



**SUJET:**  
**UN ALGORITHME 'BIG-DATA' POUR LA LOCAL-PLS**

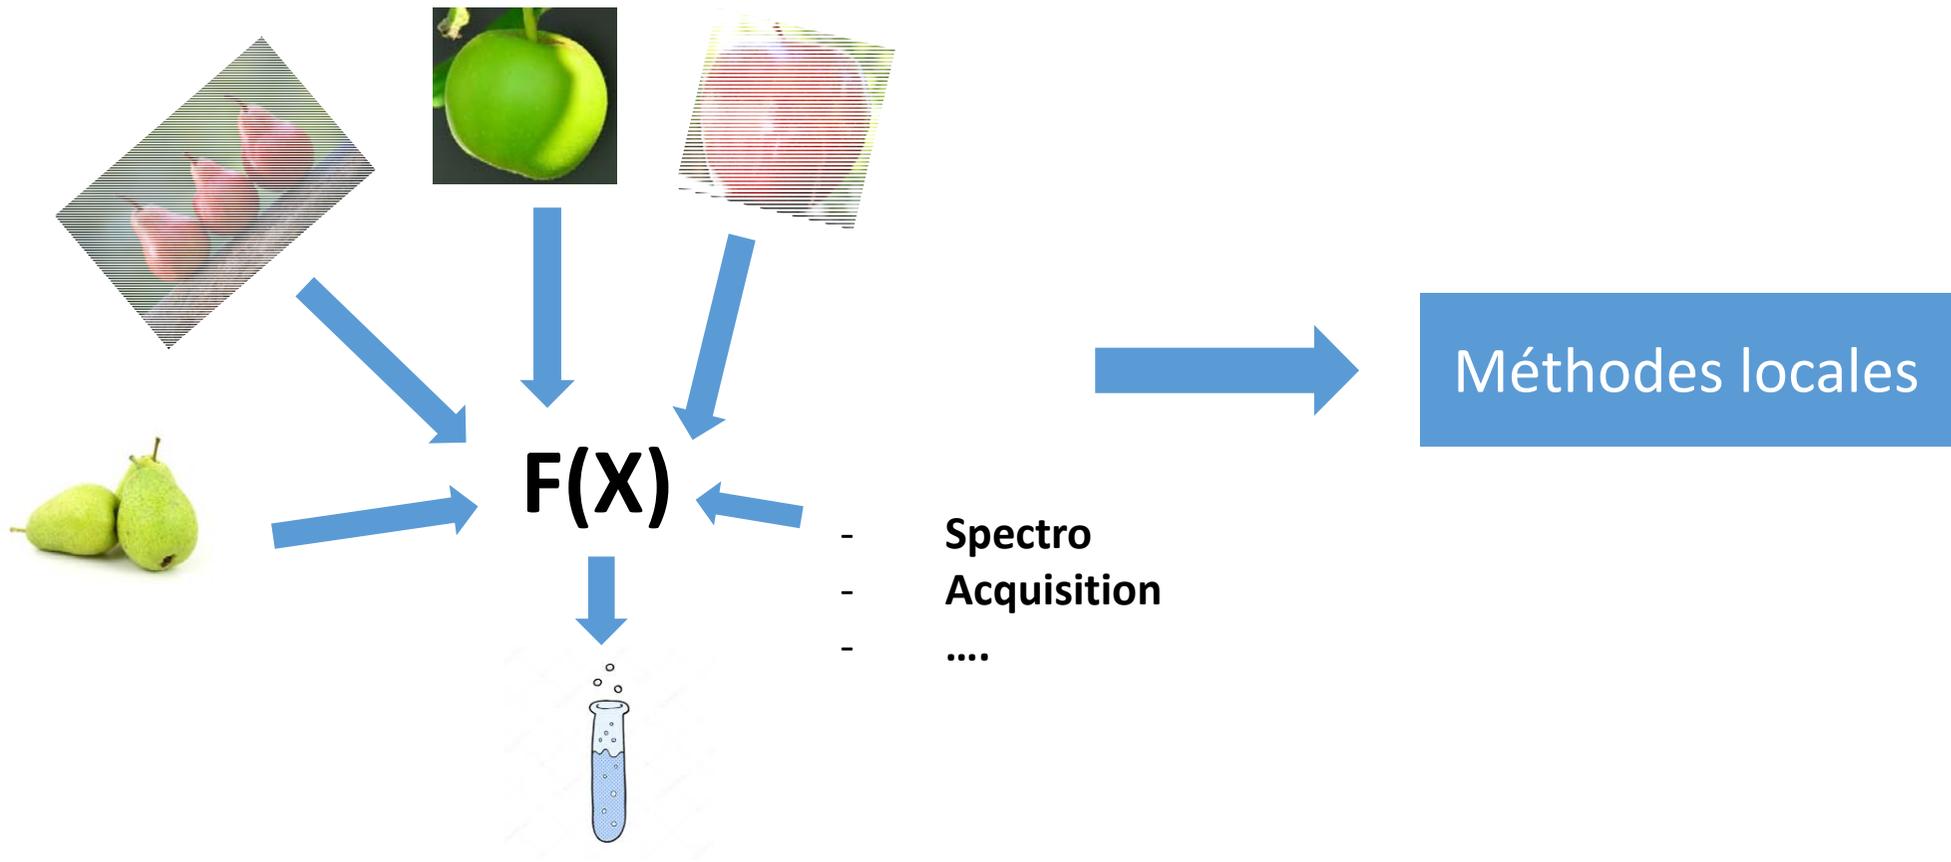


Présenté par: Maxime Metz

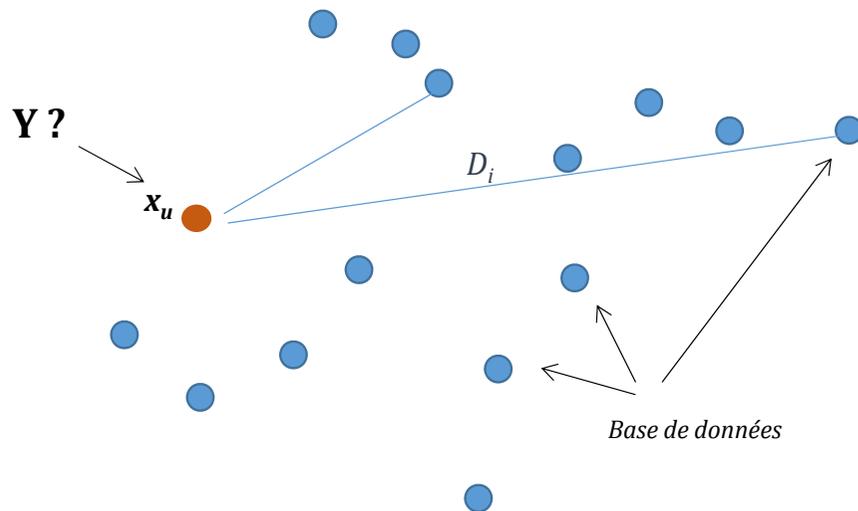
Supervisé par: Matthieu Lesnoff, Jean-Michel Roger



Un algorithme 'big-data' pour la Local-PLS  
**CONTEXTE**



## Les méthodes locales :



## Idées de base :

- Un point à prédire un modèle
- Les points ont une importance différente dans le modèle calculé

## Deux cas :

- Localement pondérée
- Sélection de voisins

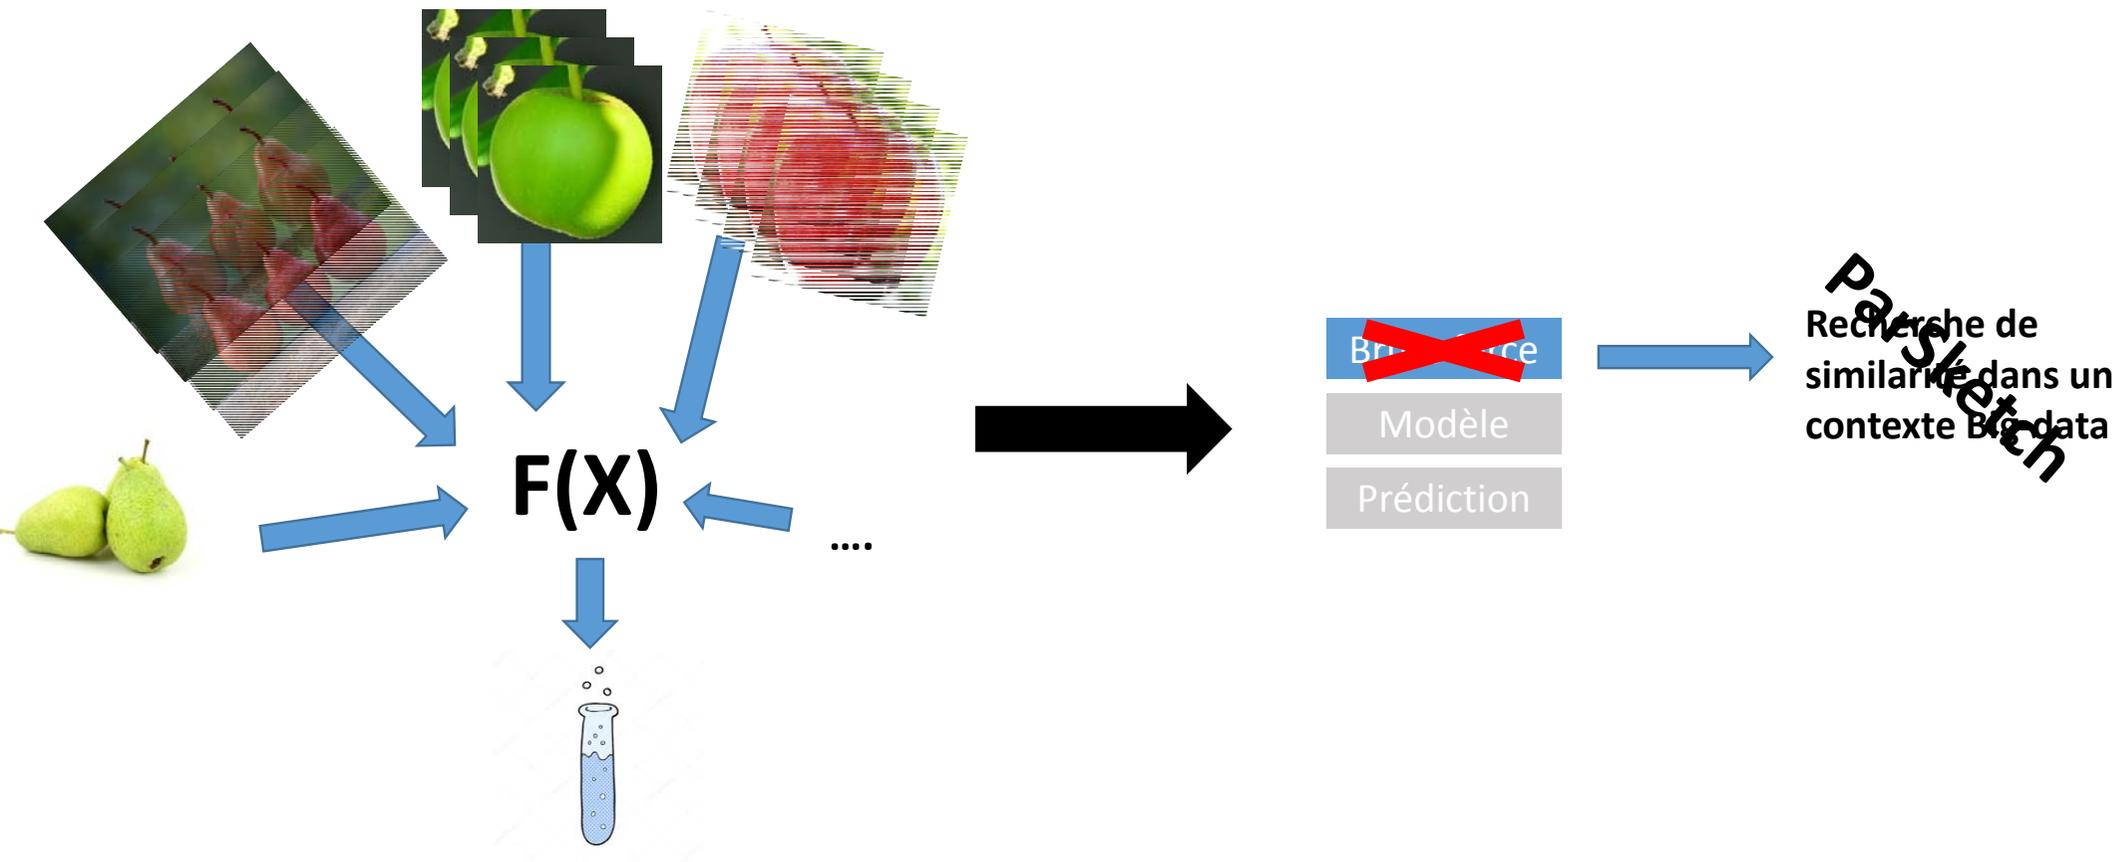
## Une procédure générale :

Brute force

Modèle

Prédiction

# Les méthodes locales pour les données massives :

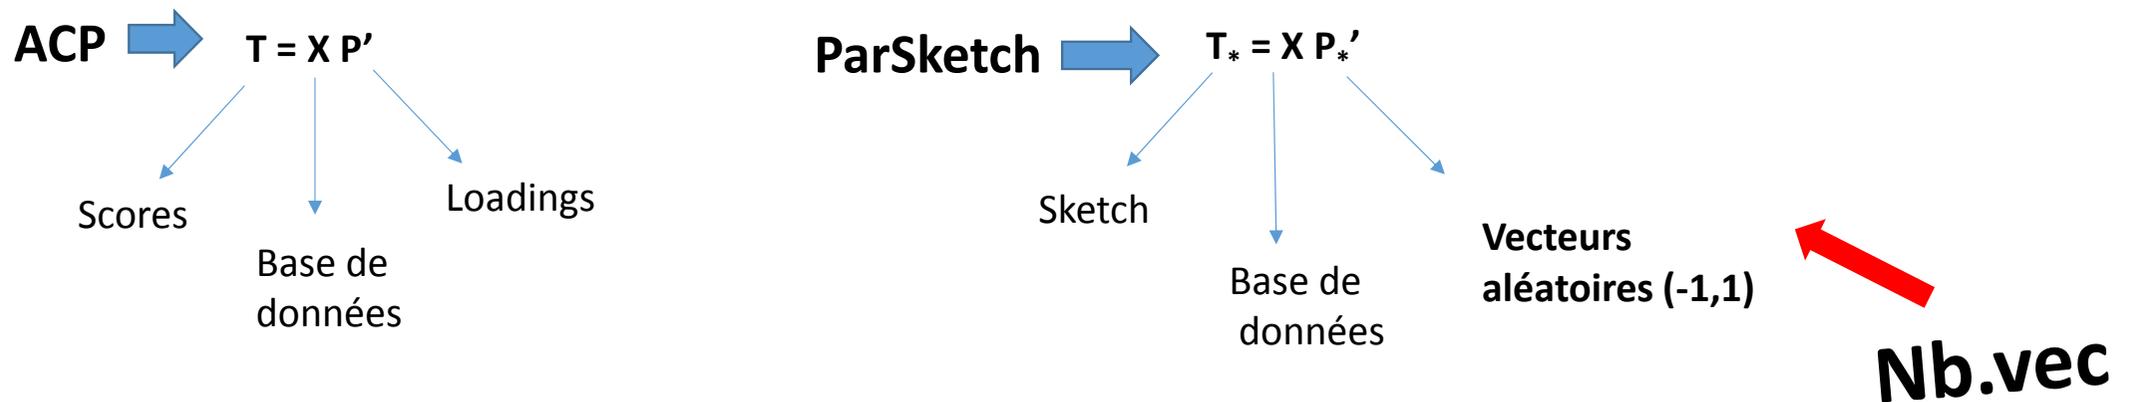


Un algorithme 'big-data' pour la Local-PLS  
**Intégration de ParSketch**

## ParSketch :



## Réduction de dimensions



### Pourquoi cette technique de réduction de dimensions ?

- Approche les distances euclidiennes
- Opération rapide
- Les variables obtenues représentent la même chose

 **Méthode « grid »**

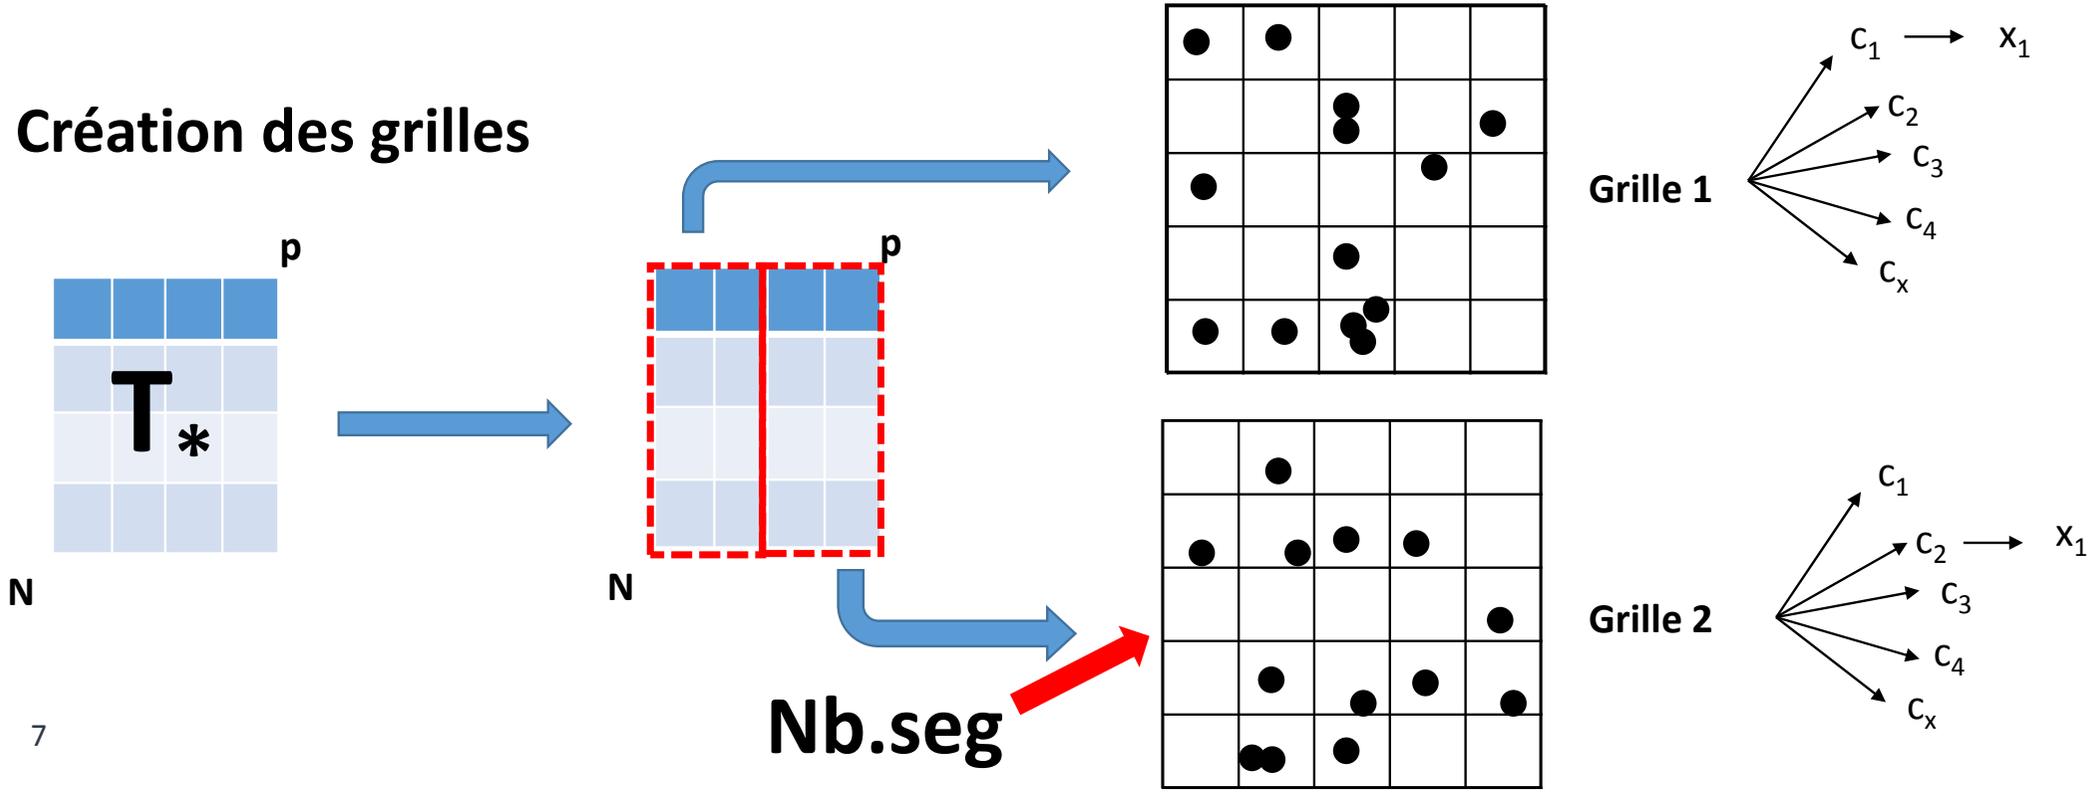
### ParSketch :



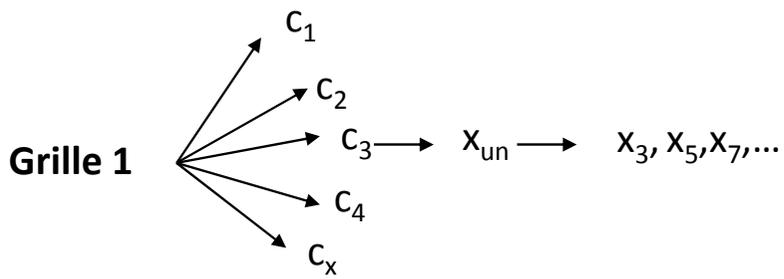
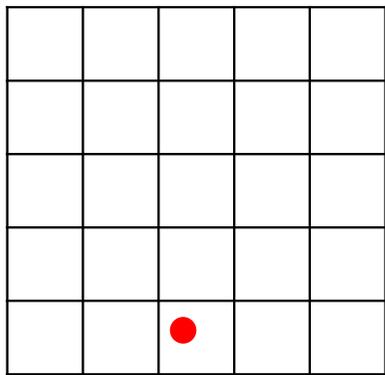
### Pourquoi créer des grilles ?

- Permet une recherche  $O(g)$  et pas  $O(n)$

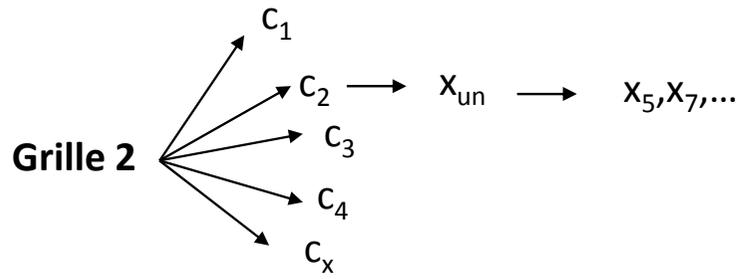
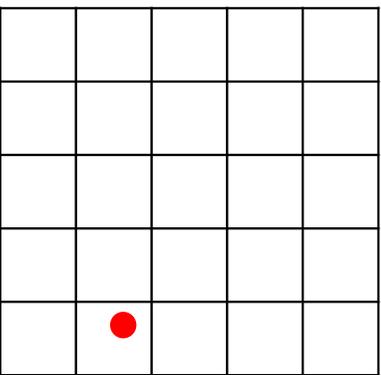
### Création des grilles



# ParSketch :



$x_3$	1
$x_5$	2
$x_7$	2



**Min.grid**

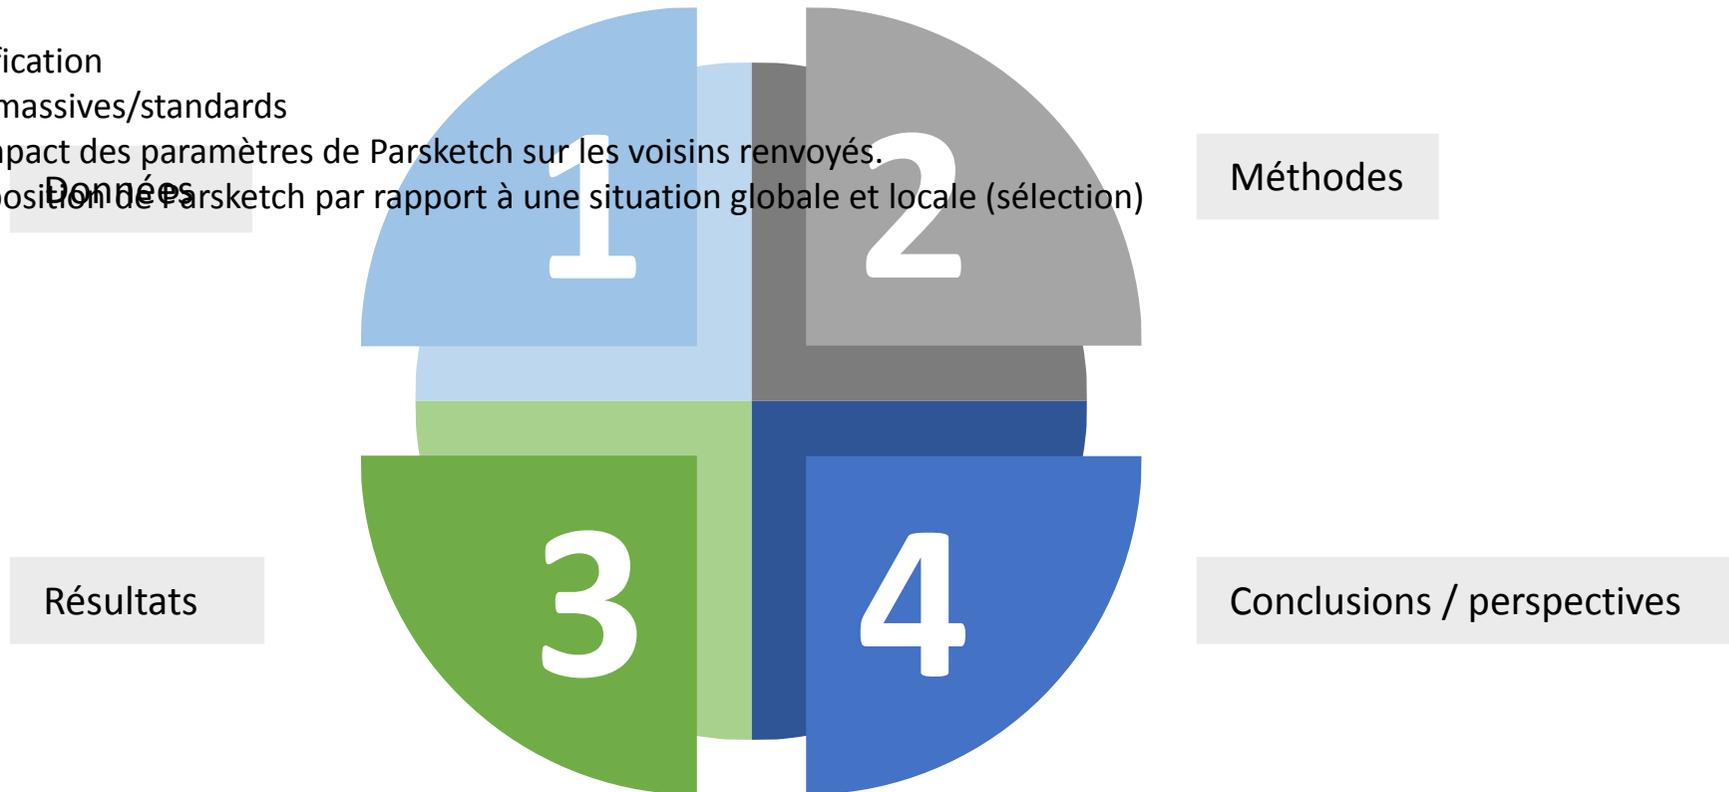
## Application :

Problème de classification

Interface données massives/standards

Observation de l'impact des paramètres de Parsketch sur les voisins renvoyés.

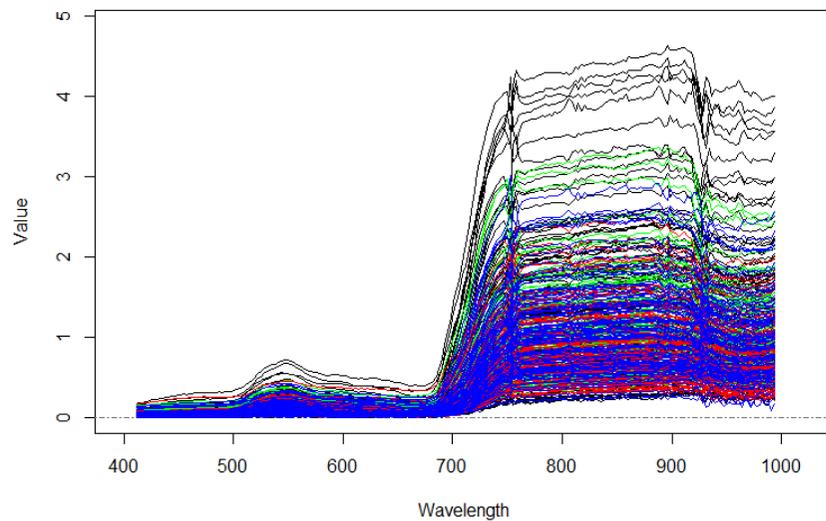
Observation de la position de Parsketch par rapport à une situation globale et locale (sélection)



# Un algorithme 'big-data' pour la Local-PLS Application

1

Données



- Spectres de feuilles
- 4 géotypes (4 images)
- 360 000 spectres
- 256 variables

## Objectifs

Discriminer les 4 classes (360 000 spectres/400 points tests)



# 2

Méthodes

## Les 3 stratégies utilisées :

**PLS-DA globale**

**Knn(Brut force) -PLS-DA**

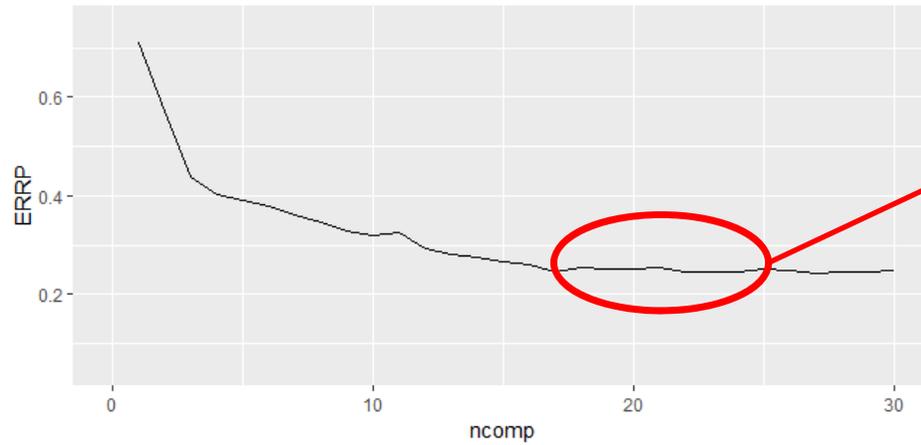
**ParSketch – PLS-DA**

# 3

## Résultats

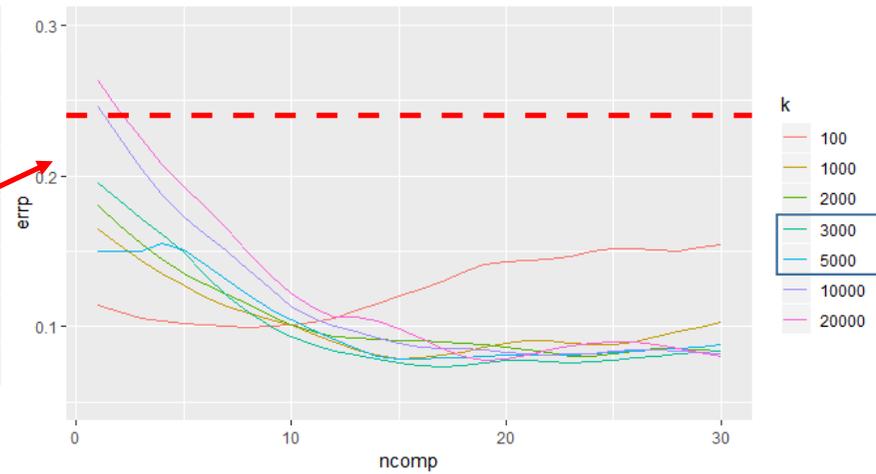
### Un algorithme 'big-data' pour la Local-PLS Application

PLS-DA :



**Meilleur résultat :**  
Err min : 24 %

Knn(Brut force) PLS-DA :



**Meilleur résultat :**

Err min : 6-7 %

Temps : ~4 h

**Observation :**

Temps de calcul longs / bonnes prédictions



# 3

Résultats

## ParSketch – PLS-DA :

### 3 paramètres :

**Nb.vec** : 10-100 vecteurs aléatoires

**Nb.seg** : 5-13 segments

**Min.grid**: 30-90 %

### 2 questions principales :

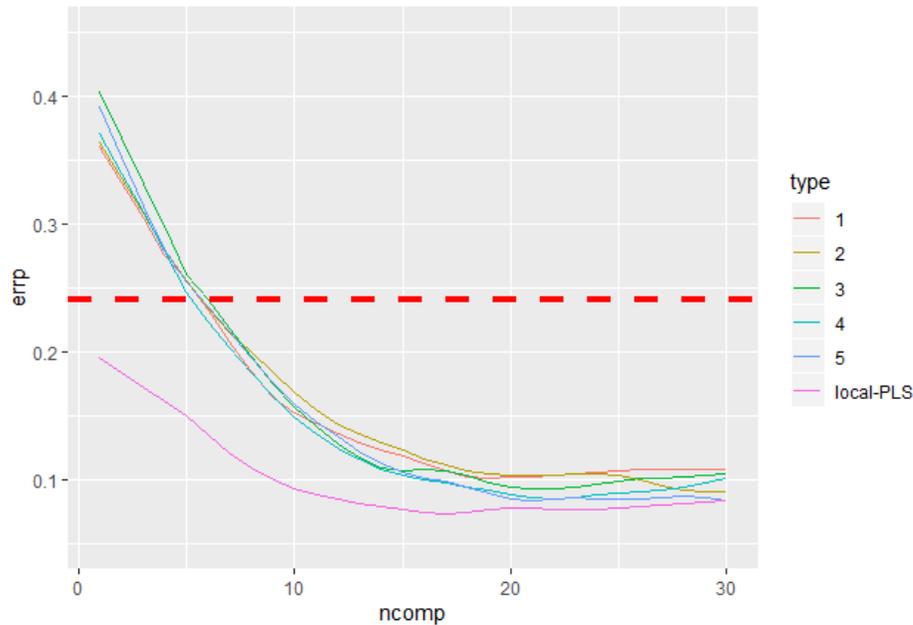
Quels sont les impacts des paramètres de ParSketch sur le voisinage renvoyé ?

Quels sont les impacts des paramètres de ParSketch sur l'erreur de prédiction ?

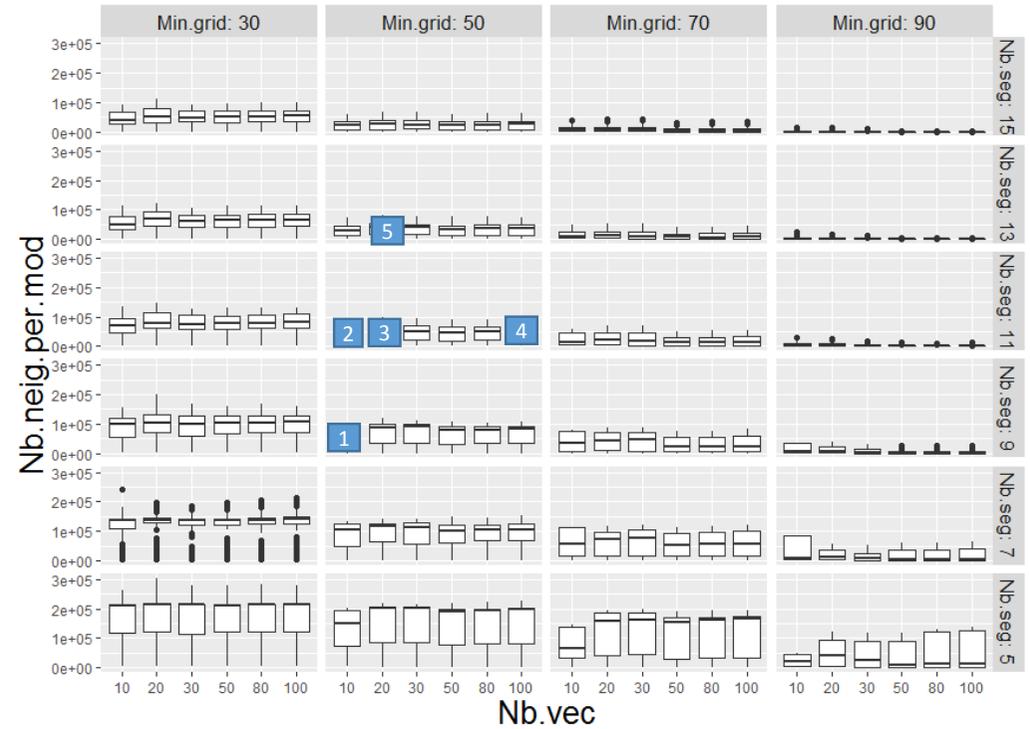
# 3

Quels sont les impacts des paramètres de sketch sur le voisinage renvoyé ?

Résultats



Un algorithme 'big-data' pour la Local-PLS  
**Etude de la méthode**



Quels sont les impacts des paramètres de sketch sur l'erreur de prédiction ?

# 4

## Conclusions / perspectives

### Conclusions

- ParSketch offre une alternative aux méthodes locales (avec sélection).
- ParSketch impose une métrique (distance euclidienne). Il est donc possible que Parsketch ne réponde pas à tous les problèmes.

### Perspectives

- ParSketch est utilisable dans n'importe quelle méthode utilisant des sous-ensembles
- Combiner Parsketch et une étape de pondération



**MERCI !!**



**Présenté par:** Maxime Metz  
**Supervisé par:** Matthieu Lesnoff,  
Jean-Michel Roger

