Atlantique – FRE 2729

Site de l'Ecole Polytechnique de l'université de Nantes

## Points abordés

- Généralités
- Clustering hiérarchique
- **Clustering par partitionnement**
  - **K-Means, Nuées dynamiques**
  - CLARA (Clustering LARge Applications), Fuzzy C-Means, ...

## Centres mobiles – K-means – K-moyennes

## Principe

- (Forgy 1965, MacQueen 1967)
- répartir les  $N$  points en  $K$  ensembles disjoints
- regrouper les points proches
  
- problème de minimisation :

$$J = \sum_{g=1}^K \sum_{i \in C_g} d^2(x_i, \mu_g)$$

- $\Rightarrow$  NP difficile
- on peut juste trouver un minimum local

## Algorithme

- Initialiser  $\mu_1, \dots, \mu_K$
- Répéter
  - affectation de chaque point à son cluster le plus proche

$$C(x_i) = \min_g d(x_i, \mu_g)$$

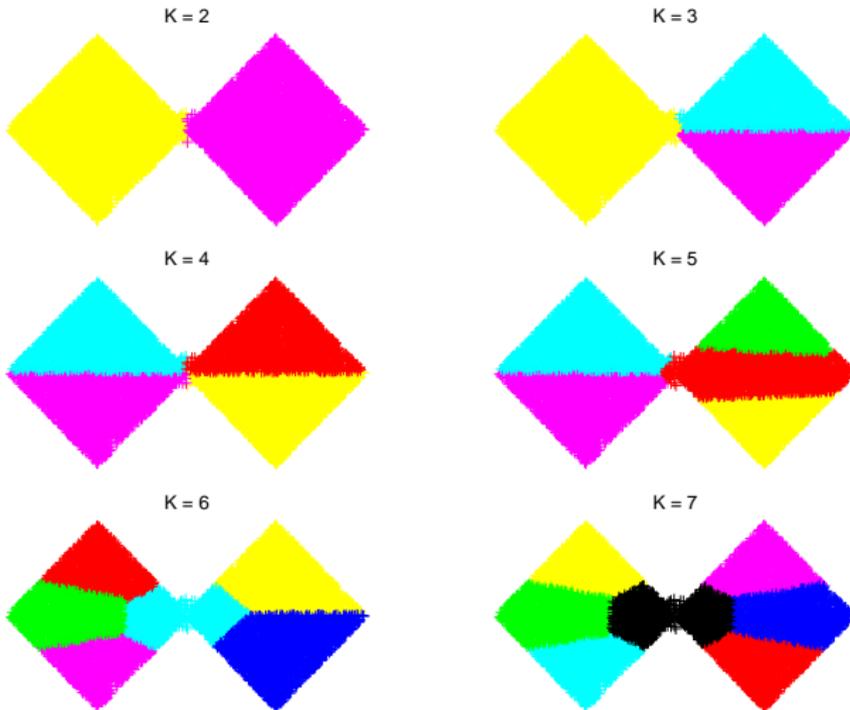
- recalculer le centre  $\mu_i$  de chaque cluster

$$\mu_g = \frac{1}{N_g} \sum_{i \in C_g} x_i$$

- Tant que  $\|\Delta\mu\| > \epsilon$

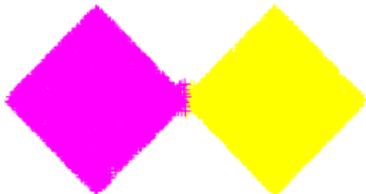
Complexité =  $O(Knl)$  ( $l$ : itérations)

# K-Means : exemple 1

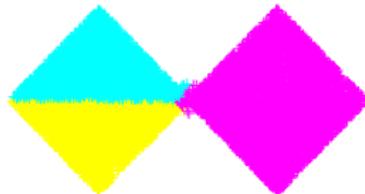


# K-Means : exemple 1

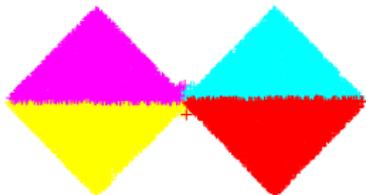
K = 2



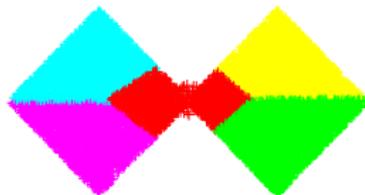
K = 3



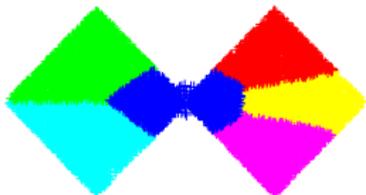
K = 4



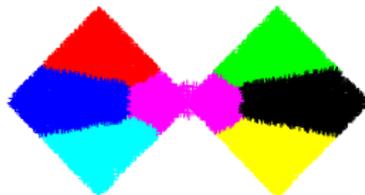
K = 5



K = 6

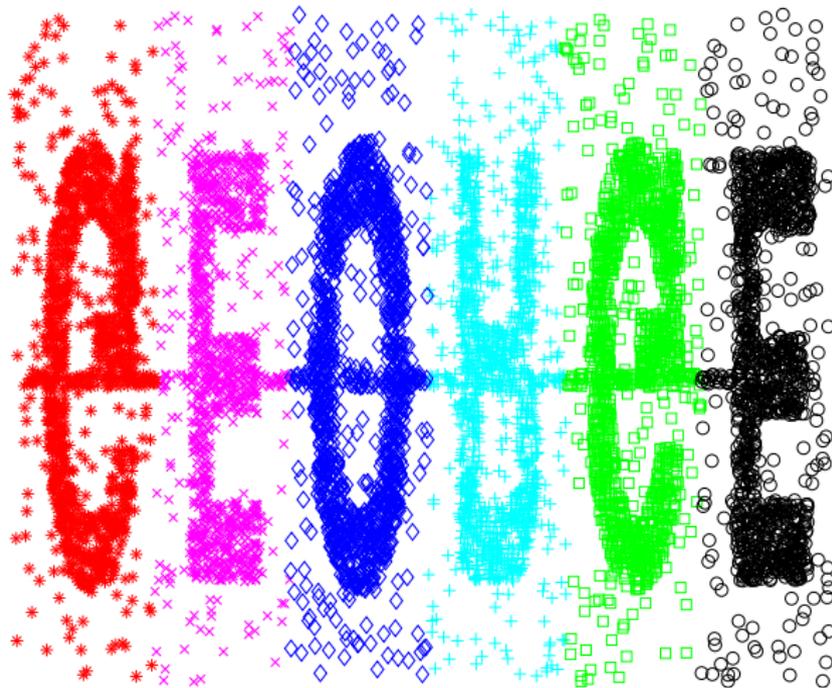


K = 7



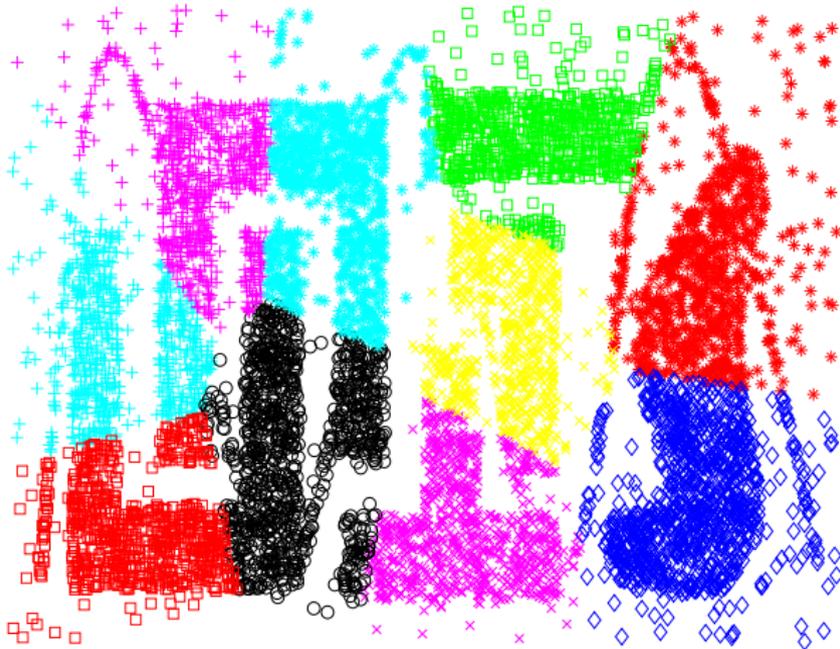
# K-Means : exemple 2

K = 6



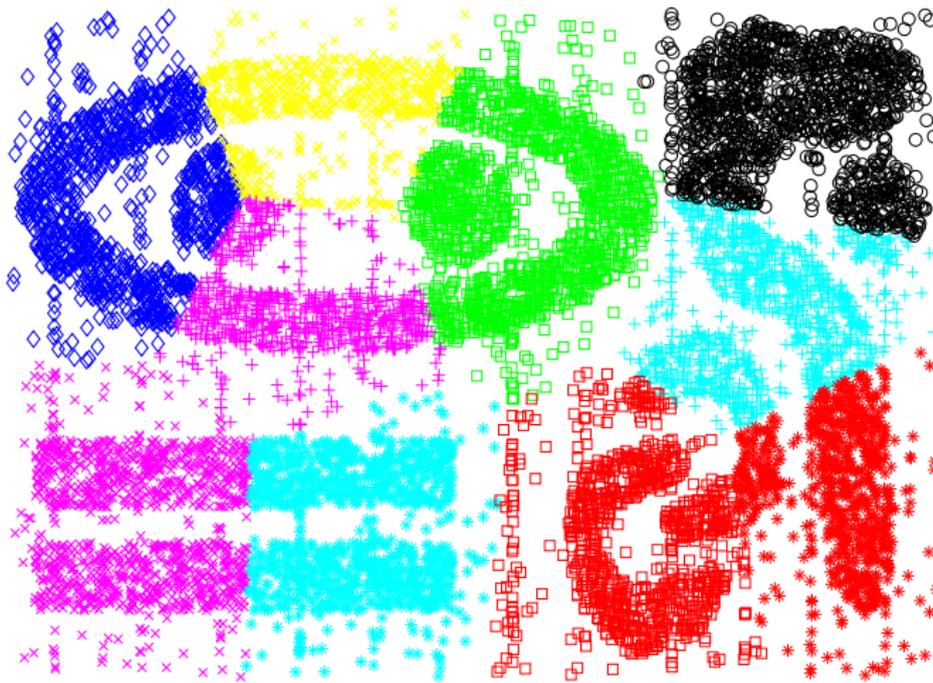
# K-Means : exemple 3

K = 10



# K-Means : exemple 4

K = 10



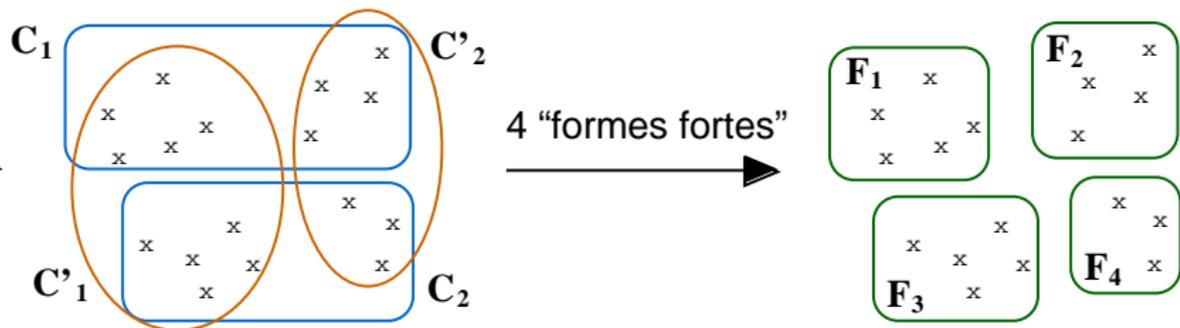
# K-Means

## Initialisation

- Initialisation des  $\mu_j$  :
  - aléatoirement dans l'intervalle de définition des  $x_i$
  - aléatoirement dans l'ensemble des  $x_i$
- Des initialisations différentes de peuvent mener à des clusters différents (problème de minima locaux)

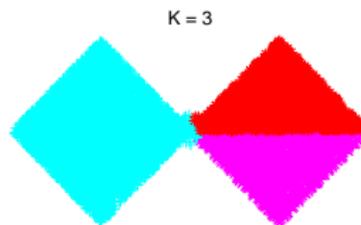
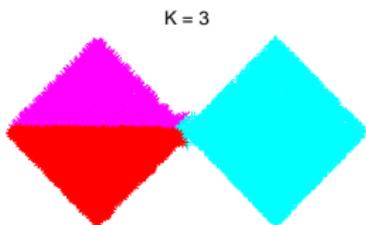
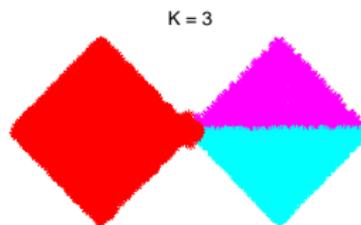
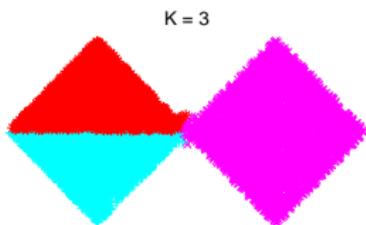
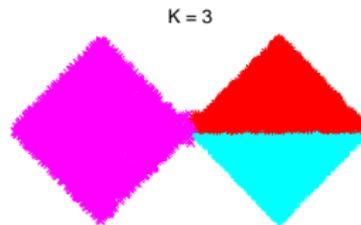
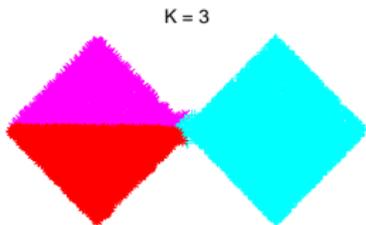
## Formes fortes

- méthode **générale** pour obtenir des clusters "stables"
  - on répète l'algo des K-Means  $r$  fois
  - on regroupe ensemble les  $x_i$  qui se retrouvent toujours dans les mêmes clusters.
  - on supprime les regroupements "faibles"



# K-Means : formes fortes

K-Means répété 6 fois



## K-Means : formes fortes

- On trouve 5 regroupements de points différents :

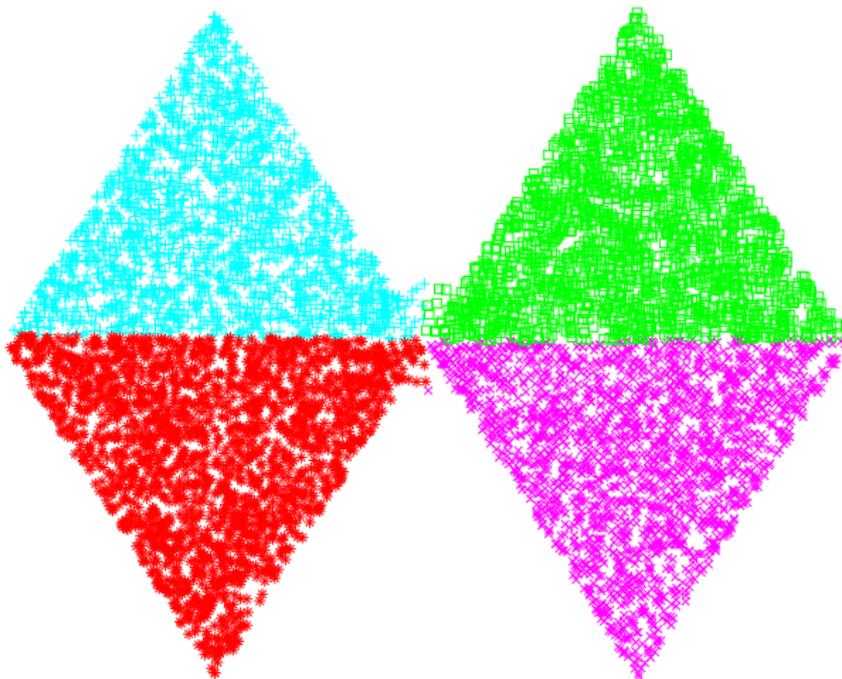
	$F_1$	$F_2$	$F_3$	$F_4$	$F_5$
$N_i$	2040	1940	49	2042	1929

- $F_3$  n'est pas représentatif
- $F_1$ ,  $F_1$ ,  $F_4$  et  $F_5$  sont les formes fortes
- on peut recalculer les clusters à partir des centres des formes fortes

# K-Means : formes fortes

K-Means répété 6 fois

4 Formes fortes pour  $K = 3$



## K-Means séquentiels

Adaptation des k-Means lorsque les exemples arrivent au fur et à mesure

### Algorithme

- Initialiser  $\mu_1, \dots, \mu_K$
- Initialiser  $n_1, \dots, n_K$  à 0
- Répéter
  - acquérir  $x$
  - affectation de chaque point à son cluster le plus proche

$$\mu_i = \operatorname{argmin}_g d(x, \mu_g)$$

- incrémenter  $n_i$
- recalculer le centre  $\mu_i$  de ce cluster

$$\mu_i = \mu_i + \frac{1}{n_i}(x - \mu_i)$$

## Principe

- Généralisation des K-Means
- Utilisation de noyaux = représentation d'un cluster
  - barycentre ( =  $\mu$  pour les K-means)
  - $n$  points représentatifs
  - ...