

# Présentation scientifique

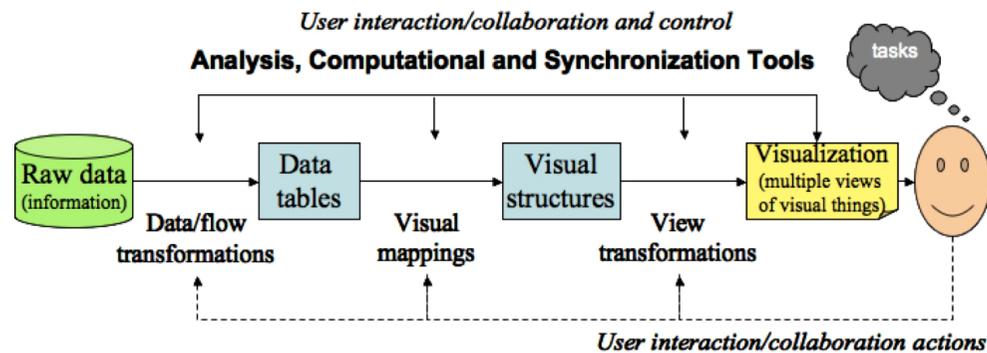
EVADoMe

Romain Bourqui

# EVADoMe : Axes de recherche

## Axes de recherche :

- Fouille de données
- Représentation de données
- Exploration interactive



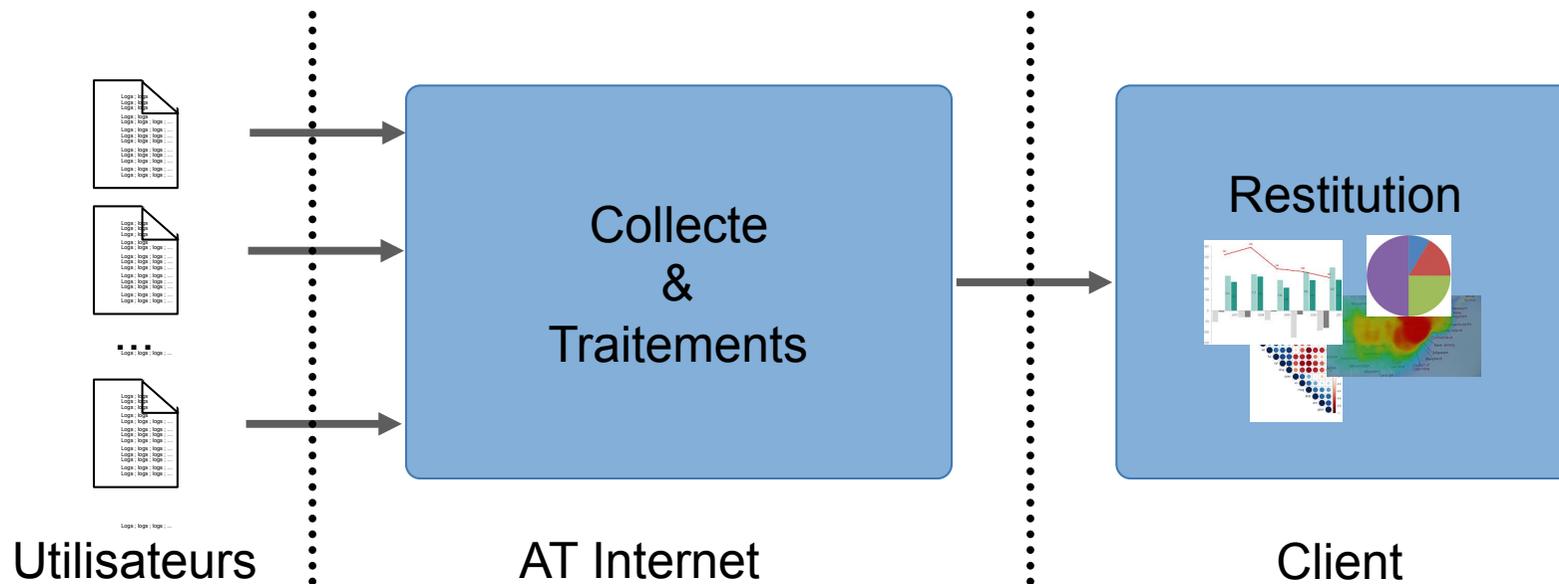
# EVADoMe : Illustration de travaux

## Contexte :

Projet : PIA « Cloud Computing » SpeedData

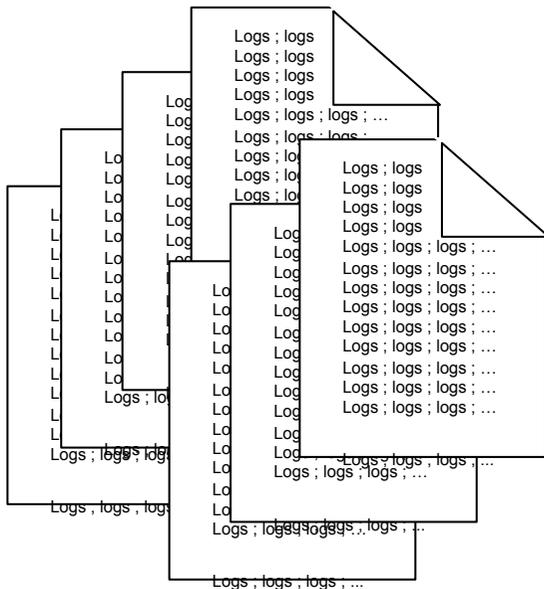
Entreprise partenaire : AT Internet

Domaine d'activité : *web analytics*

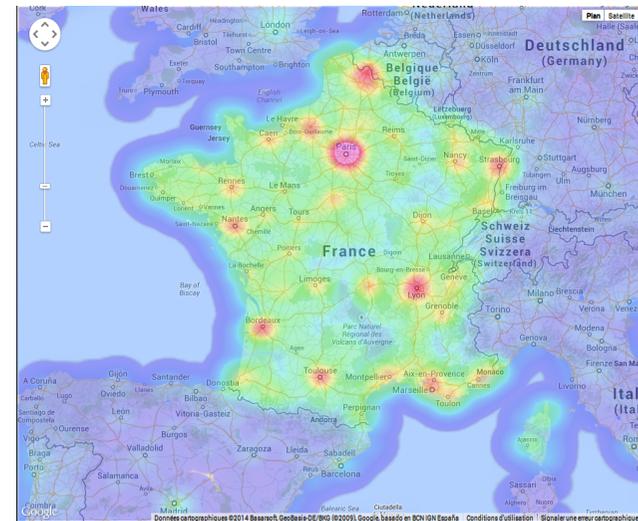


# EVADoMe : Illustration de travaux

Application :  
Visualisation de Données Géolocalisées



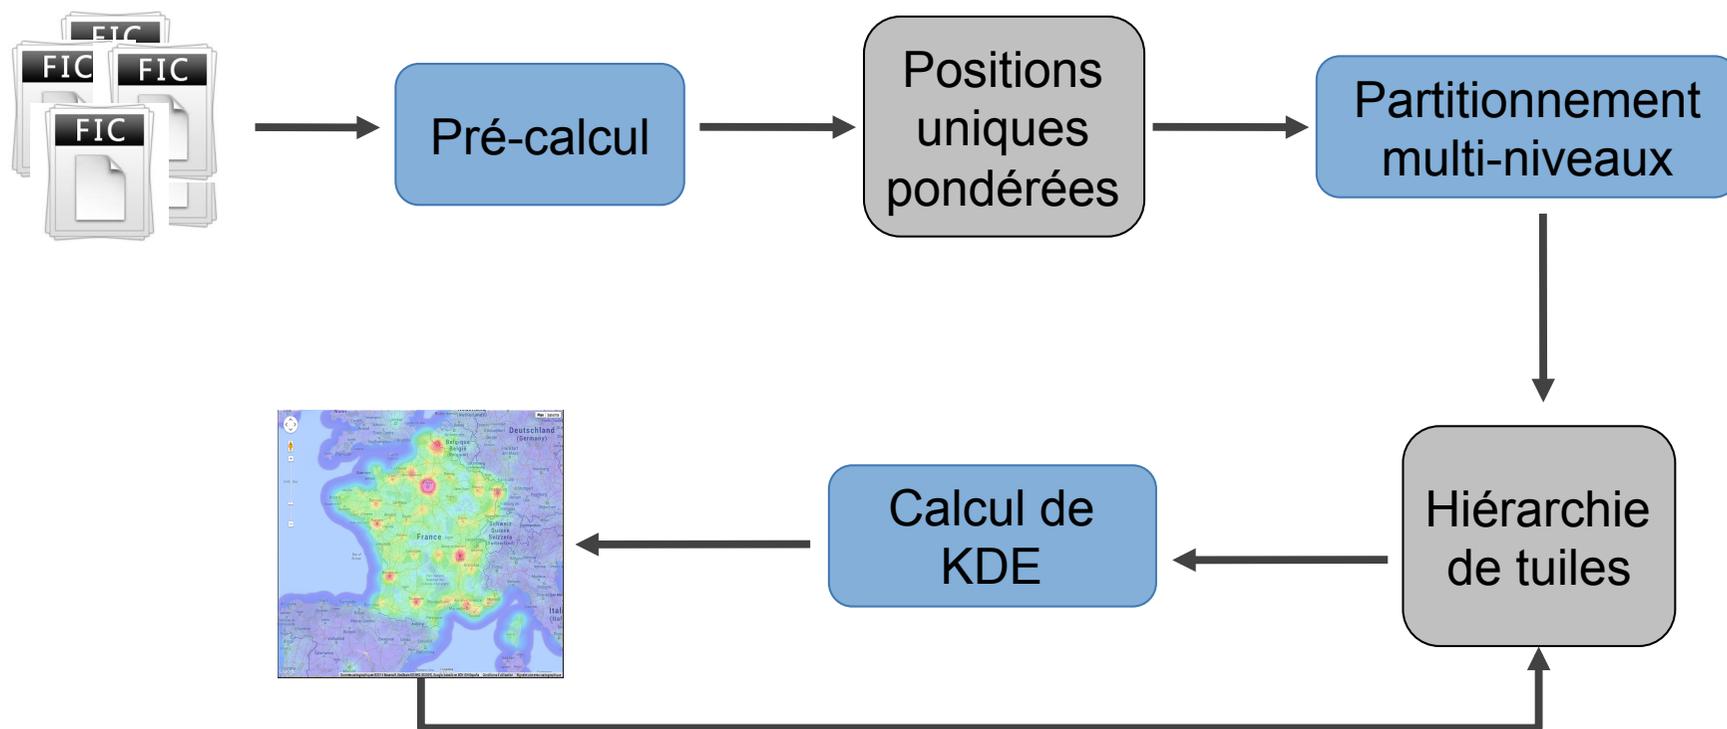
Millions/milliards de logs  
utilisateurs géolocalisés



Carte de chaleur interactive

# EVADoMe : Illustration de travaux

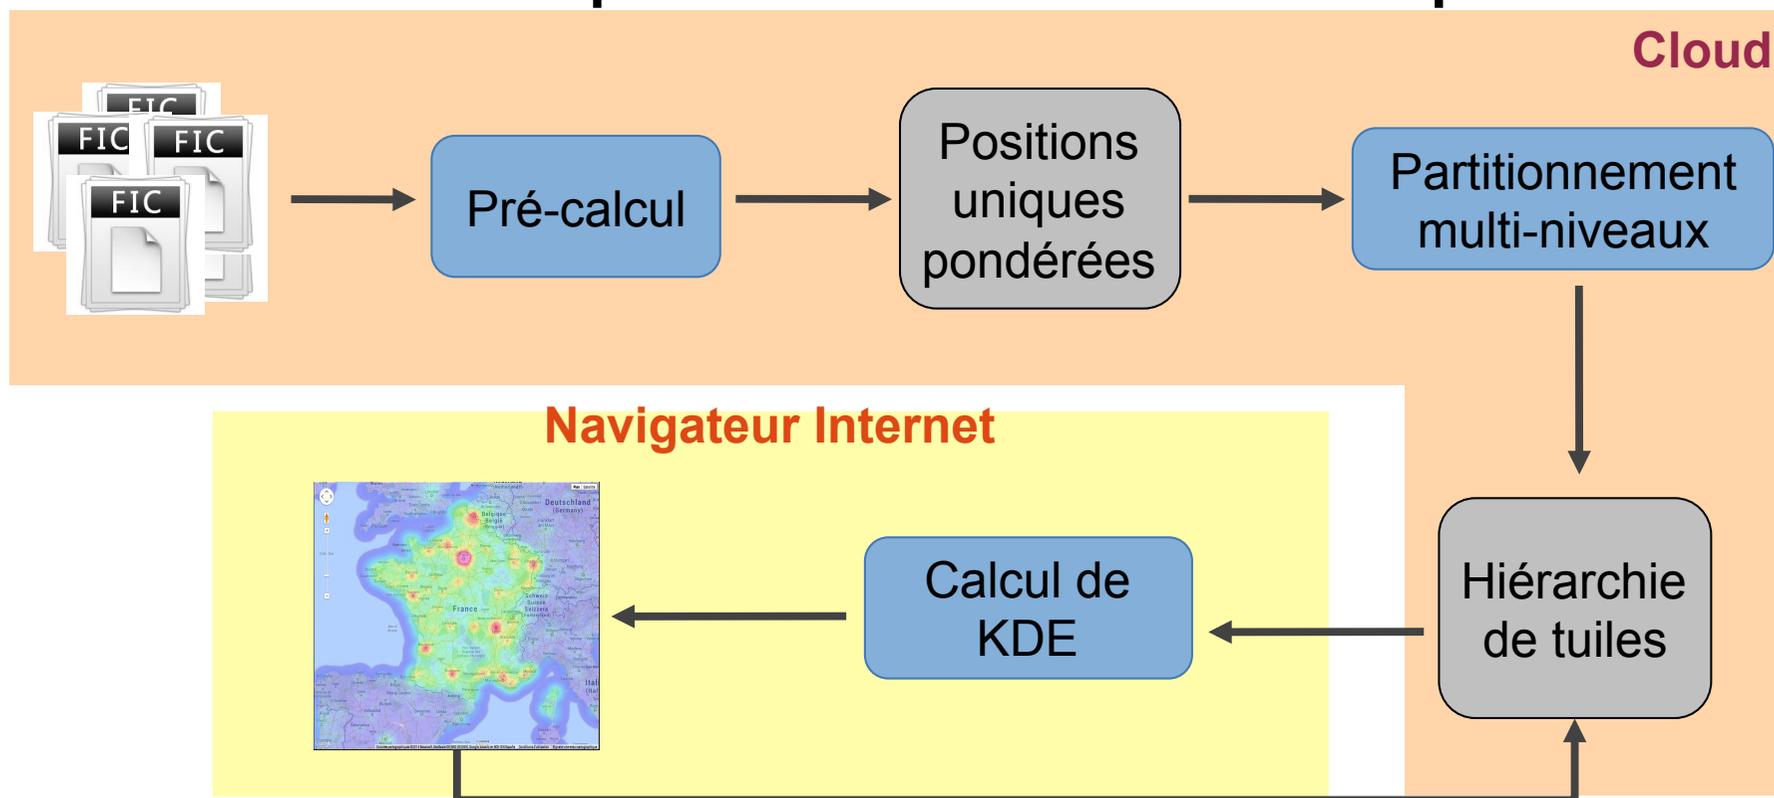
**Contribution :**  
**Infrastructure et processus de traitement complet**



Interaction utilisateur

# EVADoMe : Illustration de travaux

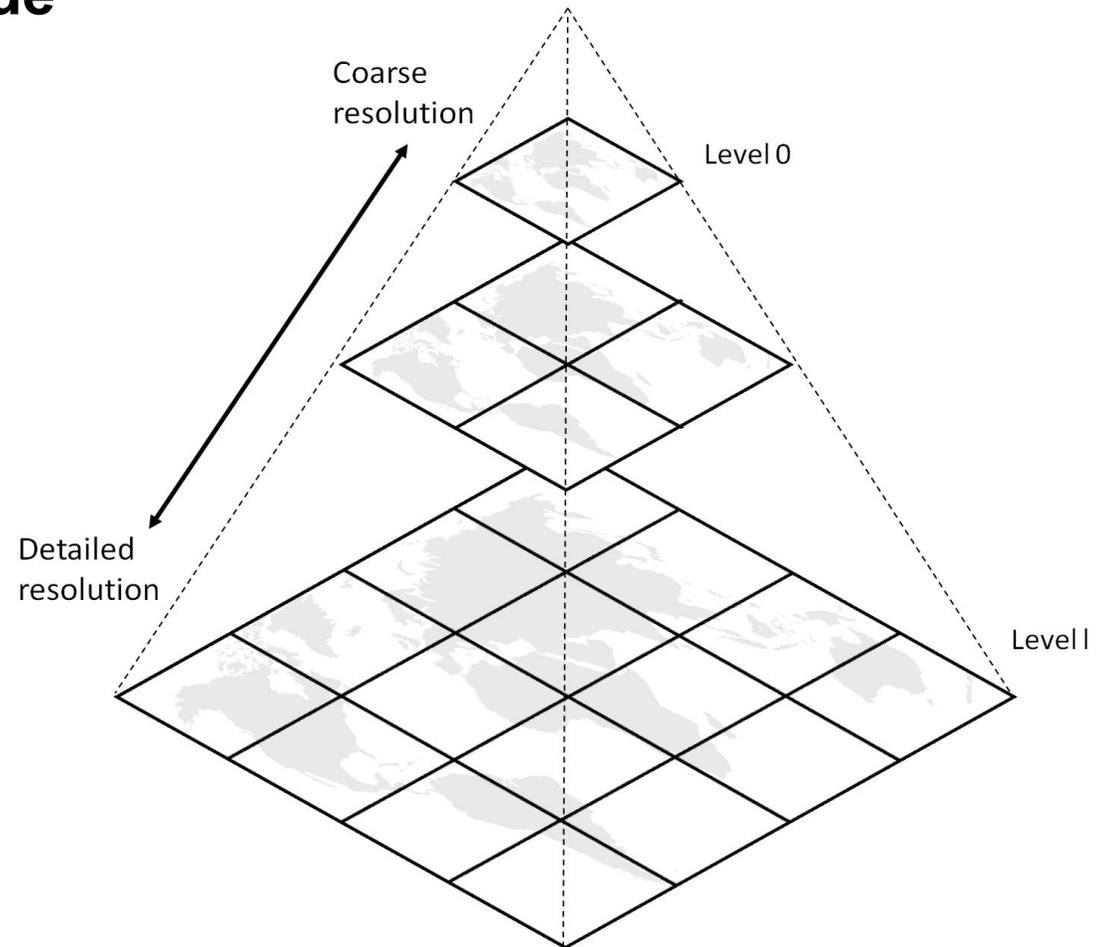
**Contribution :**  
**Infrastructure et processus de traitement complet**



# EVADoMe : Illustration de travaux

## Principe de la méthode

Utilisation d'une hiérarchie de tuiles montrant les données avec plus ou moins de précision

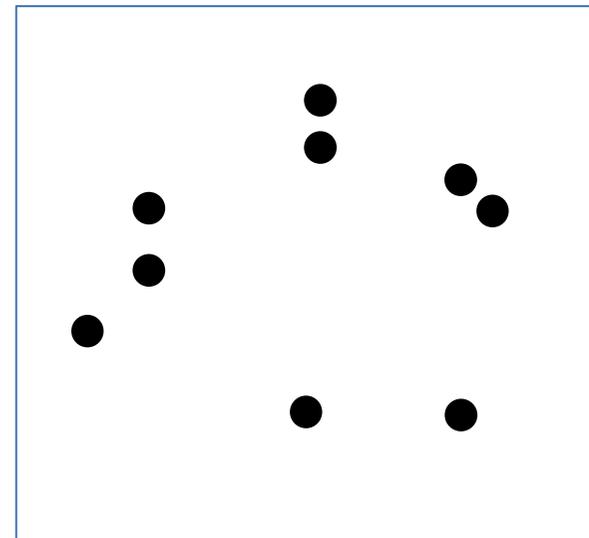


# EVADoMe : Illustration de travaux

## Algorithmes « *canopy* » : Principe

Partant d'un ensemble de points et une distance  $d$  élire un certain nombre de représentants tels que :

- tout point est à distance au plus  $d$  d'un représentant
- tout représentant soit à distance au moins  $d$  des autres représentants

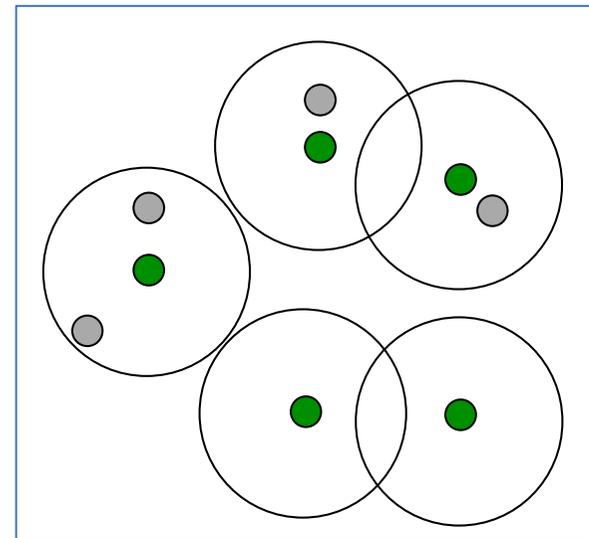


# EVADoMe : Illustration de travaux

## Algorithmes « *canopy* » : Principe

Partant d'un ensemble de points et une distance  $d$  élire un certain nombre de représentants tels que :

- tout point est à distance au plus  $d$  d'un représentant
- tout représentant soit à distance au moins  $d$  des autres représentants

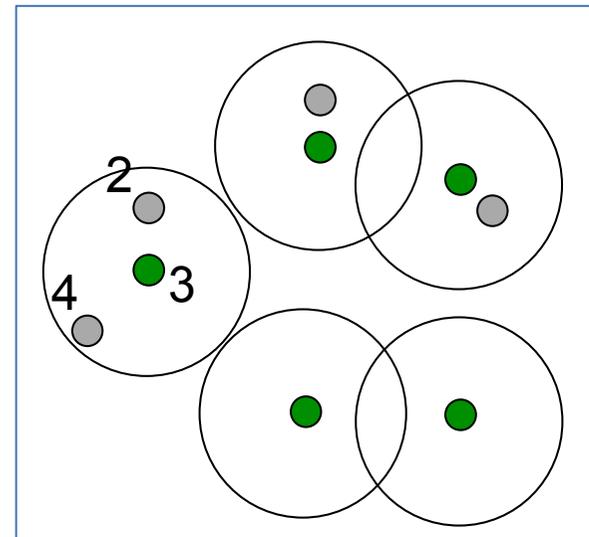


# EVADoMe : Illustration de travaux

## Algorithmes « *canopy* » : Principe

Partant d'un ensemble de points et une distance  $d$  élire un certain nombre de représentants tels que :

- tout point est à distance au plus  $d$  d'un représentant
- tout représentant soit à distance au moins  $d$  des autres représentants

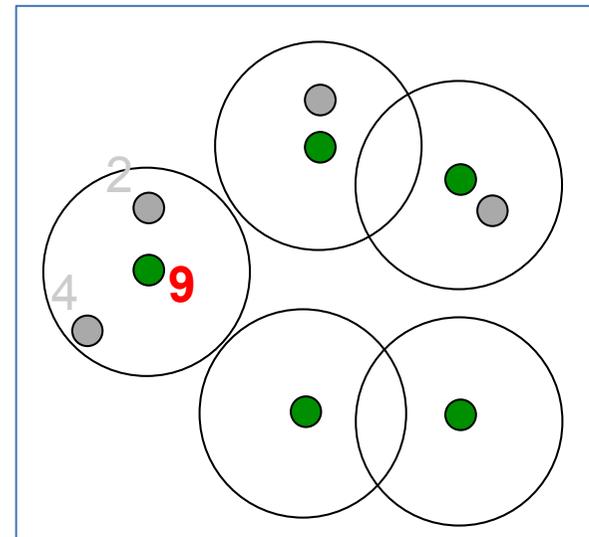


# EVADoMe : Illustration de travaux

## Algorithmes « *canopy* » : Principe

Partant d'un ensemble de points et une distance  $d$  élire un certain nombre de représentants tels que :

- tout point est à distance au plus  $d$  d'un représentant
- tout représentant soit à distance au moins  $d$  des autres représentants

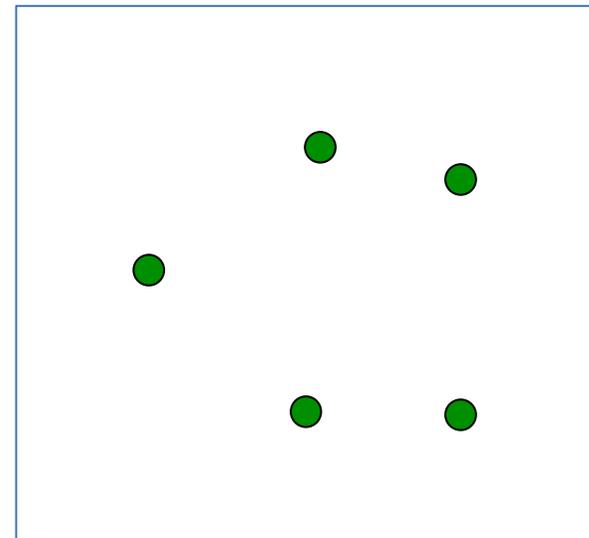


# EVADoMe : Illustration de travaux

## Algorithmes « *canopy* » : Partitionnement multi-niveaux

Appliquer itérativement l'algorithme canopy en :

- considérant les représentants du niveau précédent
- augmentant la distance  $d$



# EVADoMe : Illustration de travaux

## Principe des algorithmes « *canopy* » : Sur le cloud ?

Utilisation de 2 passes Map/Reduce

1ère passe :

- Division en bandes de l'espace (une bande par tâche)
- Calcul des représentants dans chaque bande

2ème passe :

- Gestion des conflits sur le « bord » des bandes

# EVADoMe : Illustration de travaux

Principe des algorithmes « *canopy* » :  
*Résultat*

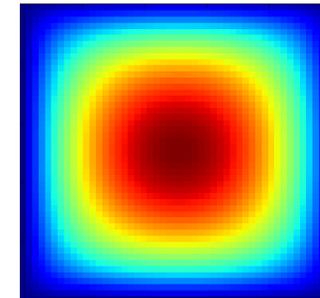
- Partitionnement multi-niveaux
- À chaque point est associé les poids qu'il représente
- Garantie sur le nombre maximum de points par tuile

# EVADoMe : Illustration de travaux

## Estimation de densité de noyaux (*KDE*) : Principe

Considérant un ensemble de  $n$  points et une image de  $p$  pixels

- Calculer pour chaque pixel l'apport de chaque point (fonction de la distance / la pondération)
- Utiliser un noyau (généralement) gaussien
- Complexité en  $O(n*p)$



# EVADoMe : Illustration de travaux

**Estimation de densité de noyaux (*KDE*) :  
Heuristique en temps constant**

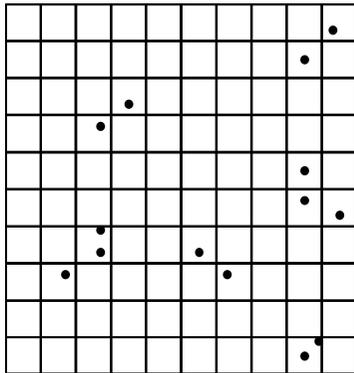
**Principe :**

Utiliser une implémentation sur la carte graphique et un découpage en tâches

- Chaque tâche calcule le KDE sur un sous ensemble de points et sur une image de résolution réduite
- Agrégation des images produites en une seule
- « Étirement » de l'image pour obtenir la résolution initiale

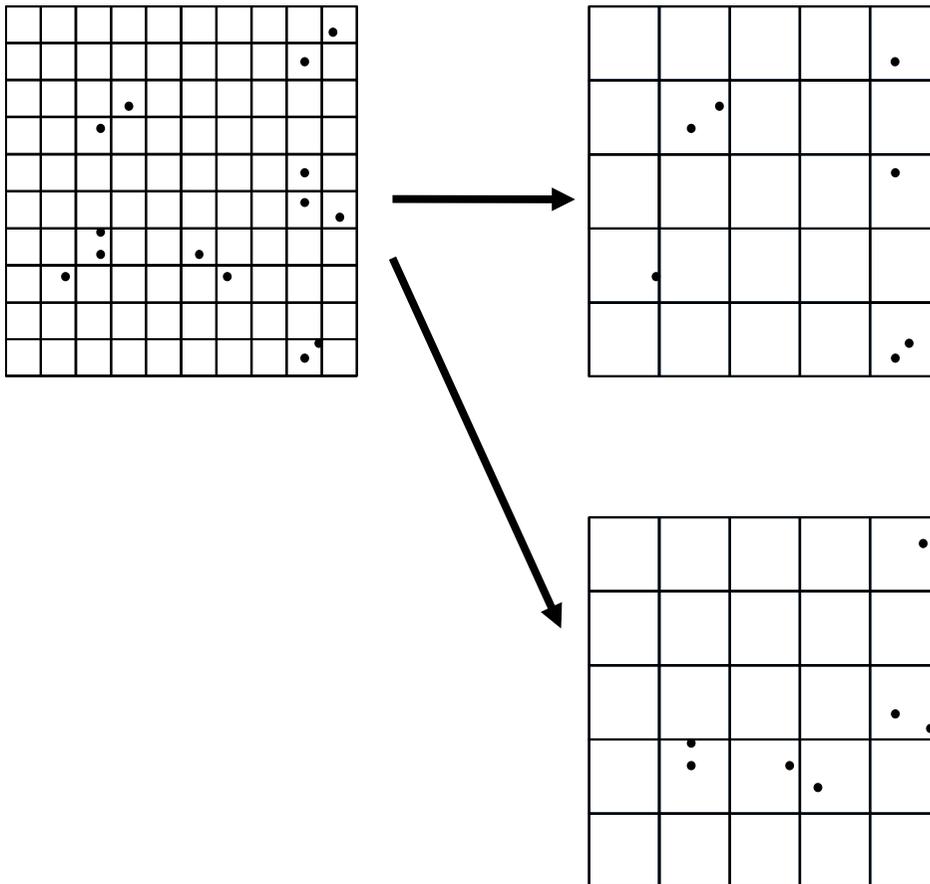
# EVADoMe : Illustration de travaux

Estimation de densité de noyaux (*KDE*) :  
Heuristique en temps constant



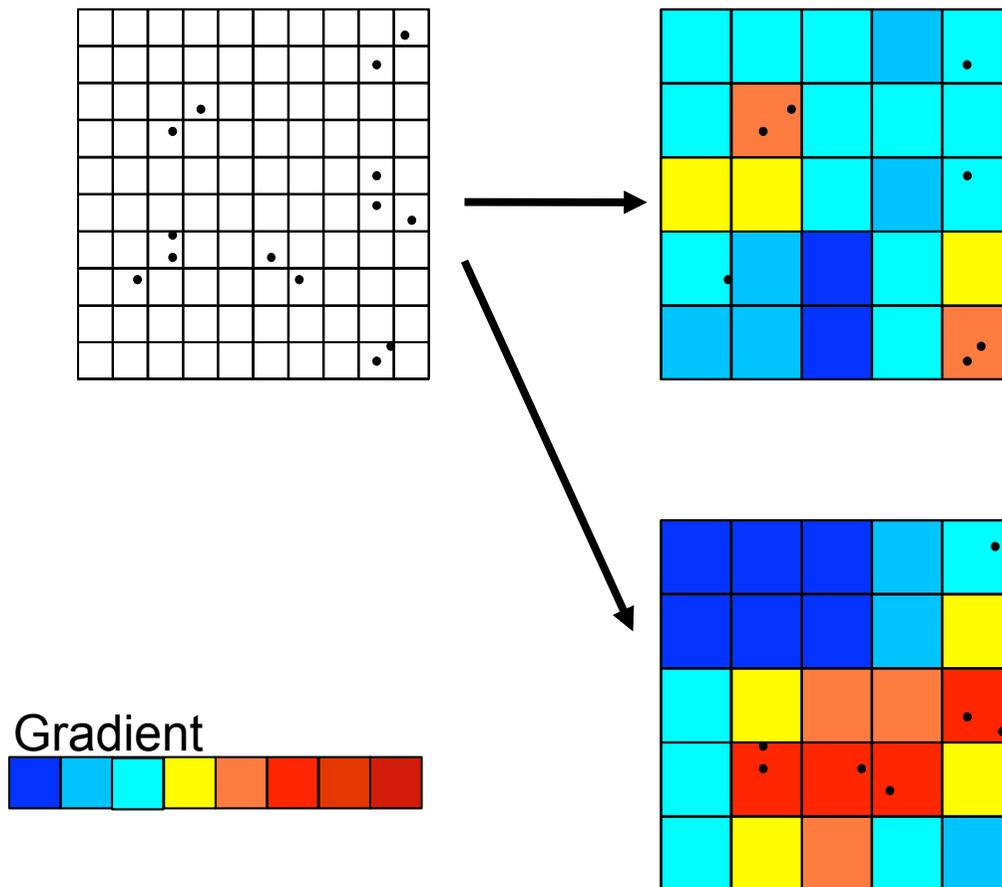
# EVADoMe : Illustration de travaux

Estimation de densité de noyaux (*KDE*) :  
Heuristique en temps constant



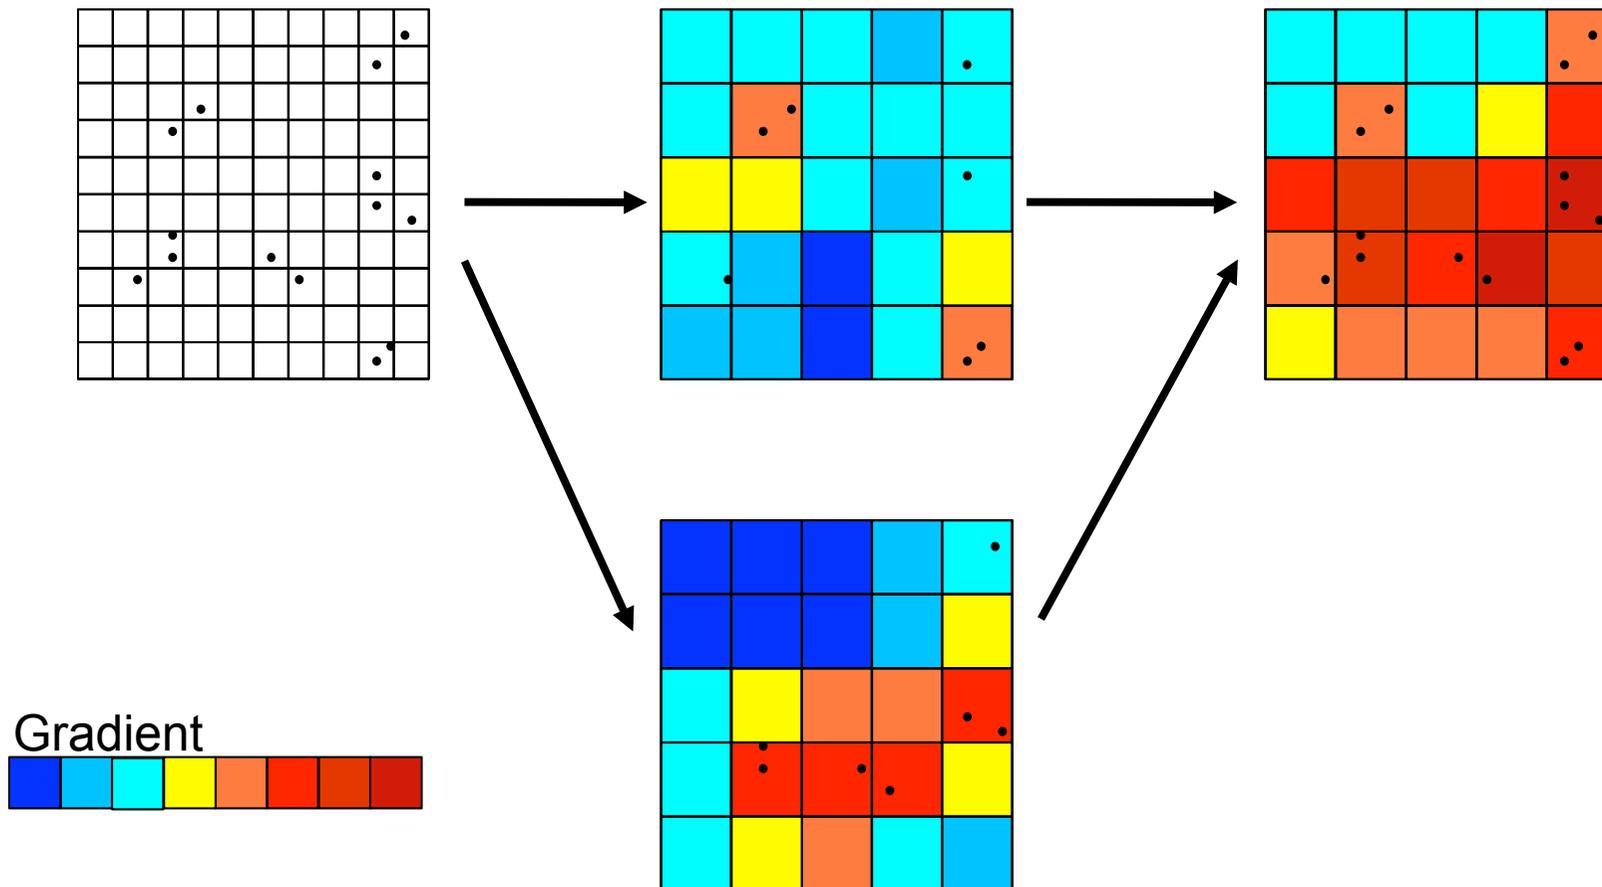
# EVADoMe : Illustration de travaux

Estimation de densité de noyaux (*KDE*) :  
Heuristique en temps constant



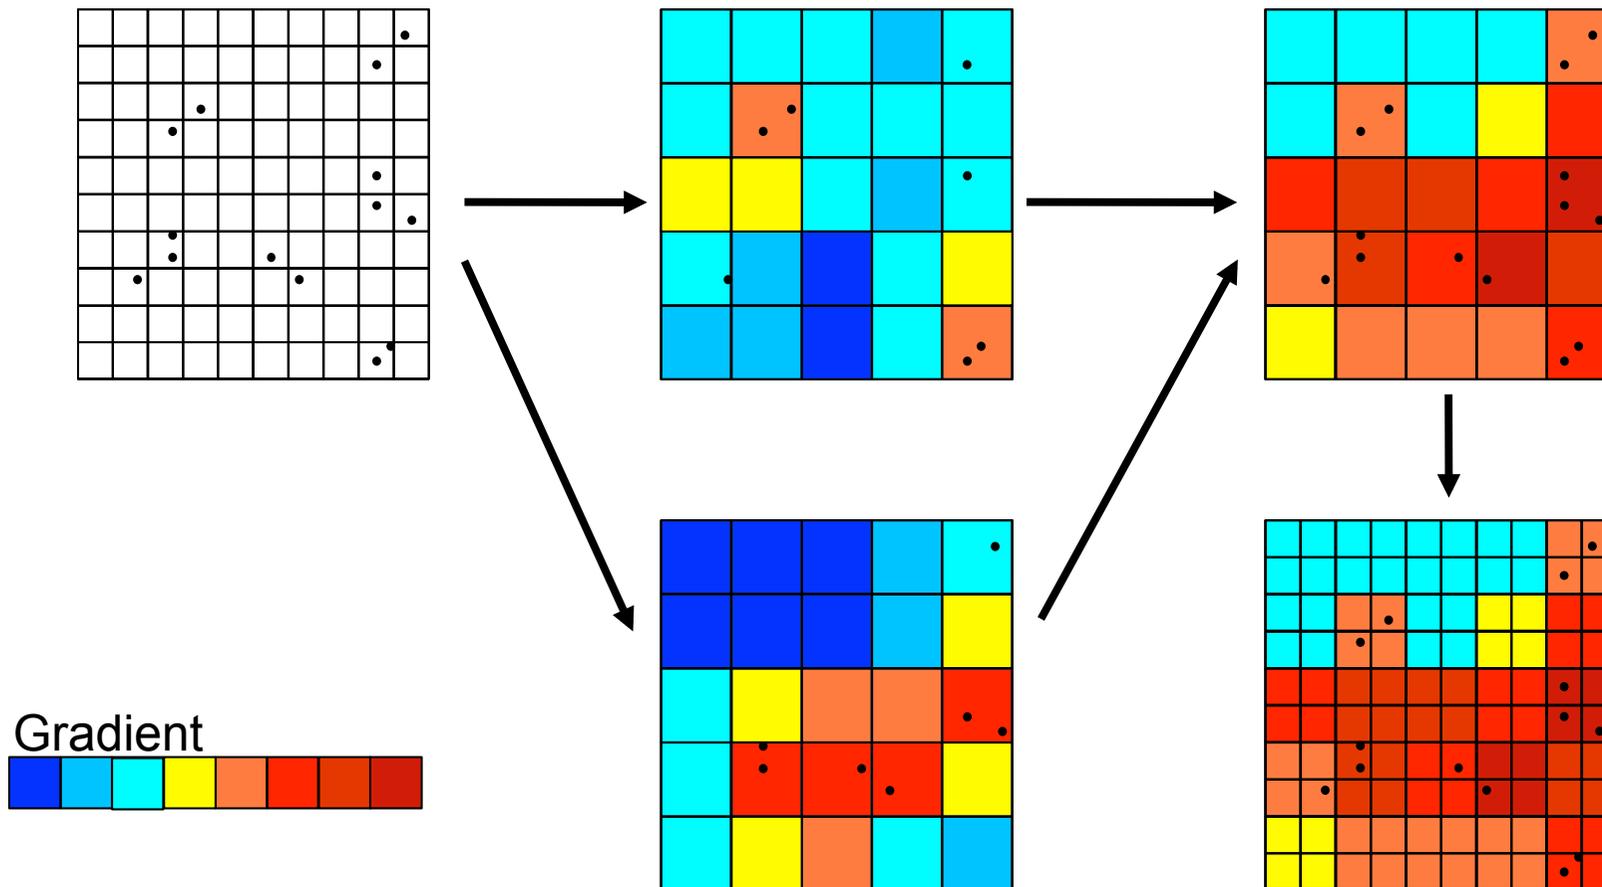
# EVADoMe : Illustration de travaux

Estimation de densité de noyaux (*KDE*) :  
Heuristique en temps constant



# EVADoMe : Illustration de travaux

Estimation de densité de noyaux (*KDE*) :  
Heuristique en temps constant



# EVADoMe : Illustration de travaux

## Estimation de densité de noyaux (*KDE*) : Heuristique en temps constant

### Principe :

Utiliser une implémentation sur la carte graphique et un découpage en tâches

- Chaque tâche calcule le KDE sur un sous ensemble de points et sur une image de résolution réduite
- Agrégation des images produites en une seule
- « Étirement » de l'image pour obtenir la résolution initiale

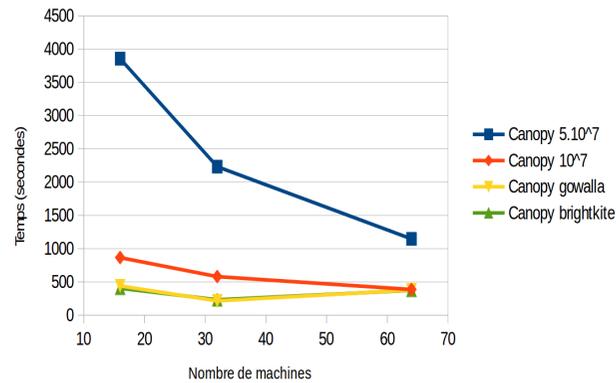
En temps constant (borné par une constante) mais cette constante dépend du nombre de pixels (fixe) et de la carte graphique

# EVADoMe : Illustration de travaux

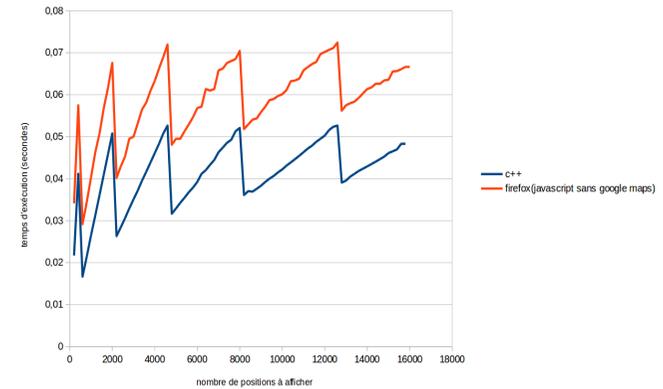
## Évaluation

Temps de calcul

### Partitionnement



### Rendu (KDE)



Qualité

