

INTRODUCTION
oooooooo

AGRÉGATS POTENTIELS
oooooooooooooooooooo

INDICES DE CONCENTRATION
oooooooooooooooooooo

MARQUES NON RÉELLES
oooooooooooo

PERSPECTIVES
ooooooo

Détection d'agrégats temporels, spatiaux et spatio-temporels: contributions aux méthodes de balayage.

Lionel Cucala

Mercredi 8 Juin 2022



Sommaire

Introduction

1-Des agrégats potentiels originaux

2-Des indices de concentration alternatifs

3-Marques multivariées et fonctionnelles

Perspectives

Sommaire

Introduction

Perspectives

Données localisées

- ▶ Dans le temps, dans l'espace ou dans les deux.
 - ▶ Domaine d'observation : $W \subset \mathbb{R}^d$.
 - ▶ Localisations : s_1, \dots, s_n .

Détection d'agrégat(s) (cas non marqué)

- ▶ Agrégat (Naus, 1963) : Ensemble de localisations "anormalement" proches.
 - ▶ Adaptation à une mesure de population sous-jacente $\mu(\cdot)$.
 - ▶ Agrégat : $Z \subset W$ tel que $n(Z)$ "anormal" par rapport à $\mu(Z)$.

Détection d'agrégat(s) (cas marqué)

- ▶ Variable X mesurée en chaque localisation.
 - ▶ Observations : $(s_1, x_1), \dots, (s_n, x_n)$.
 - ▶ Agrégat : $Z \subset W$ tel que $\{x_i : s_i \in Z\}$ "anormalement différent" de $\{x_i : s_i \in Z^c\}$.

Méthodes de balayage

- ▶ Objectif : balayer la fenêtre W et identifier l'agrégat le plus probable.
 - ▶ Statistique de balayage : indice de concentration maximum sur un ensemble d'agrégats potentiels

$$\lambda = \max_{Z \in \mathcal{C}} I(Z)$$

- Elle dépend de :
 - l'ensemble des agrégats potentiels \mathcal{C} .
 - l'indice de concentration $I(Z)$.

Significativité

- Agrégat le plus probable :

$$\hat{C} = \arg \max_{Z \in \mathcal{C}} I(Z).$$

- Significativité estimée par procédure Monte-Carlo (T simulations) :

$$\text{p-val} = \frac{1 + \sum_{j=1}^T \mathbb{1}(\lambda^{(j)} > \lambda)}{T + 1}.$$

- Simulations :

- Cas non marqué : $s_1^{(j)}, \dots, s_n^{(j)}$ i.i.d. $\sim \mu(\cdot)$.
- Cas marqué : permutation aléatoire des marques.

Sommaire

Introduction

1-Des agrégats potentiels originaux

2-Des indices de concentration alternatifs

3-Marques multivariées et fonctionnelles

Perspectives

INTRODUCTION
oooooooo

AGRÉGATS POTENTIELS
○●oooooooooooooo

INDICES DE CONCENTRATION
oooooooooooooooooooo

MARQUES NON RÉELLES
oooooooooooo

PERSPECTIVES
ooooooo

Sommaire

Introduction

1-Des agrégats potentiels originaux

2-Des indices de concentration alternatifs

3-Marques multivariées et fonctionnelles

Perspectives

Choix classiques : agrégats potentiels à géométrie contrainte

- Cadre temporel (Nagarwalla, 1996) :

$$\mathcal{C} = \{[s_j, s_j] : s_j < s_j\}.$$

- #### ► Cadre spatial (Kulldorff, 1997) :

$$\mathcal{C} = \{D_{i,j} : 1 \leq i, j \leq n\}$$

où $D_{i,j}$: disque centré en s_i passant par s_j .

- Cadre spatio-temporel (Kulldorff et al., 1998) :

$$\mathcal{C} = \{C_{i,j} : 1 \leq i,j \leq n\}$$

où $C_{i,j}$: cylindre contenant s_i et s_j .

Agrégats potentiels sans contrainte de forme

- ▶ Utilisation d'agrégats elliptiques (Kulldorff et al., 2006).
 - ▶ Utilisation des cellules de Voronoi (Duczmal et al., 2011).

Piste 1 : Parcourir les événements de façon pertinente

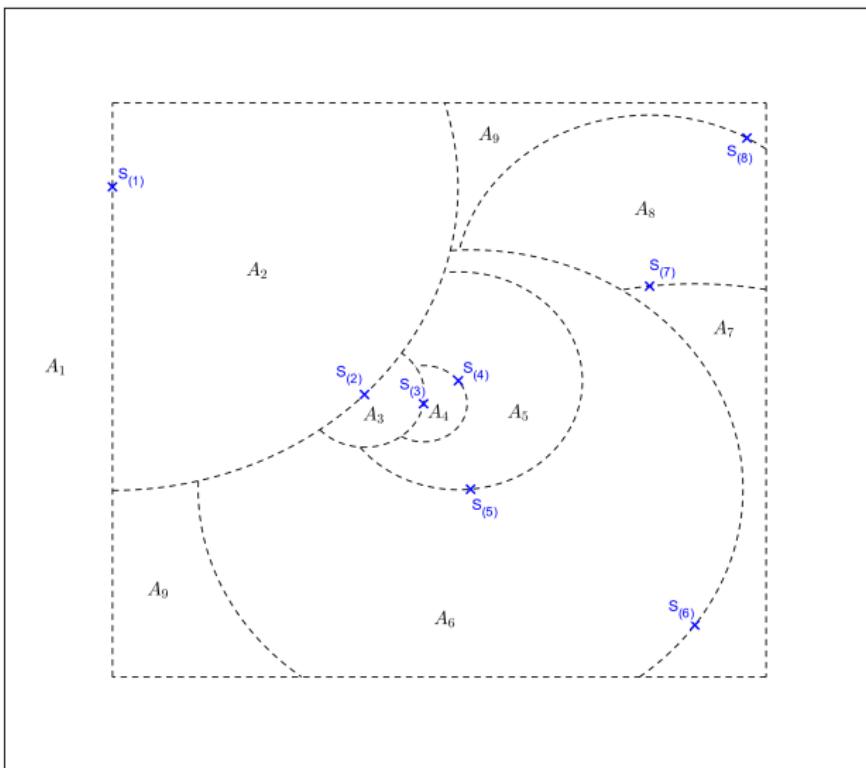
- ▶ Idée de Dematteï et al. (2007) : parcourir les localisations s_1, \dots, s_n de proche en proche.



$$s_{(1)} = \arg \min_{s \in \{s_1, \dots, s_n\}} d(s, \partial W).$$

$$\forall i \in \llbracket 2, n \rrbracket, \quad s_{(i)} = \arg \min_{s \in \{s_1, \dots, s_n\}, s \notin \{s_{(1)}, \dots, s_{(i-1)}\}} d(s, s_{(i)}).$$

Piste 1 : Parcourir les événements de façon pertinente



Piste 1 : Parcourir les événements de façon pertinente

- ▶ Définition des aires d'espacement : A_1, \dots, A_{n+1} .
- ▶ Propriété de distribution :

$$(A_1, \dots, A_{n+1}) \sim (E_1, \dots, E_{n+1})$$

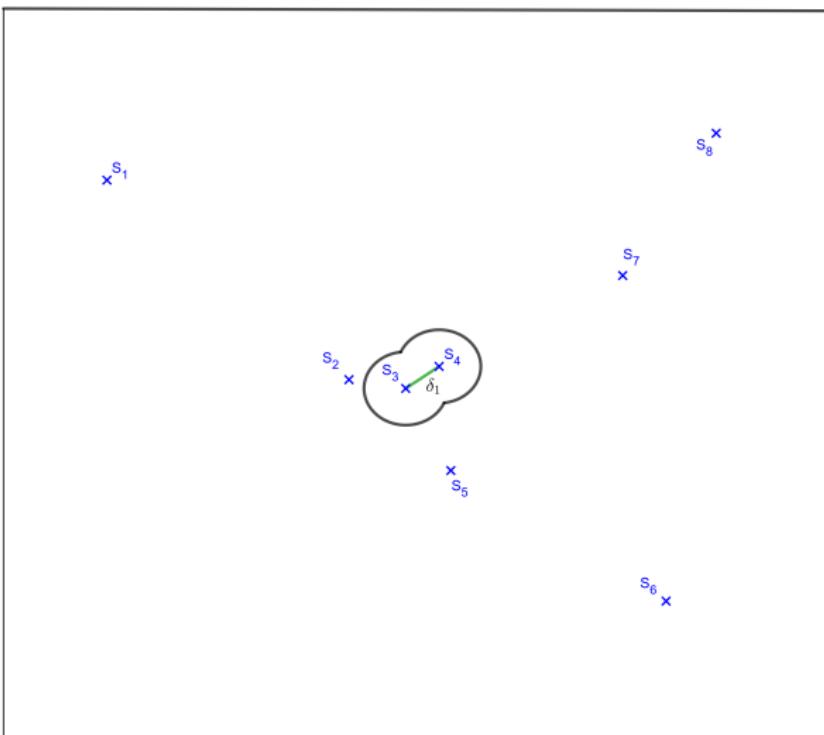
où E_1, \dots, E_{n+1} : espacements uniformes sur $[0, 1]$.

- ▶ On se ramène à de la détection d'agrégat temporel.

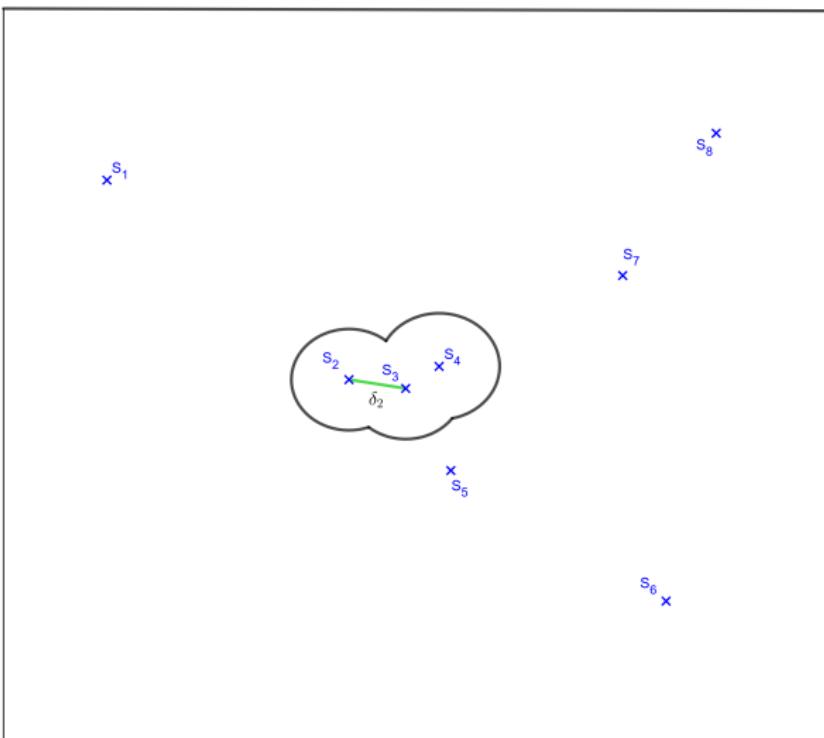
Piste 2 : Des agrégats potentiels basés sur les distances

- ▶ Algorithme de Bar-Hen et al. (2007) : création de graphes.
- ▶ Soit $\delta > 0$. On définit le graphe $\mathcal{G}(\delta)$:
 - Sommets : $\{1, \dots, n\}$.
 - Arêtes : $\{(i, j) : d(s_i, s_j) \leq \delta \text{ et } 1 \leq i < j \leq n\}$.
- ▶ Agrégats potentiels : composantes connexes de $\mathcal{G}(\delta)$ à mesure que δ augmente.

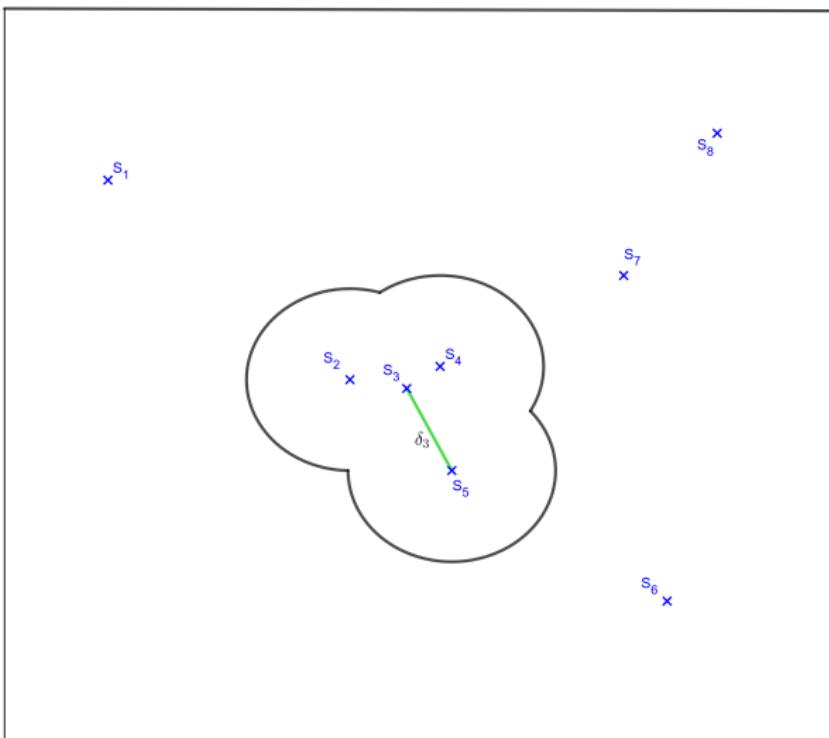
Piste 2 : Des agrégats potentiels basés sur les distances



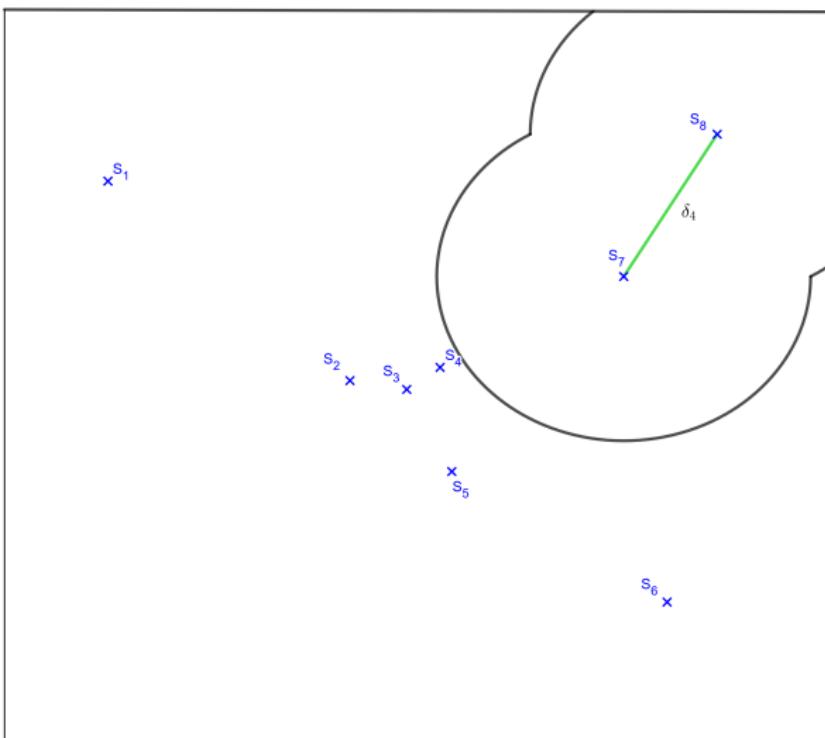
Piste 2 : Des agrégats potentiels basés sur les distances



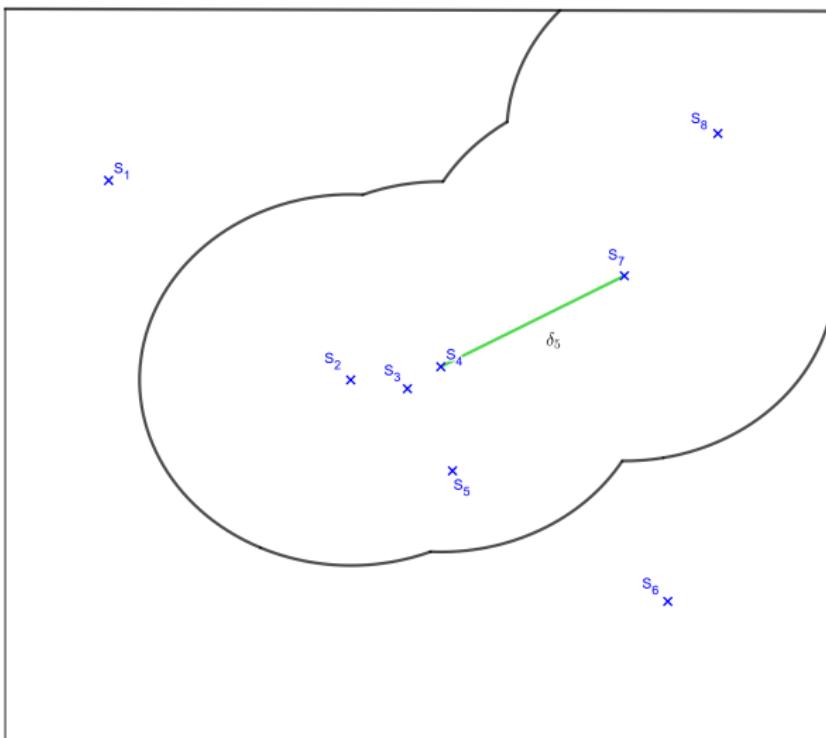
Piste 2 : Des agrégats potentiels basés sur les distances



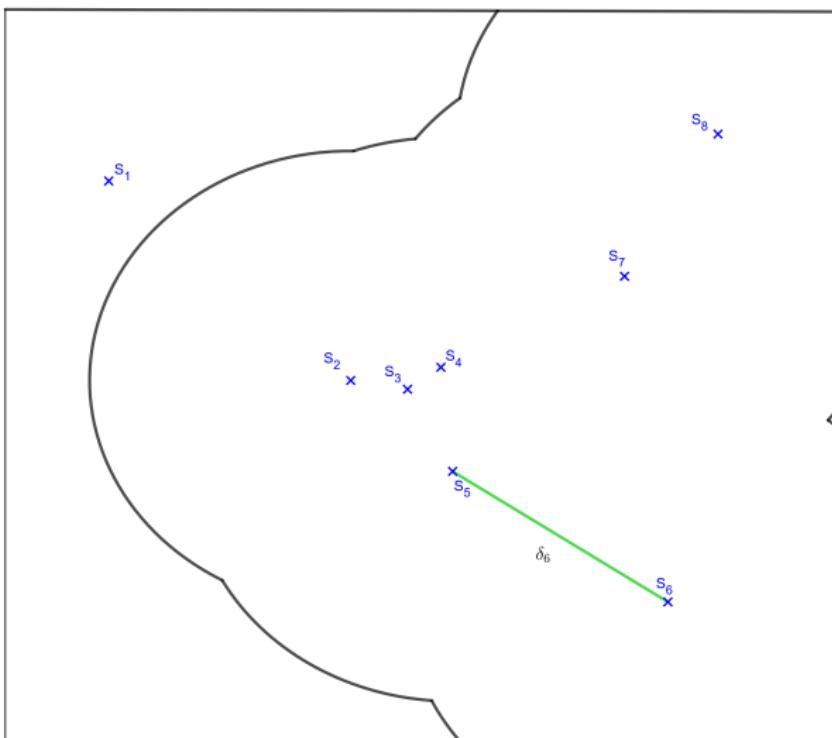
Piste 2 : Des agrégats potentiels basés sur les distances



Piste 2 : Des agrégats potentiels basés sur les distances



Piste 2 : Des agrégats potentiels basés sur les distances



Piste 3 : Une distance spatio-temporelle

► Fenêtre d'observation :

$$W = A \times T.$$

► $D = 2\sqrt{\frac{|A|}{\pi}}$ équivaut à $|T|$.

►

$$d_{ST}((y, t), (y', t')) = \sqrt{ds(y, y')^2 + \frac{D^2}{|T|^2} d_T(t, t')^2}.$$

Publications associées

- ▶ Cucala, L. (2009). A flexible spatial scan test for case event data. *Computational Statistics and Data Analysis*, 53, p. 2843-2850.
- ▶ Dematteï, C. et Cucala, L. (2011). Multiple spatio-temporal cluster detection for case event data : an ordering-based approach. *Communications in Statistics – Theory and Methods*, 40, p. 358-372.
- ▶ Cucala, L., Dematteï, C., Lopes, P. et Ribeiro, A. (2013). Spatial scan statistics for case event data based on connected components. *Computational Statistics*, 28, p. 357-369.

Sommaire

Introduction

1-Des agrégats potentiels originaux

2-Des indices de concentration alternatifs

3-Marques multivariées et fonctionnelles

Perspectives

Sommaire

Introduction

1-Des agrégats potentiels originaux

2-Des indices de concentration alternatifs

3-Marques multivariées et fonctionnelles

Perspectives

Importance de l'indice de concentration

- ➡ Statistique de balayage : indice de concentration maximum sur un ensemble d'agrégats potentiels

$$\lambda = \max_{Z \in \mathcal{C}} I(Z)$$

- ➡ Quel indice de concentration utiliser ?

Processus non marqué

- ▶ Objectif : trouver la zone où la concentration en événements est maximale par rapport à $\mu(\cdot)$.
- ▶ Problème : comment comparer Z et Z' si $n(Z) > n(Z')$ et $\mu(Z) > \mu(Z')$?
- ▶ Idée de Nagarwalla (1996) et Kulldorff (1997) : utiliser un rapport de vraisemblance généralisé.

Processus non marqué : approche paramétrique

- Modèle paramétrique \mathcal{M}_0 : absence totale d'agrégat.
 - Pour chaque agrégat potentiel $Z \in \mathcal{C}$, un modèle paramétrique $\mathcal{M}_{1,Z}$: présence d'un agrégat dans Z .
 - Rapport de vraisemblance entre les deux modèles :

$$RV(Z) = \frac{L_{1,Z}^*}{L_0^*}.$$

- ▶ Indice de concentration $I(Z)$ dérivé de $RV(Z)$.
 - ▶ Statistique de balayage :

$$\lambda = \max_{Z \in \mathcal{C}} I(Z).$$

Processus non marqué : approche paramétrique

- ▶ Kulldorff (1997) : modèle Poissonnien.
 - ▶ Nagarwalla (1996) : approche conditionnelle.
 - ▶ Rapport de vraisemblance identique :

$$RV(Z) = \frac{L_{1,Z}^*}{L_0^*} = \frac{\left(\frac{n(Z)}{\mu(Z)}\right)^{n(Z)} \left(\frac{n(Z^c)}{\mu(Z^c)}\right)^{n(Z^c)}}{n^n}.$$

- #### ► Indice de concentration :

$$I_{RV}(Z) = \log(RV(Z)) \left(\mathbb{1}(n(Z) > n\mu(Z)) - \mathbb{1}(n(Z) < n\mu(Z)) \right).$$

Un indice de concentration basé sur les espacements

- ▶ Cadre temporel : $W = [0, T]$
 - ▶ $H_0 : S_1, \dots, S_n$ i.i.d. $\sim \phi(\cdot)$.
 - ▶ $T_i = \int_0^{S_i} \phi(s) ds.$
 - ▶ Statistiques d'ordre associées : $T_{(1)} \leq \dots \leq T_{(n)}$.
 - ▶ Sous H_0 :

$$D_{i,j} = T_{(j)} - T_{(i)} \sim \beta(j-i, n+1-j+i).$$

- Indice de concentration basé sur les espacements :

$$I_{ES}([T_{(i)}, T_{(j)}]) = 1 - B_{inc}(T_{(j)} - T_{(i)}, j - i, n + 1 - j + i).$$

Un indice de concentration basé sur les espacements

- ▶ Extension aux cadres spatial et spatio-temporel.

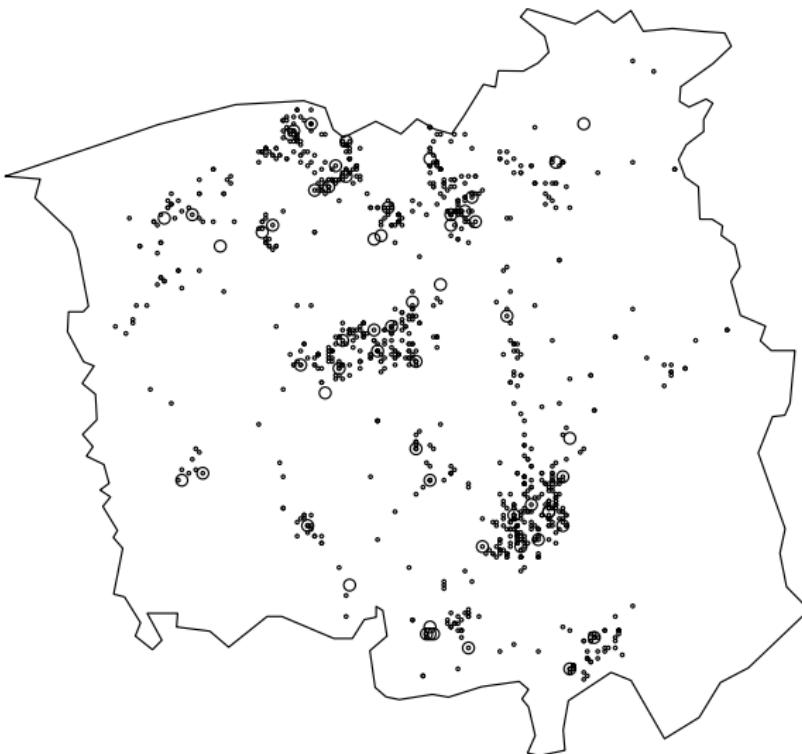
- ▶ Indice de concentration basé sur les espacements :

$$I_{ES}(Z) = 1 - B_{inc}(\mu(Z), n(Z) - 1, n + 2 - n(Z)).$$

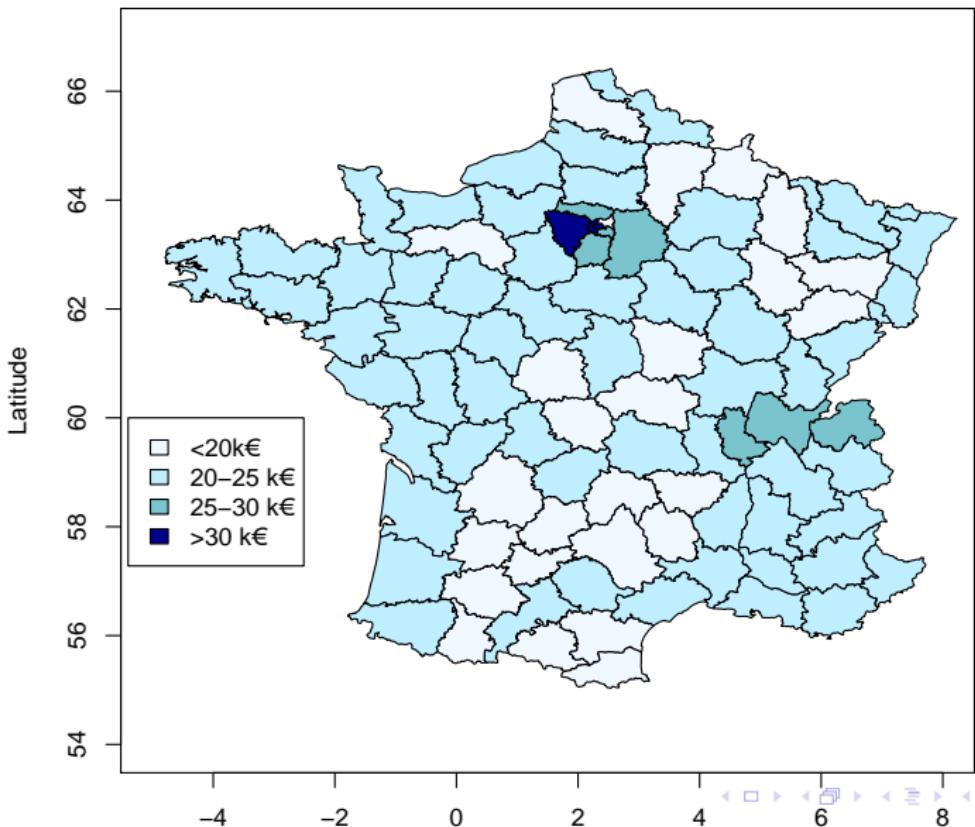
Processus marqué par une variable réelle

- ▶ Variable réelle X mesurée en chaque localisation.
- ▶ Observations : $(s_1, x_1), \dots, (s_n, x_n)$.
- ▶ Objectif : trouver la zone où la distribution des marques est la plus "anormale".

Processus marqué par une variable réelle



Processus marqué par une variable réelle



Processus marqué : approche paramétrique

- Modèle paramétrique \mathcal{M}_0 : X_1, \dots, X_n i.i.d. dans W .
 - Pour chaque agrégat potentiel $Z \in \mathcal{C}$, un modèle paramétrique $\mathcal{M}_{1,Z}$: distributions différentes dans Z et Z^c .
 - Rapport de vraisemblance entre les deux modèles :

$$RV(Z) = \frac{L_{1,Z}^*}{L_0^*}.$$

- ▶ Indice de concentration $I(Z)$ dérivé de $RV(Z)$.
 - ▶ Statistique de balayage :

$$\lambda = \max_{Z \in \mathcal{C}} I(Z).$$

Processus marqué : approche paramétrique

- ▶ Pour une variable binaire : modèle de Bernoulli (Kulldorff, 1997).
 - ▶ Rapport de vraisemblance proportionnel à

$$+ x(Z) \log(\bar{x}(Z)) + (n(Z) - x(Z)) \log(1 - \bar{x}(Z)) \\ + x(Z^c) \log(\bar{x}(Z^c)) + (n(Z^c) - x(Z^c)) \log(1 - \bar{x}(Z^c)).$$

Processus marqué : approche paramétrique

- ▶ Pour une variable continue : modèle Gaussien (Kulldorff et al., 2009).
 - ▶ Rapport de vraisemblance inversement proportionnel à

$$\frac{n(Z)\left(\overline{x^2}(Z) - (\bar{x}(Z))^2\right) + n(Z^c)\left(\overline{x^2}(Z^c) - (\bar{x}(Z^c))^2\right)}{n}.$$

Processus marqué : approche non-paramétrique

- ▶ Approche basée sur les moments.
 - ▶ Approche basée sur les rangs.
 - ▶ Hypothèse nulle :

$$H_0 : X_1, \dots, X_n \text{ i.i.d.}$$

Processus marqué : approche basée sur les moments

- #### → Écart inter-moyennes :

$$D(Z) = \bar{X}(Z) - \bar{X}(Z^c).$$

- Sous H_0 , on a :

$$\mathbb{E}_0(D(Z)) = 0 \text{ et } \mathbb{V}_0(D(Z)) = \frac{n}{n(Z)n(Z^c)}\sigma^2.$$

- #### ► Indice de concentration basé sur les moments :

$$I_M^+(Z) = \frac{\sqrt{n(Z)n(Z^c)}}{\sqrt{n}} (\bar{X}(Z) - \bar{X}(Z^c)).$$

- Lien avec le test de Student.

Processus marqué : approche basée sur les rangs

- Calcul des rangs (par ordre croissant) des X_i : R_1, \dots, R_n

- Somme des rangs dans Z : $SR(Z) = \sum_{i=1}^n R_i \mathbb{1}_Z(s_i)$.

- Sous H_0 , on a :

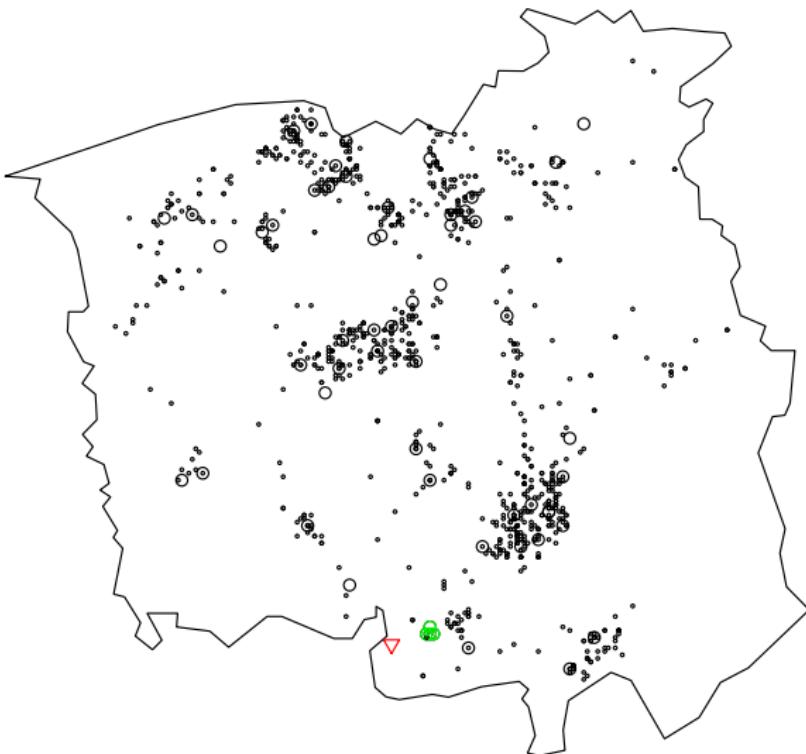
$$\mathbb{E}_0(SR(Z)) = \frac{n(Z)(n+1)}{2} \text{ et } \mathbb{V}_0(SR(Z)) = \frac{n(Z)n(Z^c)(n+1)}{12}.$$

- ▶ Indice de concentration basé sur les rangs :

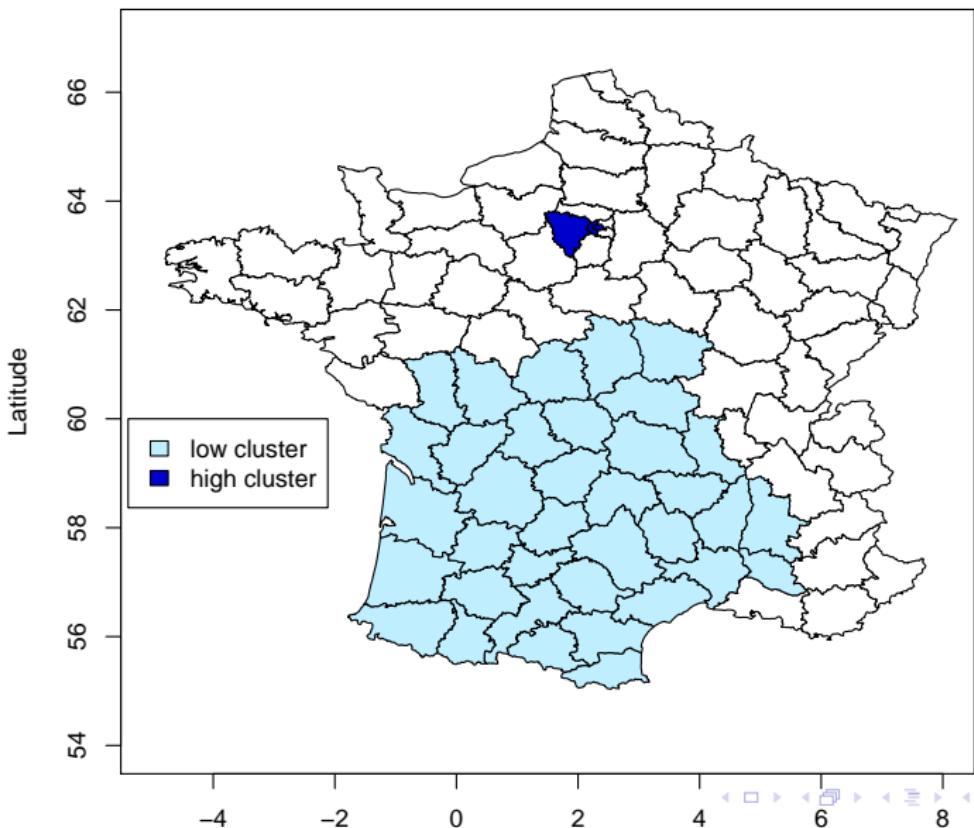
$$I_R^+(Z) = \frac{SR(Z) - \mathbb{E}_0(SR(Z))}{\sqrt{\mathbb{V}_0(SR(Z))}}.$$

- Lien avec le test de Wilcoxon-Mann-Whitney.

Processus marqué par une variable réelle



Processus marqué par une variable réelle



Publications associées

- ▶ Cucala, L. (2008). A hypothesis-free multiple scan statistic with variable window. *Biometrical Journal*, 50, p. 299-310.
- ▶ Cucala, L. (2014). A distribution-free spatial scan statistic for marked point processes. *Spatial Statistics*, 10, p. 117-125.
- ▶ Cucala, L. (2016). A Mann-Whitney scan statistic for continuous data. *Communications in Statistics – Theory and Methods*, 45, p. 321-329.
- ▶ Cucala, L. (2016). Scan statistics for detecting high-variance clusters. *Journal of Probability and Statistics*, Article ID 7591680.
- ▶ Cucala, L. et Dematteï, C. (2016). Spatial cluster detection for socio-economic data. *CSBIGS*, 6, p. 1-9.
- ▶ Cucala L. (2017). Variable Window Scan Statistics : Alternatives to Generalized Likelihood Ratio Tests. In : Glaz J., Koutras M. (eds) *Handbook of Scan Statistics*. Springer.

Sommaire

Introduction

1-Des agrégats potentiels originaux

2-Des indices de concentration alternatifs

3-Marques multivariées et fonctionnelles

Perspectives

INTRODUCTION
oooooooo

AGRÉGATS POTENTIELS
oooooooooooooooooooo

INDICES DE CONCENTRATION
oooooooooooooooooooo

MARQUES NON RÉELLES
o●oooooooooooo

PERSPECTIVES
ooooooo

Sommaire

Introduction

1-Des agrégats potentiels originaux

2-Des indices de concentration alternatifs

3-Marques multivariées et fonctionnelles

Perspectives

Processus marqué par plusieurs variables

- ▶ Variables réelles X^1, \dots, X^p mesurées en chaque localisation.
- ▶ Observations : $(s_1, x_1), \dots, (s_n, x_n)$
où $x_i = (x_i^1, \dots, x_i^p) \in \mathbb{R}^p$.
- ▶ Objectif : trouver la zone où la distribution des marques est la plus "anormale".

Processus marqué par plusieurs variables

- ▶ Méthode de Kulldorff et al. (2007) : combinaison des indices de concentration associés à chaque variable.
- ▶ Inconvénient : ne prend pas en compte les corrélations entre variables.
- ▶ Prise en compte des corrélations :
 - approche paramétrique.
 - approche non-paramétrique.

Marques multivariées : approche paramétrique

- #### → Modèle Gaussien multivarié :

$$\mathcal{M}_0 : X_1, \dots, X_n \text{ i.i.d. } \sim \mathcal{N}_p(m, \Sigma)$$

$$\mathcal{M}_{1,Z} : X_1, \dots, X_n \text{ indép. et } \begin{cases} X_i \sim \mathcal{N}_p(m_Z, \Sigma_{Z,Z^c}) & \text{si } s_i \in Z, \\ X_i \sim \mathcal{N}_p(m_{Z^c}, \Sigma_{Z^c,Z^c}) & \text{si } s_i \in Z^c. \end{cases}$$

- Rapport de vraisemblance inversement proportionnel à

$$|\Sigma_{Z,Z^c}^*|$$

$$\text{où } \Sigma_{Z,Z^c}^* = \frac{n(Z)S(Z) + n(Z^c)S(Z^c)}{n}.$$

- Lien avec le test de Hotelling.

Marques multivariées : approche non-paramétrique

- ▶ Extension multivariée du test de WMW proposée par Oja and Randles (2004).
- ▶ Fonction signe multivariée :

$$\forall x \in \mathbb{R}^p, \quad S(x) = \begin{cases} ||x||^{-1}x & \text{if } x \neq 0, \\ 0 & \text{if } x = 0, \end{cases}$$

- ▶ Rang multivarié associé à X_i :

$$R_i = \frac{1}{n} \sum_{k=1}^n S_{i,k}$$

où

$$S_{i,k} = S(A_x(X_i - X_k))$$

et A_x est la matrice de Tyler.

Marques multivariées : approche non-paramétrique

- #### ► Statistique de test d'égalité entre Z et Z^c :

$$U_{Z|Z^c}^2 = \frac{p}{c_x^2} [n(Z) ||\bar{R}_Z||^2 + n(Z^c) ||\bar{R}_{Z^c}||^2]$$

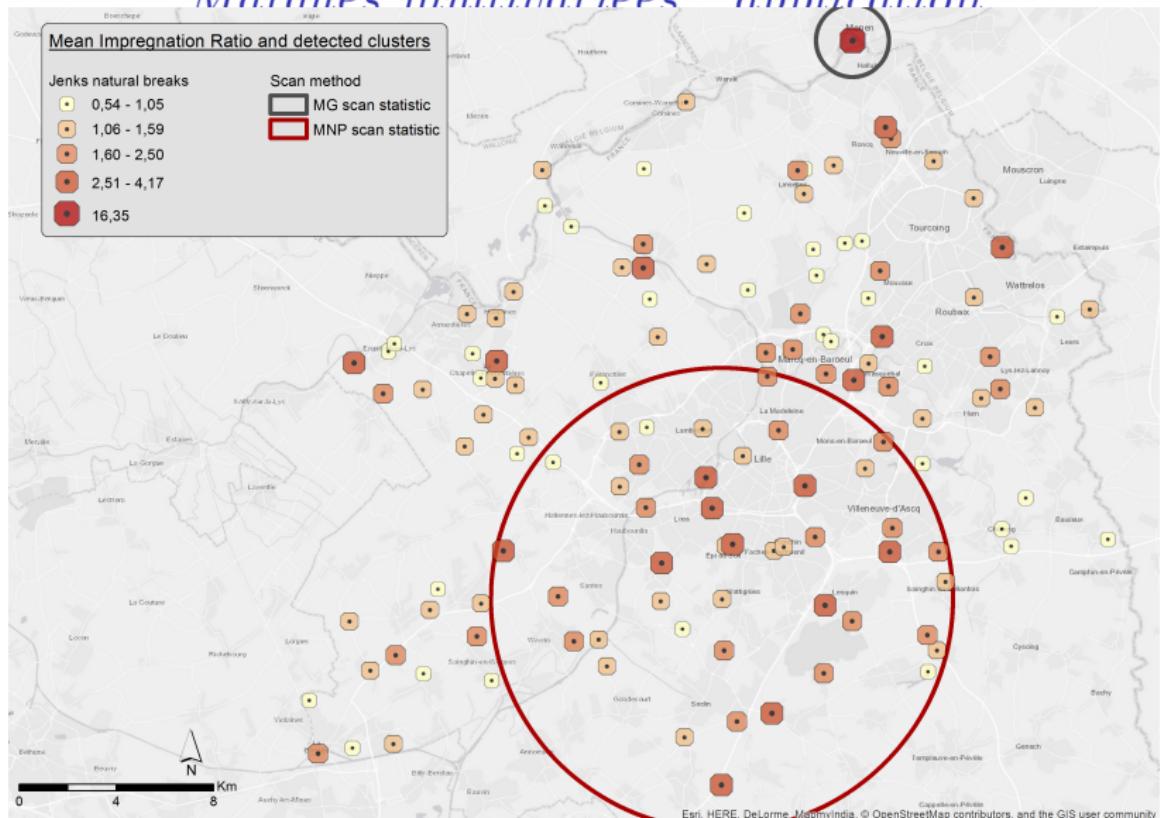
94

$$\left\{ \begin{array}{lcl} \bar{R}_Z & = & \frac{1}{n(Z)} \sum_{i=1}^n R_i \mathbf{1}_Z(s_i), \\ \\ c_x^2 & = & \sum_{i=1}^n R_i^T R_i. \end{array} \right.$$

- ▶ Si distributions dans Z et Z^c identiques : $U_{Z|Z^c}^2 \rightarrow \chi_p^2$.
 - ▶ Indice de concentration multivarié non-paramétrique :

$$I_{MNP}(Z) = U_Z^2|_{Z^c}.$$

Marmies multivariées · application



Processus marqué par une variable fonctionnelle

- ▶ Variable fonctionnelle X mesurée en chaque localisation.
- ▶ Observations : $(s_1, x_1), \dots, (s_n, x_n)$
où $x_i \in \chi$, espace fonctionnel.
- ▶ Objectif : trouver la zone où la distribution des marques est la plus "anormale".

Marques fonctionnelles : approche non-paramétrique

- ▶ Extension fonctionnelle du test de WMW proposée par Chakraborty et Chaudhuri (2015).
- ▶ Statistique de test :

$$T_{WMW}(Z) = \frac{1}{n(Z)n(Z^c)} \sum_{\{i:s_i \in Z\}} \sum_{\{j:s_j \in Z^c\}} \frac{X_j - X_i}{\|X_j - X_i\|_\chi}.$$

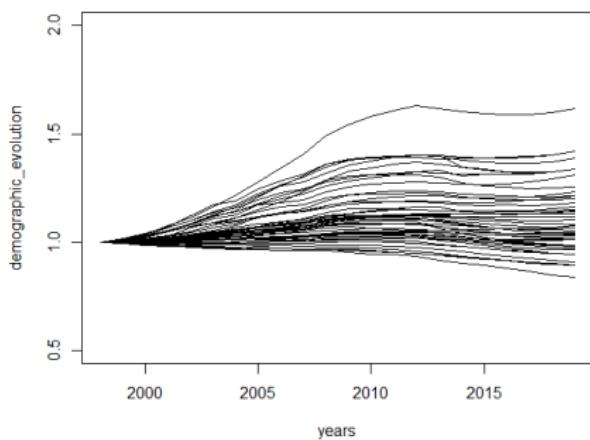
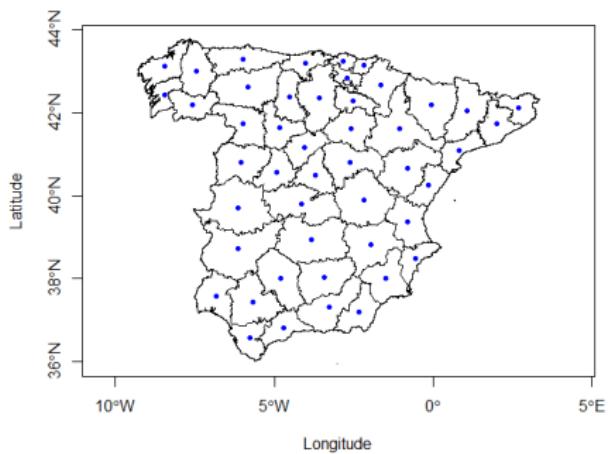
- ▶ Si distributions dans Z et Z^c identiques :

$$\tilde{T}_{WMW}(Z) = \sqrt{\frac{n(Z)n(Z^c)}{n}} T_{WMW}(Z) \text{ cv faiblement vers } G(0, \Gamma).$$

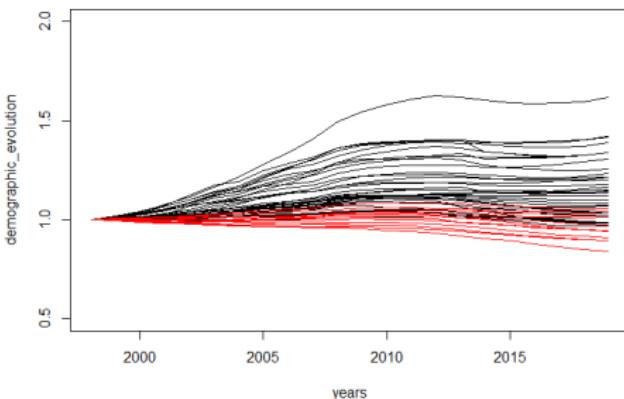
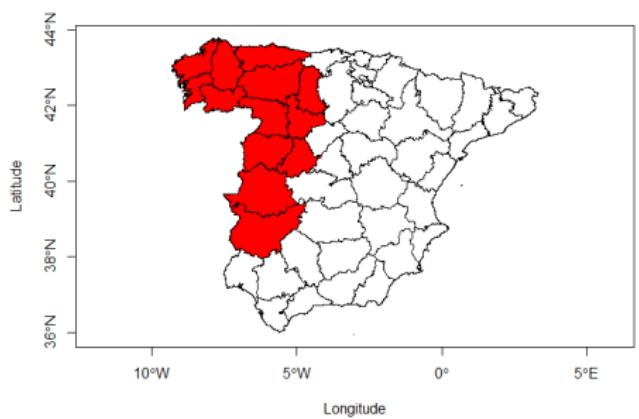
- ▶ Indice de concentration fonctionnel non-paramétrique :

$$I_{FNP}(Z) = \|\tilde{T}_{WMW}(Z)\|_\chi.$$

Marques fonctionnelles : application



Marques fonctionnelles : application



Publications associées

- ▶ Cucala, L., Genin, M., Lanier, C. et Occelli, F. (2017). A multivariate Gaussian scan statistic for spatial data. *Spatial Statistics*, 21, p. 66-74.
- ▶ Cucala, L., Genin, M., Occelli, F. et Soula, J. (2019). A multivariate nonparametric scan statistic for spatial data. *Spatial Statistics*, 29, p. 1-14.
- ▶ Smida, Z. Cucala, L., Durif, G. et Gannoun, A. (2021). A Wilcoxon-Mann-Whitney spatial scan statistic for functional data. *Computational Statistics and Data Analysis*, 167, 107378.

Sommaire

Introduction

1-Des agrégats potentiels originaux

2-Des indices de concentration alternatifs

3-Marques multivariées et fonctionnelles

Perspectives

Sommaire

Introduction

1-Des agrégats potentiels originaux

2-Des indices de concentration alternatifs

3-Marques multivariées et fonctionnelles

Perspectives

Processus marqué par une variable fonctionnelle

- ▶ Existence de deux statistiques de balayage pour données fonctionnelles :
 - une basée sur le test WMW (Smida et al., 2021).
 - une basée sur un test de type ANOVA (Frévent et al., 2021).
- ▶ Possibilités d'indices de concentration basés sur d'autres tests :
 - le test de Student fonctionnel de Horvath et al. (2013).
 - le test de la médiane de Smida et al. (2022).
- ▶ Enrichissement du package R HDSPatialScan.

Prise en compte de l'autocorrélation spatiale

- ▶ Les méthodes de balayage reposent sur une hypothèse d'indépendance .
- ▶ Hypothèse peu réaliste mais simplifie les calculs.
- ▶ Prise en compte de l'autocorrélation spatiale pour processus marqué par une variable continue : utilisation du modèle SAR.
- ▶ Difficultés pour estimer le paramètre d'autocorrélation spatiale.
- ▶ Alternative possible : le modèle SEM (Spatial Error Model).

Méthodes de balayage "global"

- ▶ Objectif : comparer les distributions de deux processus non marqués.
- ▶ Les statistiques de balayage classiques pointent la plus grande disparité entre les deux processus.
- ▶ Idée : utilisation d'un indice de concentration pour introduire une statistique de balayage " global".
- ▶ Première tentative : remplacer le maximum de l'indice de concentration par sa variance empirique.

Méthodes de balayage "double"

- ▶ Cadre : Processus marqué par une variable continue.
- ▶ Objectif : identifier la zone où les événements sont plus nombreux et les marques plus grandes.
- ▶ H_0 : localisation issues d'un processus de Poisson et marques i.i.d.
- ▶ Deux approches possibles :
 - paramétrique : indice de concentration basé sur un rapport de vraisemblance.
 - non-paramétrique : indice de concentration basé sur un test d'égalité entre Z et Z^c .

Publications associées

- ▶ Frévent, C., Ahmed, M.S., Soula, J., Smida, Z., Cucala, L., Dabo-Niang, S. et Genin, M. (2021). HDSpatialScan : Multivariate and Functional Spatial Scan Statistics.
- ▶ Ahmed, M.S. Cucala, L. et Genin, M. (2021). Spatial autoregressive models for scan statistic. *Journal of Spatial Econometrics*.
- ▶ Bonneau, F. et Cucala, L. (2021). Global scan methods for comparing two spatial point processes. In : Daouia A., Ruiz-Gazen A. (eds) *Advances in Contemporary Statistics and Econometrics*. Springer, Cham.
- ▶ Cucala, L. (2022). A double scan statistic for continuous data.