

---

# Repérage de zones défavorisées

## Comparaison de méthodes

Jean-Michel Floch

**Insee-DG**

**Département de l'action régionale**

**[jean-michel.floch@insee.fr](mailto:jean-michel.floch@insee.fr)**

# Les données spatialisées

---

- Depuis le travail de synthèse de Cressie (1993), on distingue trois types de données spatialisées:
  - Géostatistiques
  - Surfaciennes
  - Ponctuelles
- Des méthodes spécifiques ont été développées dans chaque domaine
  - ex : Variographie, krigeage dans le cas de la géostatistique

# Pour un même problème pratique...

---

- Plusieurs méthodes peuvent se retrouver en concurrence
- Laissons de côté les cas où l'on fait rentrer de force les données dans une modélisation non adaptée (quelques utilisations limite du krigeage en sciences sociales..)
- Cela peut provenir des données (valeurs brutes/taux..) ,du maillage territorial

# Quelques questions

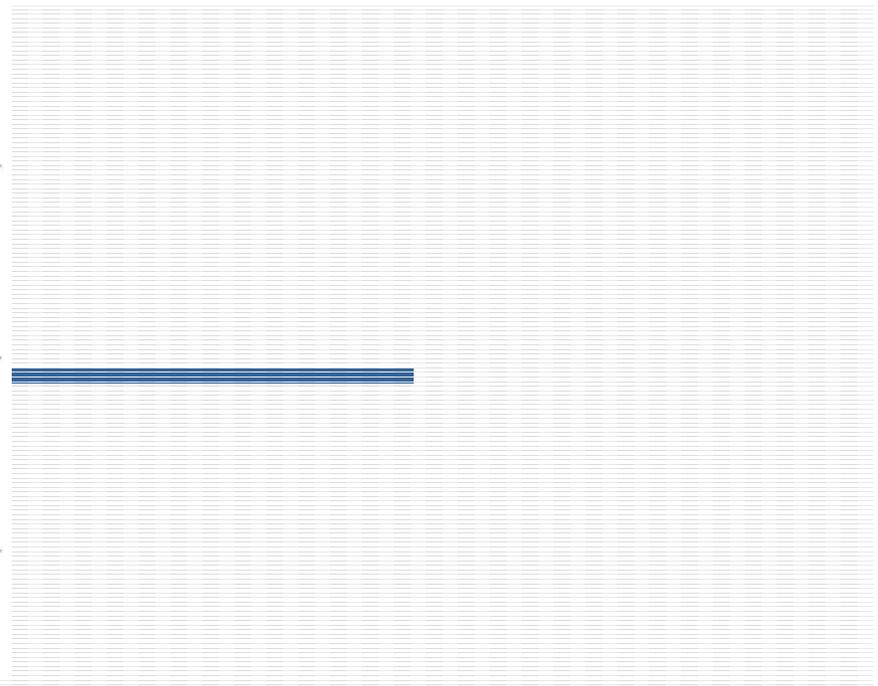
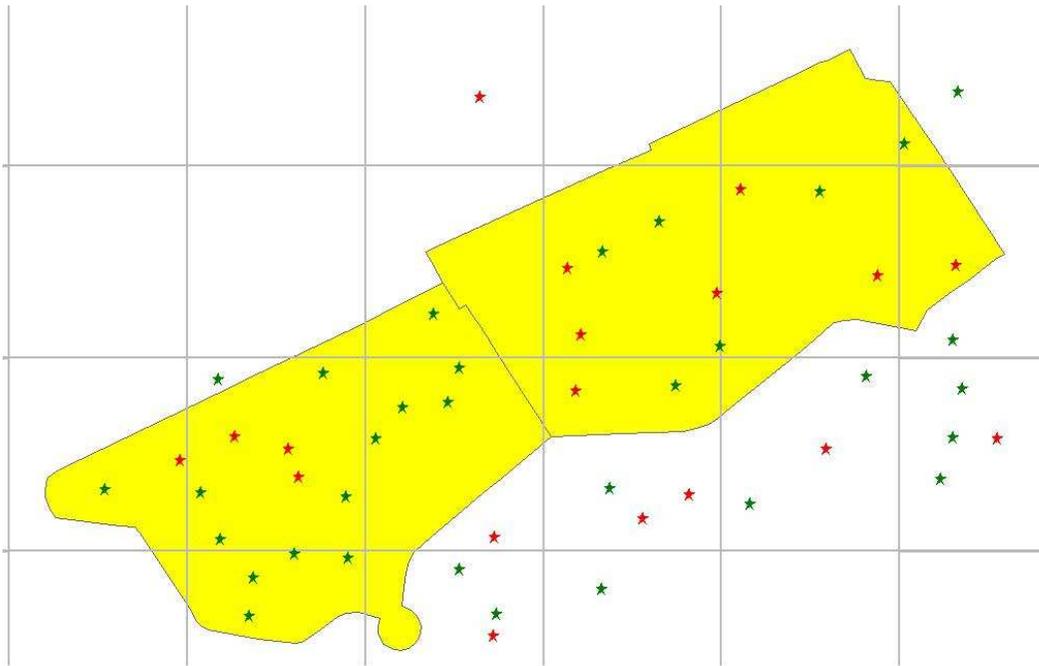
---

- A information initiale identique, comment départager les méthodes
- Lorsque l'on fait « avec ce que l'on a » ( comme données, les données pouvant conditionner l'éventail des méthodes possibles), est-ce qu'on obtient des résultats acceptables?

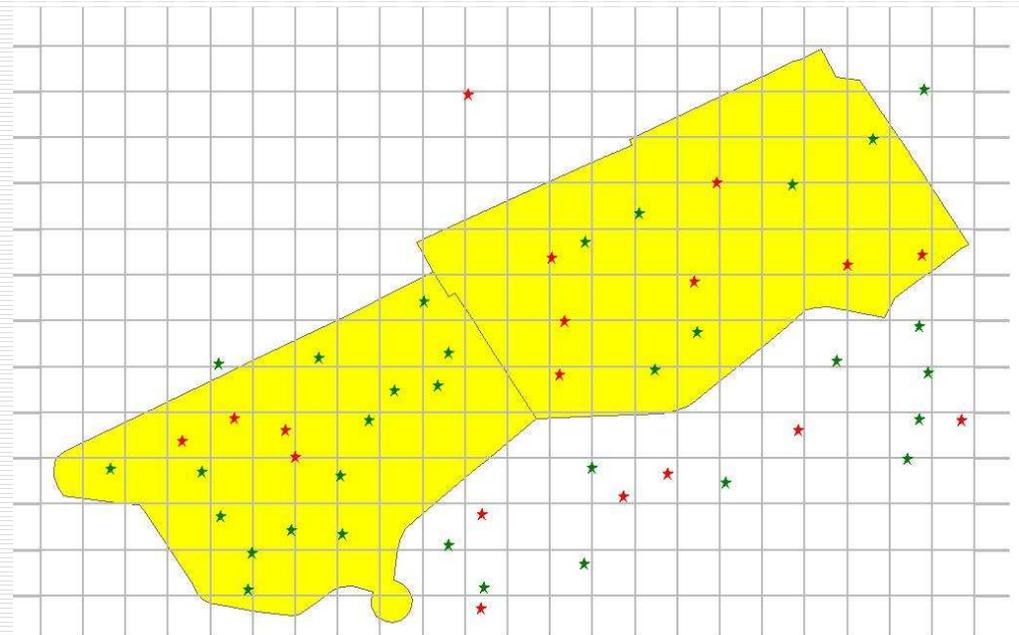
## Un exemple : l'étude de la localisation des bas ( ou hauts ) revenus

Info.

- On dispose pour chaque ménage de variables indicatrices indiquant que le revenu/UC est inférieur ou supérieur à un certain seuil, ainsi que de la localisation géographique (x,y). C'est l'information la plus complète que l'on puisse avoir
- On peut avoir des comptages sur un carroyage
- On peut enfin avoir des taux sur des découpages administratifs

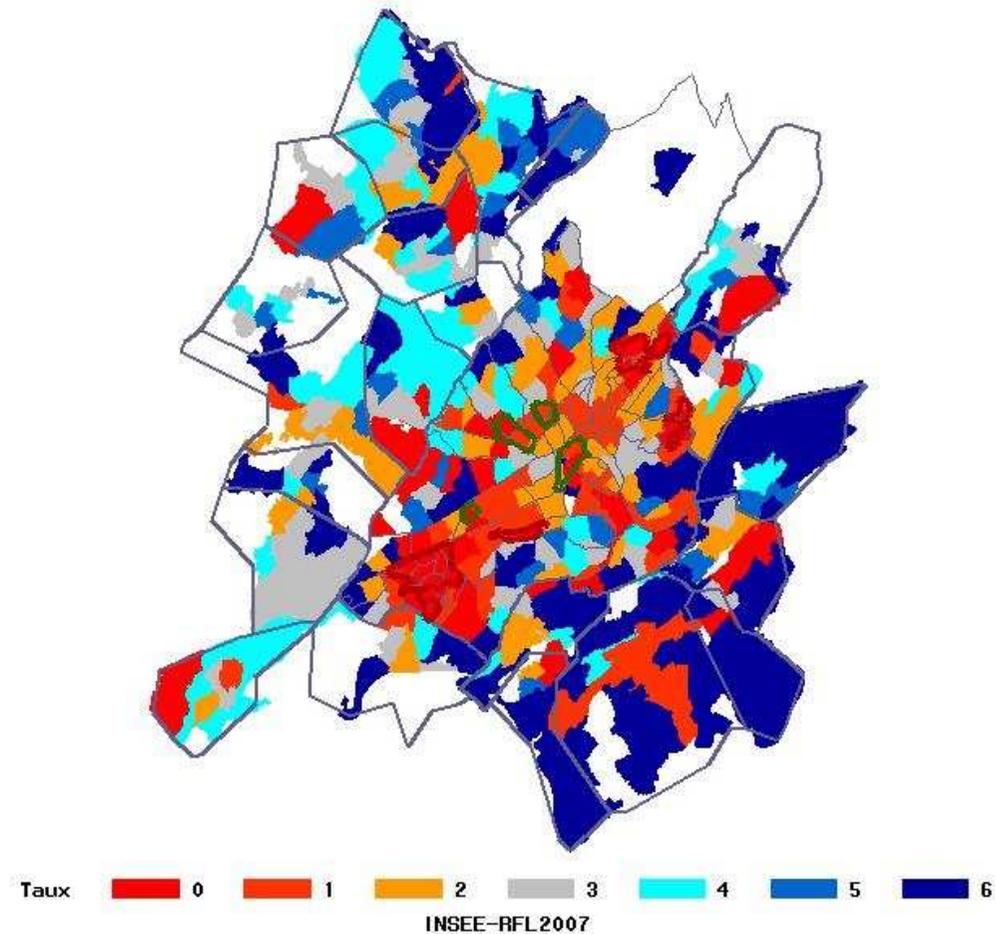


La réduction de la maille  
fait qu'on se « rapproche »  
des données individuelles



# La situation étudiée

Taux de bas revenus par section cadastrale  
Besançon



# Les méthodes étudiées pour résoudre ce problème

---

- Les LISA (Surfacique)
- Ratios de densité estimée (Ponctuel)
- Indicateurs « M » de Marcon et Puech (Ponctuel)

# Les LISA

(Local indicators of spatial association  
L.Anselin Geographical analysis 1995)

# Le I de Moran : mesure globale de l'autocorrélation

$$I = \frac{1}{s^2} \frac{\sum_1^N \sum_1^N w_{ij} (z_i - \bar{z})(z_j - \bar{z})}{\sum_1^N \sum_1^N w_{ij}}$$

$$S_0 = \sum_{i=1}^N \sum_{j=1}^N w_{ij}$$

$$S_1 = \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N (w_{ij} + w_{ji})^2$$

$$S_2 = \sum_{i=1}^N (w_{i.} + w_{.i})^2$$

$$E(I) = \frac{-1}{N-1}$$

$$V(I) = \frac{N^2 S_1 - N S_2 + 3 S_0^2}{(N-1)(N+1) S_0^2} - \left( \frac{1}{N-1} \right)^2$$

$$\frac{I - E(I)}{\sqrt{V(I)}} \approx N(0,1)$$

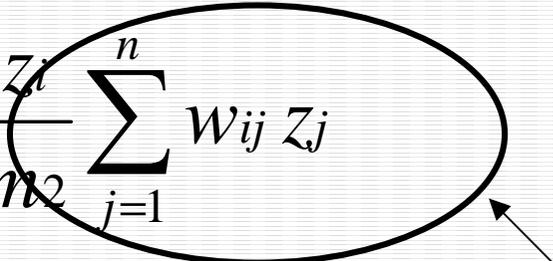
# Global et local

---

- S'il n'y avait pas d'autocorrélation, on n'étudierait pas le territoire
- D'où l'intérêt de mesures qui montrent d'où vient cette autocorrélation : développement des LISA et mise en évidence de points chauds ( hot spots)

# La version « Lisa » du I de Moran

- Les Lisa ont deux propriétés.
- -ils traduisent l'importance de la propension à former des grappes autour d'une zone considérée
- -leur somme est proportionnelle à un indicateur global d'association spatiale.

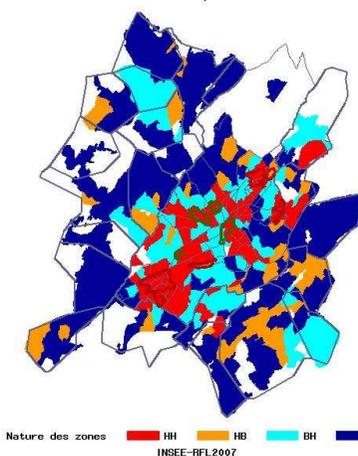
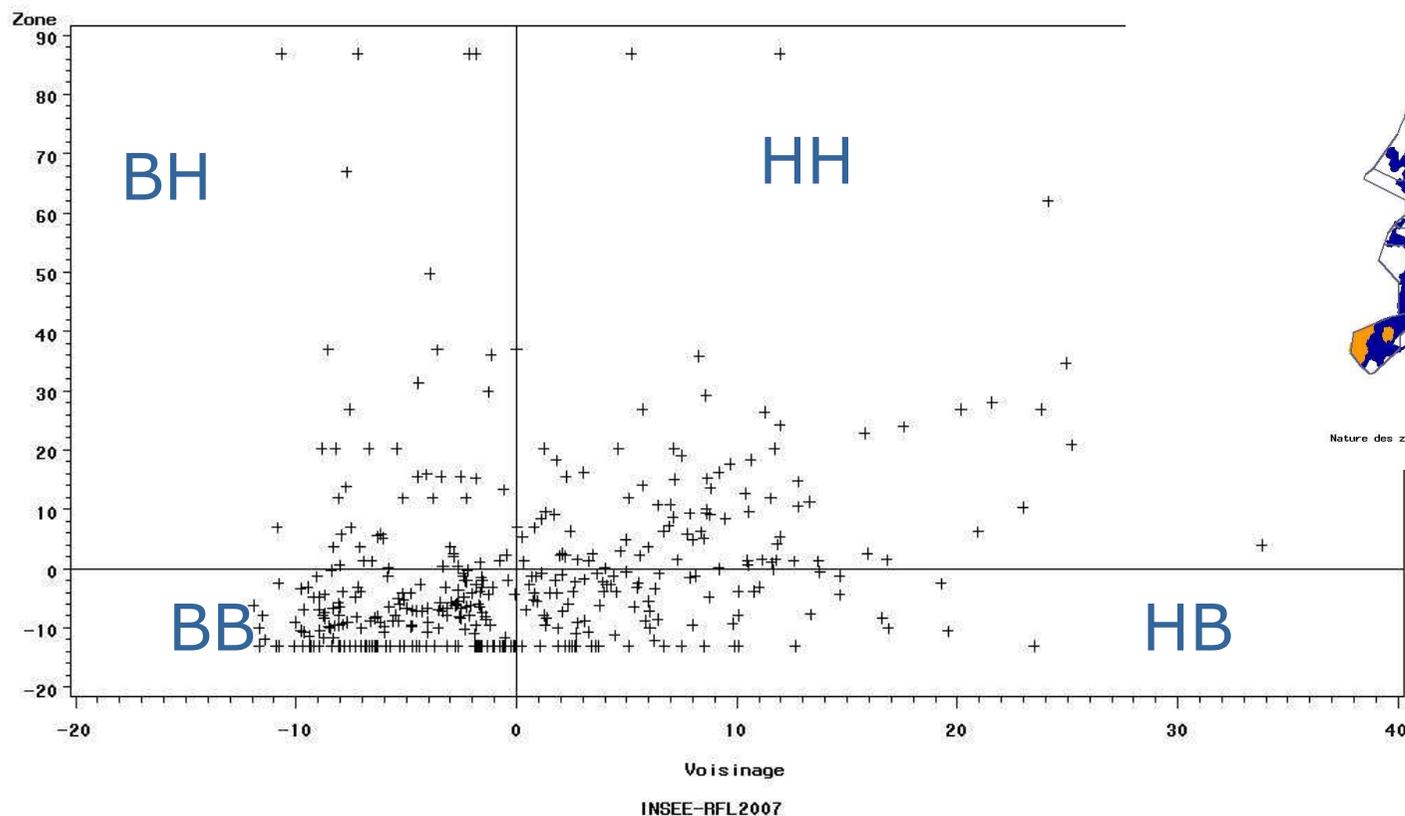
$$I_i = \frac{z_i}{m_2} \sum_{j=1}^n w_{ij} z_j$$
$$\sum_{i=1}^n I_i = \frac{1}{m_2} \sum_{i=1}^n \sum_{j=1}^n w_{ij} z_i z_j = \frac{1}{S_0} I$$


Valeur observée dans le voisinage

# Graphique de Moran et partition de la population (HH, BB, HB, BH)

Diagramme de MORAN

Indicateur de MORAN : Caractérisation des zones  
Besançon



# Des tests

- Mise en évidence des zones qui se détachent significativement des autres

$$E(I_i) = \frac{\sum_{j=1}^n w_{ij}}{n-1}$$

$$\text{Var}(I_i) = \frac{w_{i(2)}(n-b_2)}{(n-1)} + \frac{2w_{i(kh)}(2b_2-n)}{(n-1)(n-2)} - E(I_i)^2$$

$$Z(I_i) = \frac{I_i - E(I_i)}{\sqrt{\text{Var}(I_i)}}$$

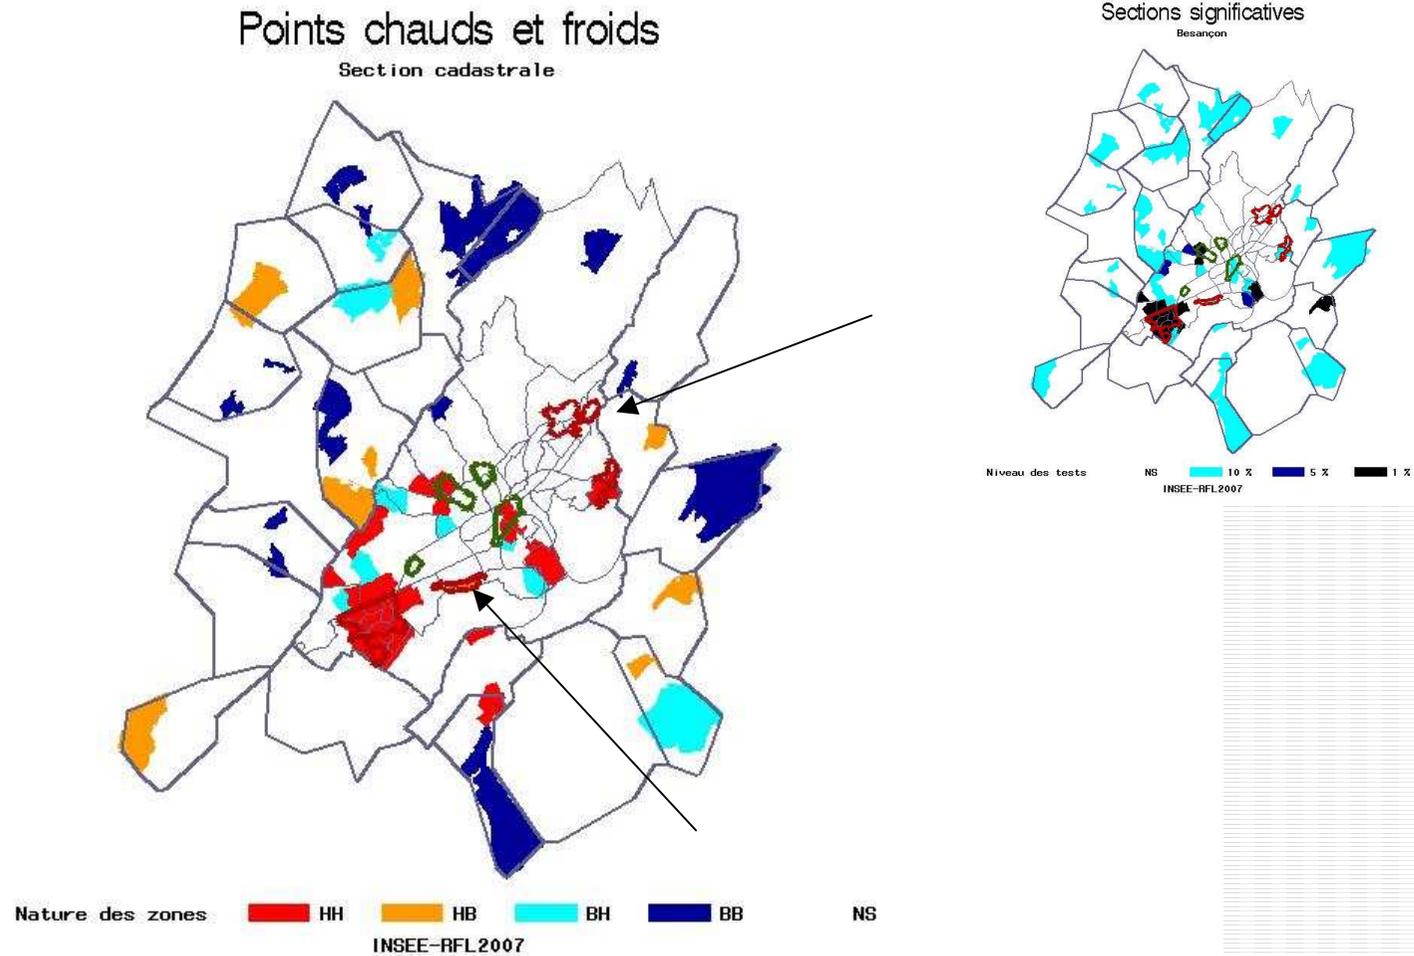
$$b_2 = \frac{m_4}{m_2^2}$$

$$m_r = \sum_{i=1}^n \frac{z_i^r}{n}$$

$$w_{i(2)} = \sum_{j=1}^n w_{ij}^2$$

$$w_{i(kh)} = \sum_{k=1}^n \sum_{h=1}^n w_{ik} w_{ih}$$

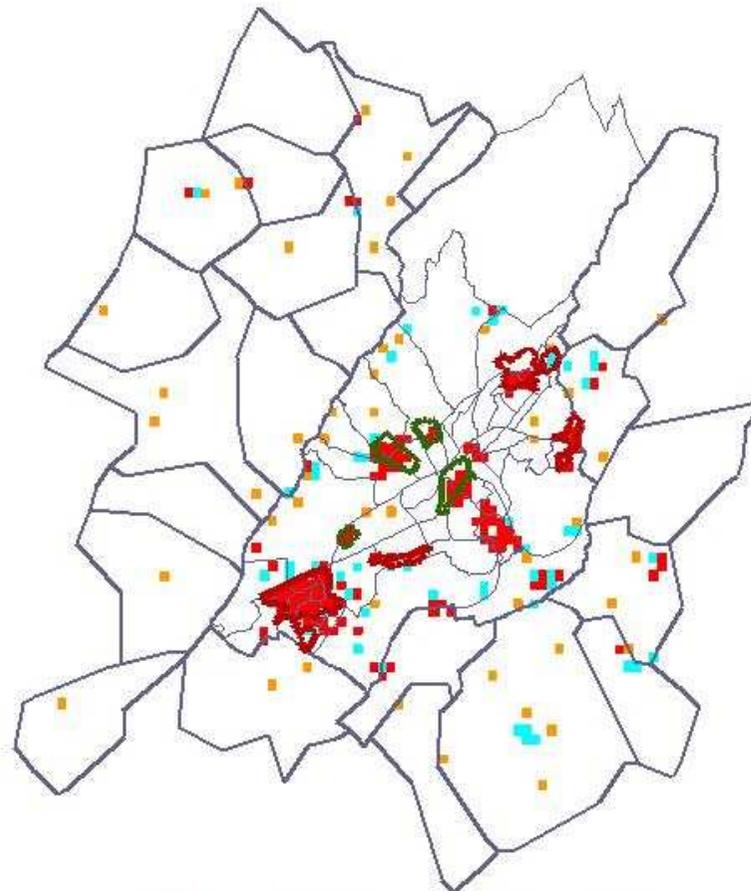
# Résultats sur les données à la section cadastrale



# Résultats sur un carroyage

Points chauds et froids

Carreau de 200 m



Nature des zones ■ HH ■ HB ■ BH ■ BB NS  
INSEE-RFL2007

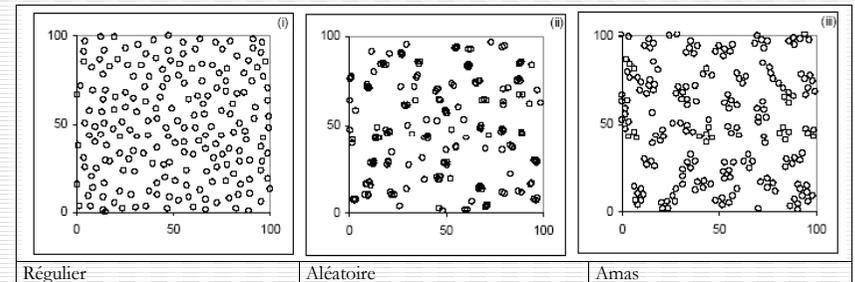


---

# Les ratios de densité estimée

# Le cadre théorique

- Les données : une série de localisation, chaque point pouvant être doté d'un certain nombre d'attributs



- Une caractéristique du premier ordre, l'intensité

$$\lambda(s) = \lim_{ds \rightarrow 0} \left\{ \frac{E(N(ds))}{ds} \right\}$$

$N(S)$  est le nombre de points dans l'Aire  $S$

# Processus homogène

- Si  $\lambda = \text{cte}$ , on peut définir un processus homogène de Poisson ( l'aléatoire dans le plan)

$$P(N(S) = n) = e^{-\lambda S} \frac{(\lambda S)^n}{n!}$$

- Dans le cas contraire ( la règle pour nous) , on a un processus inhomogène ( cas d'un processus inhomogène de Poisson)

$$P(N(S) = n) = e^{-\nu(S)} \frac{(\nu(S))^n}{n!} \quad \text{avec} \quad \nu(S) = \int_s \lambda(s) ds$$

# Intensité du processus et densité de probabilité

---

- On va utiliser des techniques non paramétriques d'estimation de la densité
- Lien entre  $\lambda(s)$  et  $f(s)$  (densité de probabilité de la répartition des points)
  - $\int \lambda(s) ds = n$
  - $\int f(s) ds = 1$
- Article de Diggle et Marron (JASA 1988) sur l'équivalence de l'estimation de l'intensité et de la densité

# Ratio de densité, risque relatif

---

- Les épidémiologistes définissent un risque relatif

$$\lambda(s) = \vartheta(s) * \lambda_0(s) \quad \text{Cas/contrôle (0)}$$

- Ce qui fait apparaître le rapport des intensités. On va ici introduire le rapport des densités, qui va traduire la sur(sous)représentation de la population d'intérêt par rapport à la population de référence

# Propriété du rapport de densité

---

- Dans un cadre bien délimité ( ici population d'intérêt sous-ensemble de la population de référence), le ratio des densités de probabilité  $f_B$  et  $f_p$  (  $f_b$  et  $f_p$  étant définis par rapport à la mesure de Lebesgue) est lui même la densité de probabilité de la distribution de B par rapport à la mesure  $f_p \cdot \mu$  (théorème de Radon-Nikodym)
- Interprétation possible également en terme d'espérance conditionnelle

# L'estimation du ratio

---

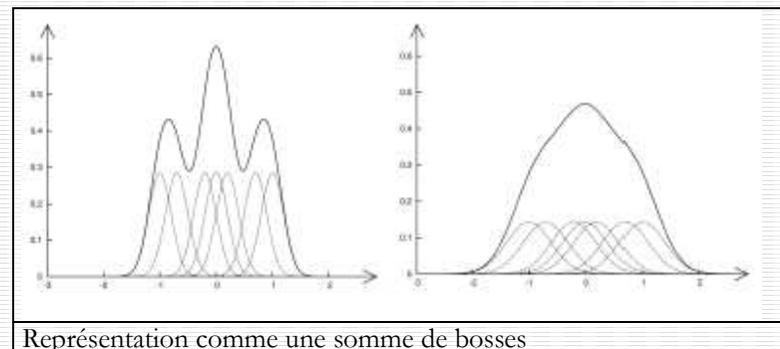
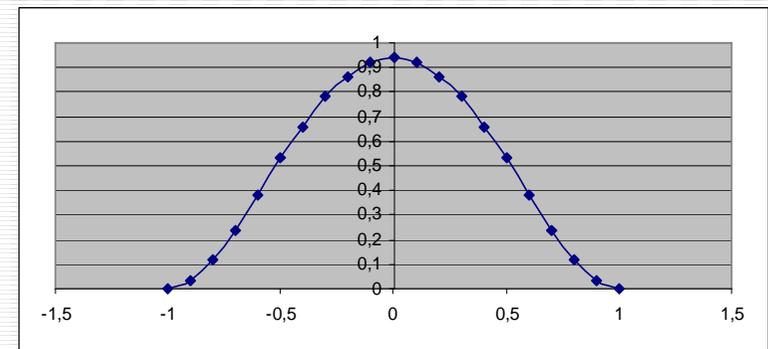
- On va quitter le monde merveilleux des probabilités et estimer  $r = f_B / f_P$  par  $\hat{r} = \hat{f}_B / \hat{f}_P$
- On va utiliser pour cela les estimateurs non-paramétriques de la densité ( les exemples seront présentés sur la droite et non dans le plan, mais ils peuvent se généraliser ( au prix quand même de quelques difficultés )

# L'estimation de la densité

$$\hat{f}_h(x) = \frac{1}{nh} \sum_{i=1}^n K\left(\frac{x - X_i}{h}\right)$$

Exemple de noyau  
Biweight de Tukey

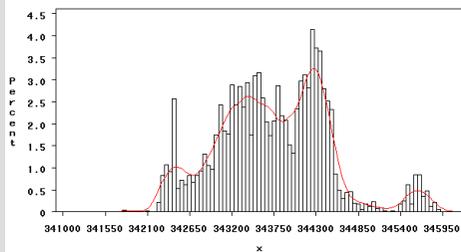
- h Fenêtre
- K fonction Noyau ( kernel)
- x point d'estimation
- $X_i$  point d'observation



Représentation comme une somme de bosses

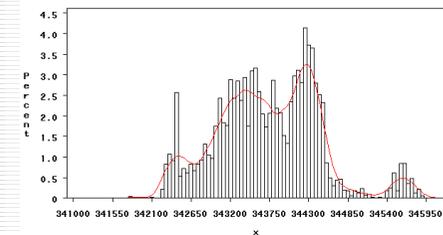
# L'épineux problème de la fenêtre

- Un consensus sur le fait que le noyau importe peu ( à condition qu'il soit décroissant et symétrique)

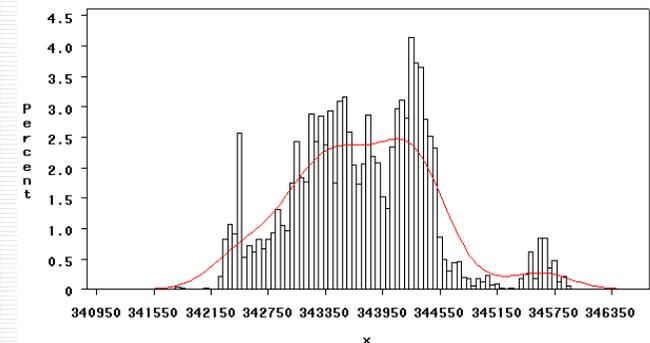
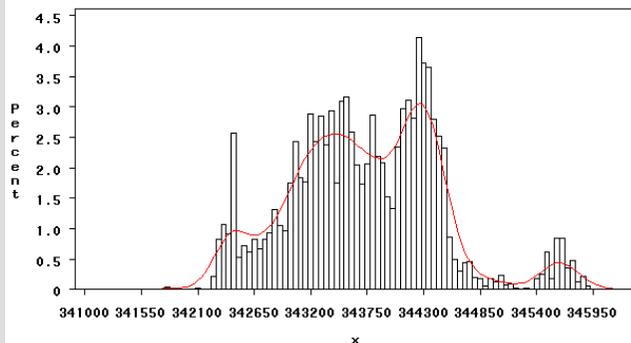


T

Bw



- La fenêtre est plus difficile à déterminer



# Quelques difficultés

---

- Biais des estimateurs
- Fenêtre optimale pour estimer à la fois la densité « numérateur » et la densité « dénominateur »

# Des résultats d'optimalité problématiques

- Dans SAS, la procédure KDE, qui utilise le noyau gaussien, qui permet des résultats ultra-rapides (FFT), le noyau optimal est

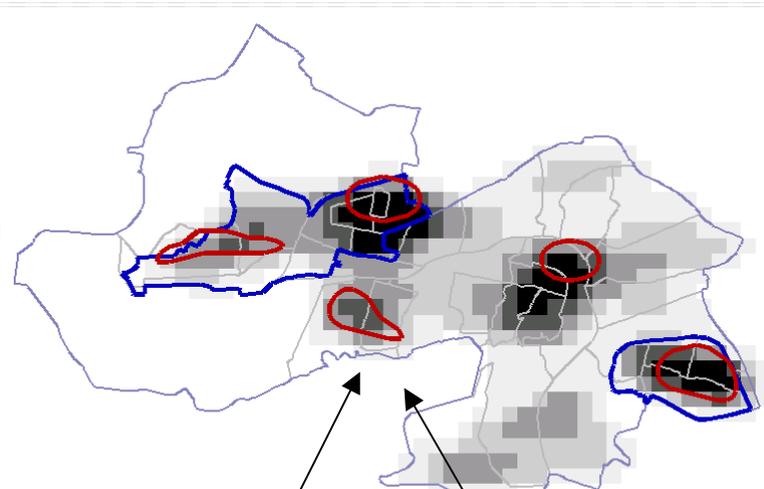
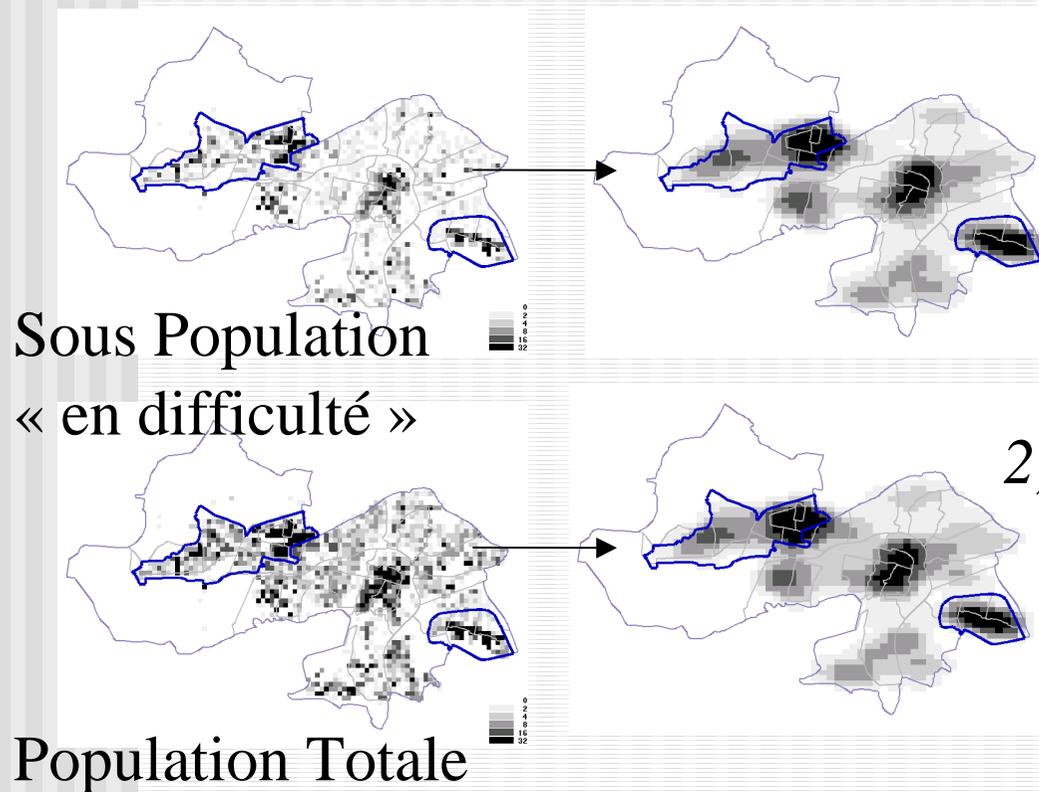
$$\frac{1}{2\pi h_x h_y} \exp\left(-\frac{\left(\frac{x}{h_x}\right)^2 + \left(\frac{y}{h_y}\right)^2}{2}\right)$$

$$h_x = \hat{\sigma}_x n^{-\frac{1}{6}} \text{ (resp. } y)$$

- L'expérience et la confrontation avec la connaissance du terrain nous a conduit à diminuer par deux la bande passante

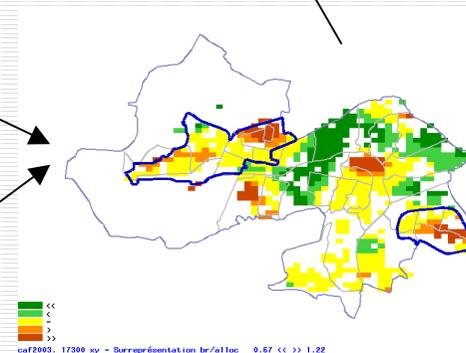
# Un outil standard

## 1) Simplification



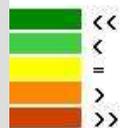
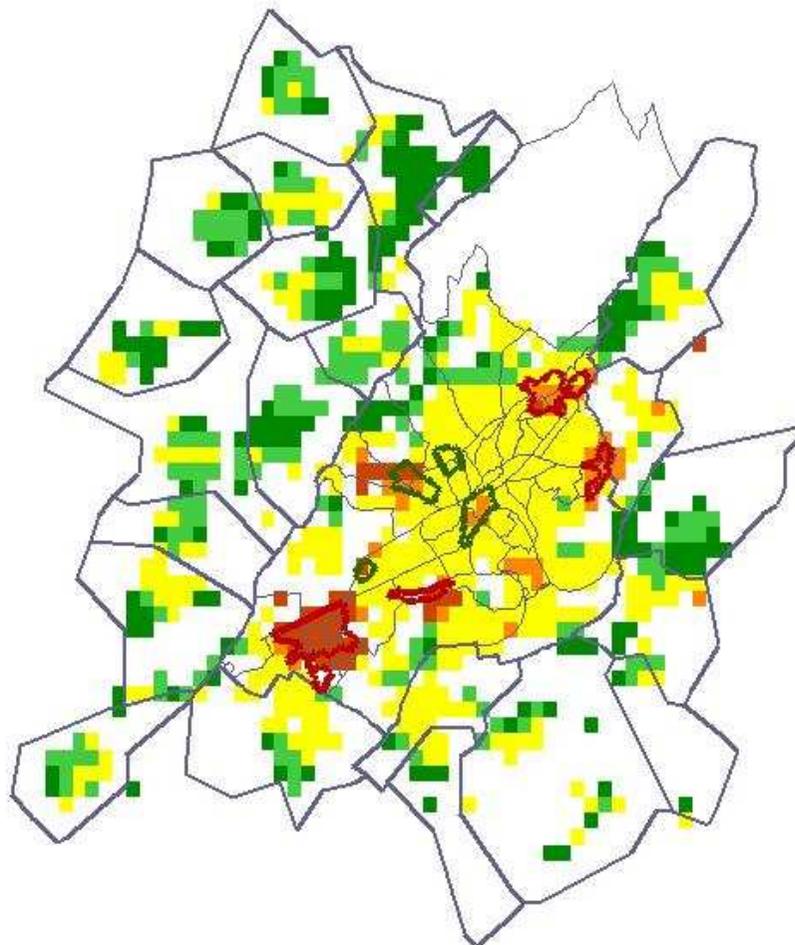
## 3) Extraction des contours Superposition

## 2) SP/PT



# Le résultat

Ratios de densité



ee.men\_besac - Surreprésentation b\_rev/rev 0.26 << >> 1.75



---

# Indicateurs de Marcon et Puech

# Les propriétés du second ordre

---

- Intensité d'un processus ponctuel

$$\lambda(s) = \lim_{ds \rightarrow 0} \left\{ \frac{E(N(ds))}{ds} \right\} \leftarrow 1^{\circ} \text{ ordre}$$

- Propriétés du second ordre

$$\lambda_2(s_i, s_j) = \lim_{ds_i, ds_j \rightarrow 0} \left\{ \frac{E(N(ds_i)N(ds_j))}{ds_i ds_j} \right\}$$

- Inutilisable en tant que telle
- Ce sont les fonctions K de Ripley ( et leurs variantes) qui servent à aborder ces questions

# La fonction K de Ripley

---

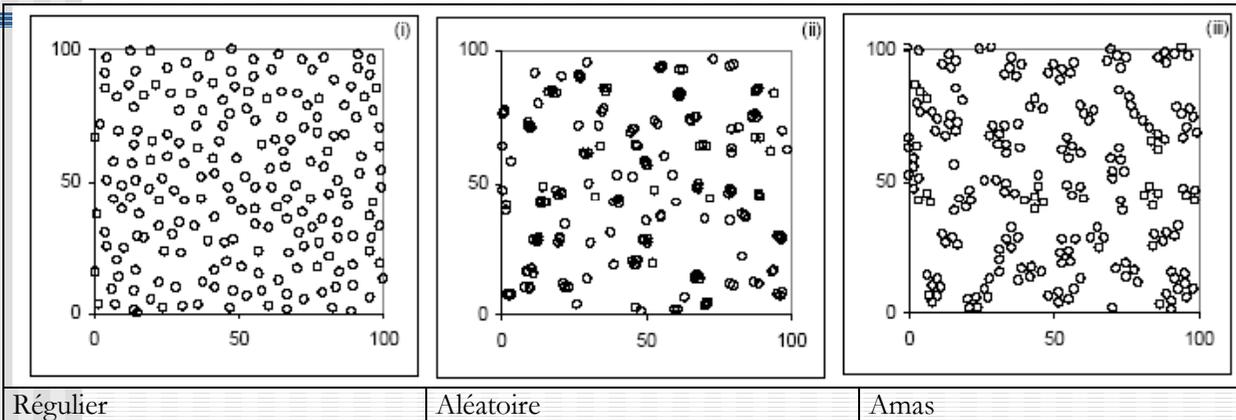
$$\frac{K(r)}{\pi r^2} = \frac{\frac{1}{N} \sum_{i=1}^N \sum_{j \neq i} d_{ij}(r)}{\frac{N-1}{D}}$$

$N$  : Nbre de points du semis

$d_{ij}(r)$  : indicatrice valant 1 si  $j$  est à une distance inférieure à  $r$  de  $i$

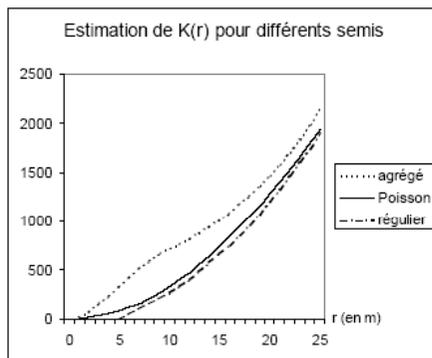
$D$  : Aire du domaine

# Trois configurations classiques, leur K (Ripley), leur L(Besag)

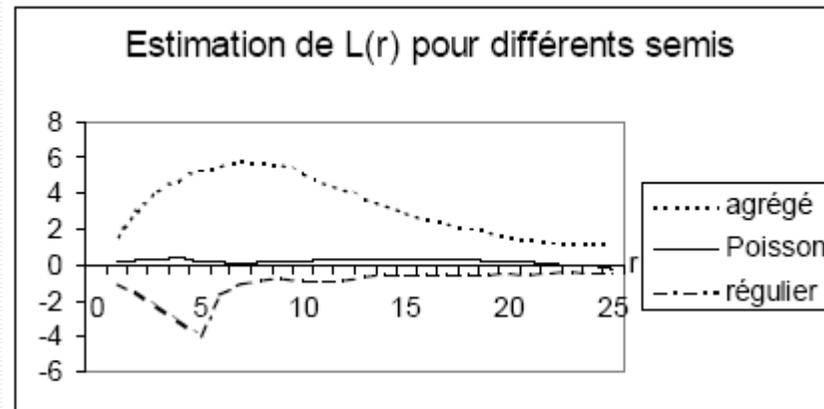


(Source : Thèse de François GOREAUD)

$$L(r) = \sqrt{\frac{K(r)}{\pi} - r}$$



Estimation de la fonction K(r) pour un semis agrégé, un semis de Poisson, et un semis régulier.

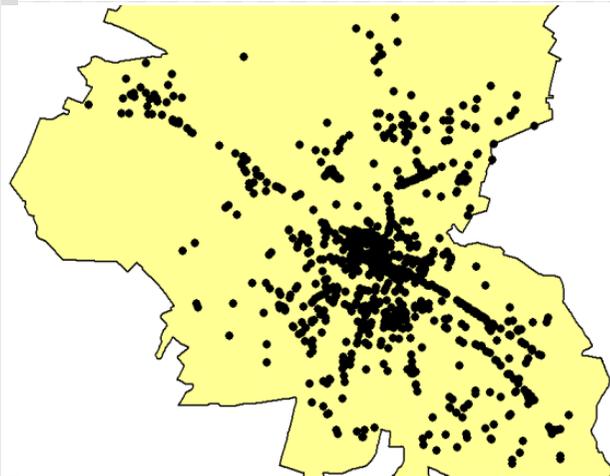


K

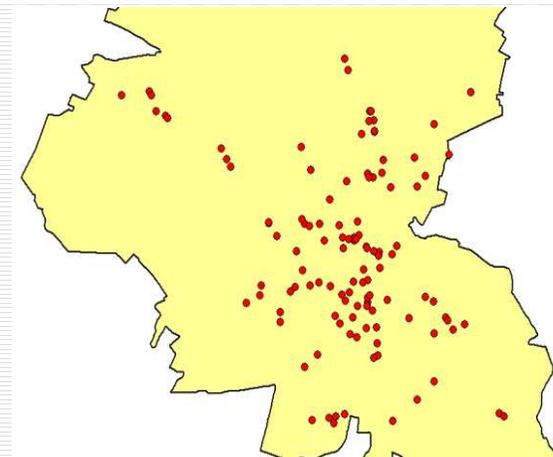
# De K et L à M....

- Les fonctions K et L permettent de savoir si le processus est ou n'est pas homogène, mais comme toujours, par rapport à quoi ( espace « amorphe »,  $\mathbb{R}^2$  ou espace structuré)

*Ensemble des équipements*



*Médecins généralistes*



# Les travaux de E.Marcon et F.Puech

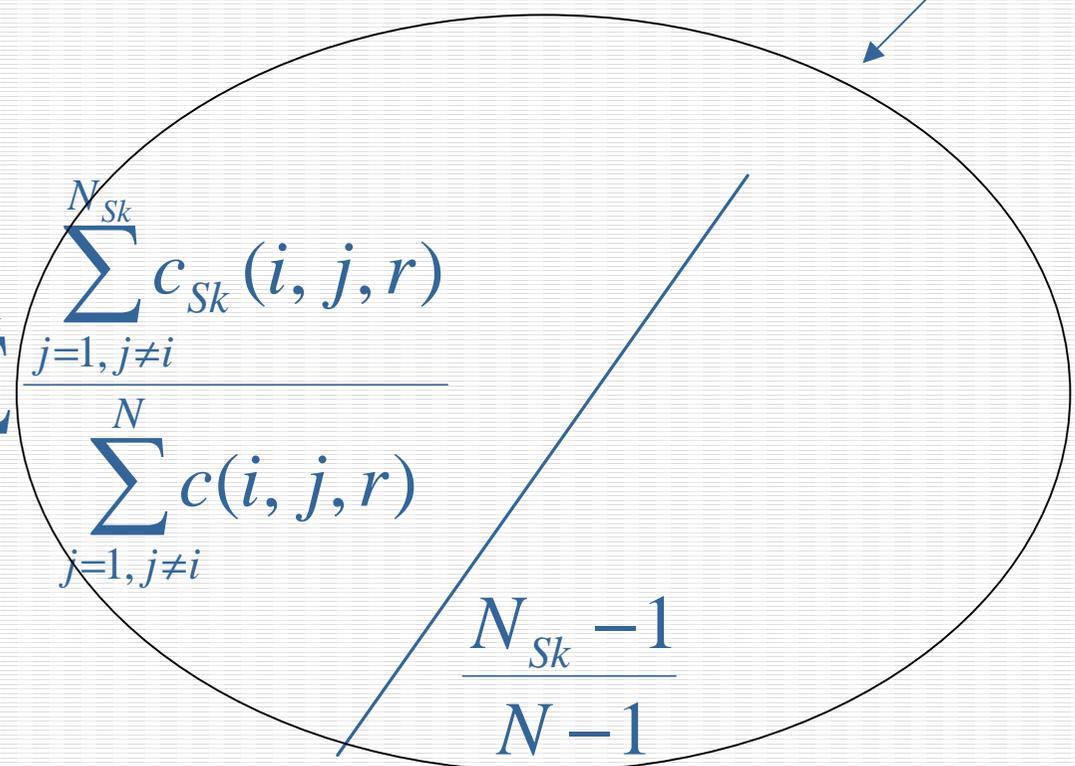
---

- Ils visent :
  - À prendre en compte la structure sous-jacente ( dans notre cas, la population des bas revenus relativement à un espace peuplé et non à  $R^2$ )
  - A permettre ( comme dans le cas des LISA de faire apparaître les zones de non-stationnarité

# La formulation de M

Proportion moyenne de points de type  $S_k$  au voisinage de chaque entité de  $S_k$

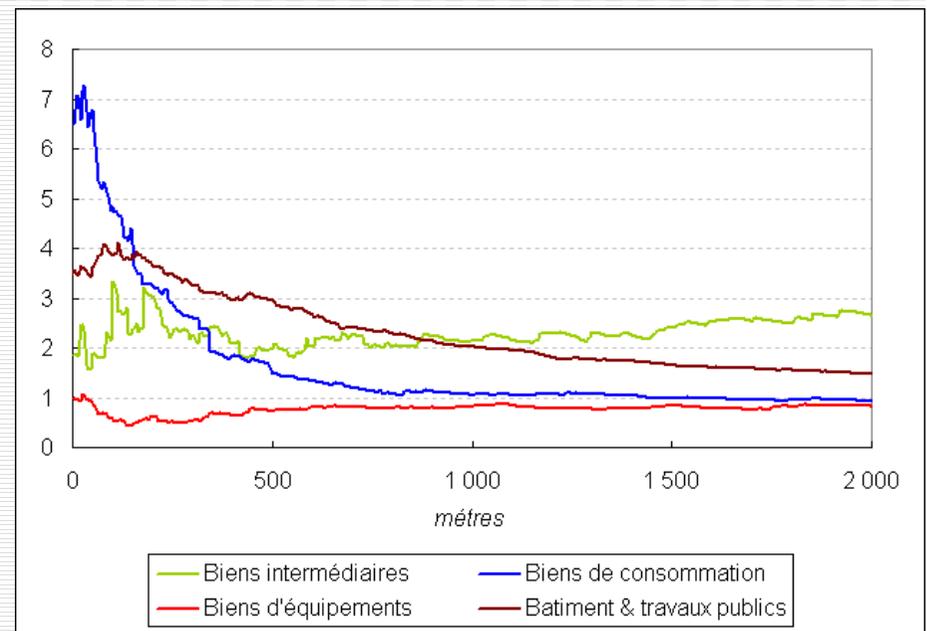
Valeurs individuelles de M

$$M_{S_k}(r) = \frac{1}{N_{S_k}} \sum_{i=1}^{N_{S_k}} \frac{\sum_{j=1, j \neq i}^{N_{S_k}} c_{S_k}(i, j, r)}{\sum_{j=1, j \neq i}^N c(i, j, r)}$$


# Lecture

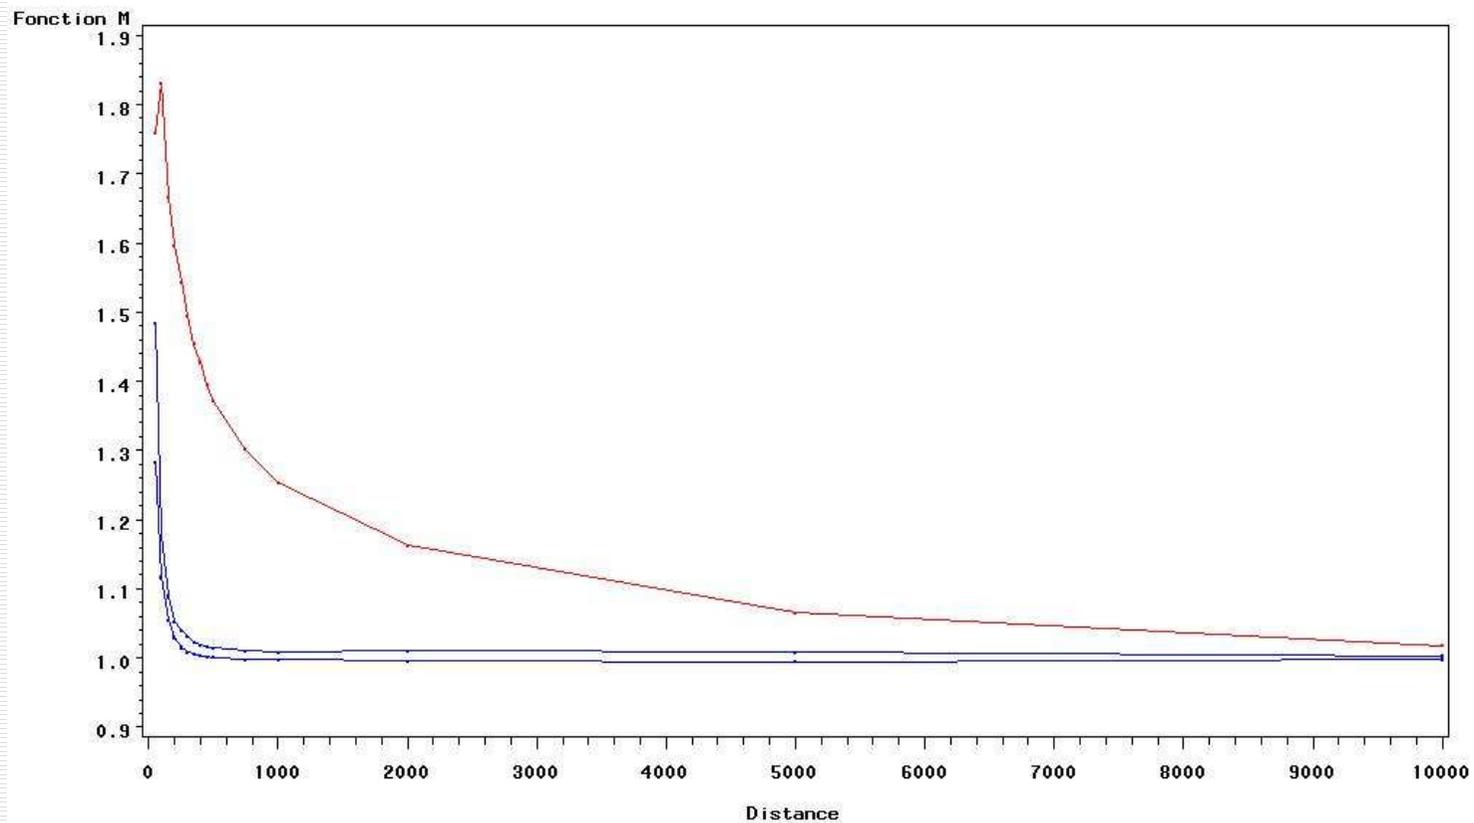
- La fonction M est une mesure de concentration relative
- La référence pour la lecture de la fonction M est la valeur 1

Un exemple dans un  
autre champ



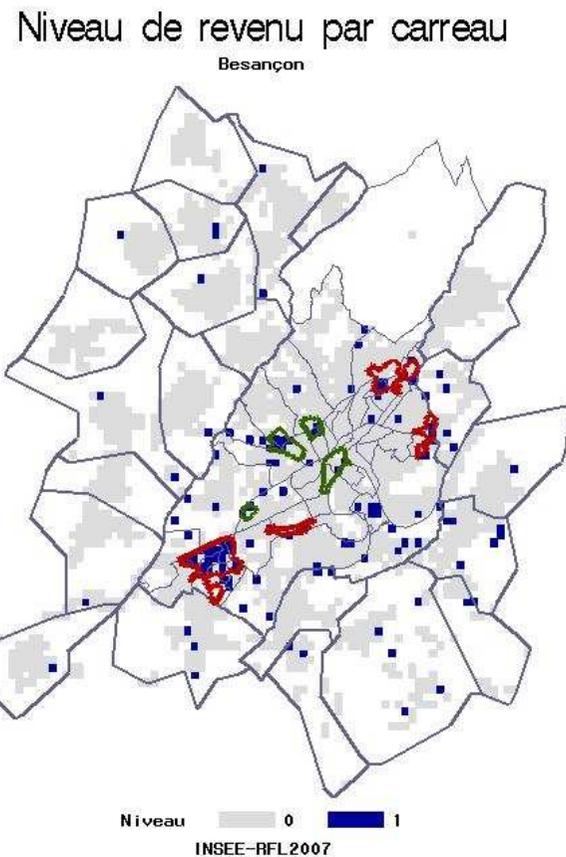
# La fonction M pour les bas revenus

Fonction M de Marcon et Puech (en rouge)  
Intervalle de confiance en bleu



# Le repérage des zones

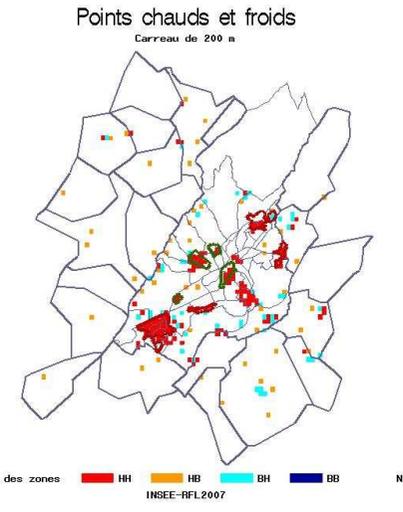
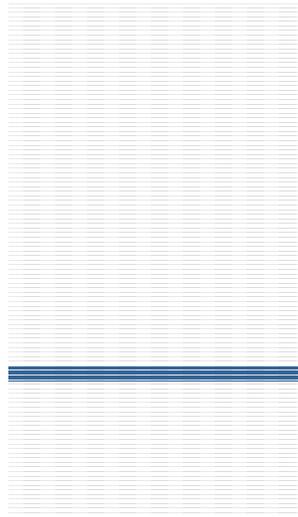
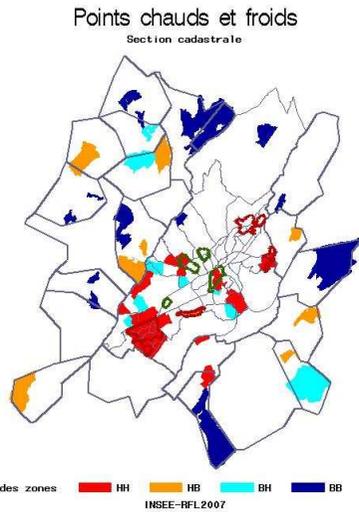
- Valeur locale  $M_i > 1.8$ , à 100 m de distance





---

# Conclusion



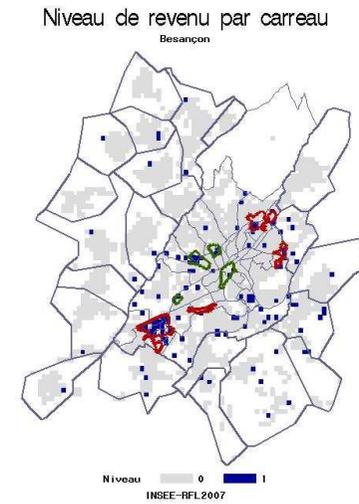
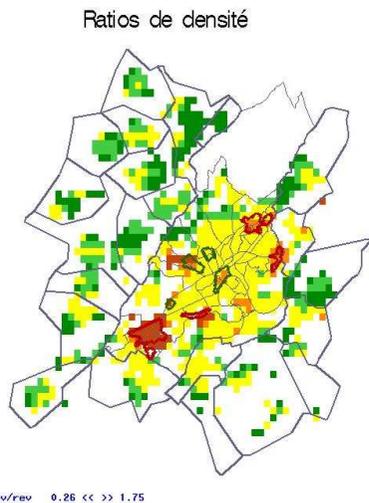
Lisa section

Lisa carreau

Ratios

Bas revenus

Marcon & Puech



# Quelques remarques

---

- Trois représentations cohérentes, ne laissant pas de côté de zones bien identifiées de difficultés sociales
- Représentation plus approximative dans le cas des sections cadastrales
- Les Lisa, qui n'utilisent que des taux peuvent contribuer à l'analyse. La disponibilité de données sur un maillage fin permet de meilleurs résultats.



Merci de  
votre  
attention



---

Merci de votre attention