

Réduction de dimension en régression spatiale et prédiction spatiale

J.M. Loubes¹ et A.F. Yao²

¹Université Toulouse 3, Institut de Mathématiques de Toulouse.

²Université Aix-Marseille 2, Centre d'Océanologie de Marseille.

Motivations

- Estimation de la fonction de régression $m(\cdot)$:

$$Y = m(X) + \varepsilon,$$

$(Y, X) \in \mathbb{R} \times \mathbb{R}^d$ et ε erreur aléatoire.

\Rightarrow A partir d'observations spatialement dépendantes.

- Proposer un prédicteur spatial basé sur l'estimateur (de la régression) obtenu.

Motivations

- Estimation de la fonction de régression $m(\cdot)$:

$$Y = m(X) + \varepsilon,$$

$(Y, X) \in \mathbb{R} \times \mathbb{R}^d$ et ε erreur aléatoire.

\Rightarrow A partir d'observations spatialement dépendantes.

- Proposer un prédicteur spatial basé sur l'estimateur (de la régression) obtenu.

Motivations

.... plus précisément...

- Etendre les méthodes réduction de dimension au cas où les observations sont spatialement dépendantes.
- Proposer un prédicteur spatial basé sur le modèle de régression obtenu.

Réduction de dimension

... en Régression (i.i.d.)...

$$Y = m(X) + \varepsilon$$

- \implies la qualité de l'estimation non-paramétrique de la fonction $m(\cdot)$ est pénalisée par la dimension du régresseur

Modèle de réduction de dimension:

- \implies plusieurs solutions: la méthode de "Projection pursuit regression" (Friedman and Stuetzle, 1981), GAM, "General Additive Model" (Hastie et Tibshirani, 1986), ACE: Adevrage Component Estimation (Brieman et Friedman, 1985),...
- \implies SIR ("Sliced Inverse Regression"), Li(1991), OPG("Outer Product Gradient"), Hirstache et al(2001), MAVE("Minimum Average Variance Estimation".), Xia et al(2002)...

Réduction de dimension

... en Régression (i.i.d.)...

$$Y = m(X) + \varepsilon$$

- \implies la qualité de l'estimation non-paramétrique de la fonction $m(\cdot)$ est pénalisée par la dimension du régresseur

Modèle de réduction de dimension:

- \implies plusieurs solutions: la méthode de "Projection pursuit regression" (Friedman and Stuetzle, 1981), GAM, "General Additive Model" (Hastie et Tibshirani, 1986), ACE: Adevrage Component Estimation (Brieman et Friedman, 1985),...
- \implies SIR ("Sliced Inverse Regression"), Li(1991), OPG("Outer Product Gradient"), Hirstache et al(2001), MAVE("Minimum Average Variance Estimation".), Xia et al(2002)...

Réduction de dimension

... en Régression (i.i.d.)...

$$Y = m(X) + \varepsilon$$

- \implies la qualité de l'estimation non-paramétrique de la fonction $m(\cdot)$ est pénalisée par la dimension du régresseur

Modèle de réduction de dimension:

- \implies plusieurs solutions: la méthode de "Projection pursuit regression" (Friedman and Stuetzle, 1981), GAM, "General Additive Model" (Hastie et Tibshirani, 1986), ACE: Adevrage Component Estimation (Brieman et Friedman, 1985),...
- \implies SIR ("Sliced Inverse Regression"), Li(1991), OPG("Outer Product Gradient"), Hirstache et al(2001), MAVE("Minimum Average Variance Estimation".), Xia et al(2002)...

Modèle de réduction de dimension

... on suppose que ...

- on a

$$m(X) = g(\Phi.X)$$

- $g(.) : \mathbb{R}^D \rightarrow \mathbb{R}$, fonction inconnue, $\Phi : \mathbb{R}^d \rightarrow \mathbb{R}^D$, $D \leq d$.
- Φ , matrice normale ($\Phi^T \Phi = I_D$, Φ^T matrice orthogonale de Φ) à estimer.
- $g(.)$ pouvant être estimé par régression non-paramétrique de Y sur $\Phi.X$.
- L'espace de dimension D , $\text{Im}(\Phi^T)$,
 \implies appelé "Effective Dimension Reduction space" (EDR).

Modèle de réduction de dimension

... on suppose que ...

- on a

$$m(X) = g(\Phi.X)$$

- $g(.) : \mathbb{R}^D \rightarrow \mathbb{R}$, fonction inconnue, $\Phi : \mathbb{R}^d \rightarrow \mathbb{R}^D$, $D \leq d$.
- Φ , matrice normale ($\Phi^T \Phi = I_D$, Φ^T matrice orthogonale de Φ) à estimer.
- $g(.)$ pouvant être estimé par régression non-paramétrique de Y sur $\Phi.X$.
- L'espace de dimension D , $\text{Im}(\Phi^T)$,
 \implies appelé "Effective Dimension Reduction space" (EDR).

Modèle de réduction de dimension.

$$\dots m(X) = g(\Phi \cdot X) \dots$$

- Si (ϕ_1, \dots, ϕ_D) est une base de l'EDR,
- le modèle se résume par:
- \Leftrightarrow il suffit de D vecteurs de \mathbb{R}^d : ϕ_1, \dots, ϕ_D , pour estimer $m(X)$.
- \Rightarrow Modèle multi-indices: $m(x) = g(\phi_1'x, \dots, \phi_D'x)$.
- ...Ainsi, estimer l'espace l'EDR \Leftrightarrow
- estimer une base (ϕ_i) de l'EDR ...
- ...et sa dimension, D .
- Divers méthodes d'estimation de l'EDR. \implies La Régression Inverse.

Modèle de réduction de dimension.

$$\dots m(X) = g(\Phi \cdot X) \dots$$

- Si (ϕ_1, \dots, ϕ_D) est une base de l'EDR,
- le modèle se résume par:
- \Leftrightarrow il suffit de D vecteurs de \mathbb{R}^d : ϕ_1, \dots, ϕ_D , pour estimer $m(X)$.
- \Rightarrow Modèle multi-indices: $m(x) = g(\phi_1'x, \dots, \phi_D'x)$.
- ...Ainsi, estimer l'espace l'EDR \Leftrightarrow
- estimer une base (ϕ_i) de l'EDR ...
- ...et sa dimension, D .
- Divers méthodes d'estimation de l'EDR. \Rightarrow La Régression Inverse.

Modèle de réduction de dimension.

$$\dots m(X) = g(\Phi.X) \dots$$

- Si (ϕ_1, \dots, ϕ_D) est une base de l'EDR,
- le modèle se résume par:
- \Leftrightarrow il suffit de D vecteurs de \mathbb{R}^d : ϕ_1, \dots, ϕ_D , pour estimer $m(X)$.
- \Rightarrow Modèle multi-indices: $m(x) = g(\phi_1'x, \dots, \phi_D'x)$.
- ...Ainsi, estimer l'espace l'EDR \Leftrightarrow
- estimer une base (ϕ_i) de l'EDR ...
- ...et sa dimension, D .
- Divers méthodes d'estimation de l'EDR. \implies La Régression Inverse.

Modèle de réduction de dimension

... cadre général loi conditionnelle...

- Quantile conditionnelle: $Q(Y|X) = Q(Y|\Phi.X)$ (Gannoum et al. 2004),...
- Plus généralement:
- La loi de Y sachant X est la même que celle de Y sachant $\Phi.X$:

$$F(Y|X) = F(Y|\Phi.X)$$

- il suffit de D vecteurs de \mathbb{R}^d : ϕ_1, \dots, ϕ_D , pour entièrement connaître $Y|X$.

Modèle de réduction de dimension

... cadre général loi conditionnelle...

- Quantile conditionnelle: $Q(Y|X) = Q(Y|\Phi.X)$ (Gannoum et al. 2004),...
- Plus généralement:
- La loi de Y sachant X est la même que celle de Y sachant $\Phi.X$:

$$F(Y|X) = F(Y|\Phi.X)$$

- il suffit de D vecteurs de \mathbb{R}^d : ϕ_1, \dots, ϕ_D , pour entièrement connaître $Y|X$.

Estimation de l'EDR

... par la régression inverse...

- **Condition.** (Li, 1991) $\forall b \in \mathbf{R}^p$, $E(b'X | \phi_1'X, \dots, \phi_K'X)$ est une combinaison linéaire des $\phi_i'X$.

Théorème. (Li, 1991) L'EDR contient le sous-espace propre associé aux valeurs propres non-nulles de $\Sigma^{-1}\mathbf{var}(E(X|Y))$ ($\Sigma = \mathbf{var}(X)$).

- \implies Si $\Sigma^{-1}\mathbf{var}(E(X|Y))$ est de plein rang,
- \implies l'estimation de l'EDR s'obtient par diagonalisation d'un estimateur de la matrice $\Sigma^{-1}\mathbf{var}(E(X|Y))$.

Estimation de l'EDR (cas i.i.d.)

... par estimation de $\Sigma^{-1}\text{var}(E(X|Y))...$

- Estimation de Σ par estimateur empirique.
- Estimation de **var**($E(X|Y)$)
 - par régressogramme de $E(X|Y)$
 - \Rightarrow SIR(Li, 1991): “Sliced Inverse Regression”
 - par méthode à noyau de $E(X|Y)$
 - \Rightarrow (Fang and Zu, 1997): “kernel inverse regression”

Estimation de l'EDR (cadre i.i.d.)

... alternatives la régression inverse...

Quid: lorsque $\Sigma^{-1}\text{var}(E(X|Y))$ n'est pas de plein rang?... voir dégénérée?

- SIR II (Li, 1991), SIR- α Saracco(1999,...) moment d'ordre ≥ 2 , PHD (Li, 1992) : la matrice hessienne de la fonction $g(\cdot), (m(x) = g(\phi_1'x, \dots, \phi_D'x))$.
- MAVE, OPG (Hirstache et al; 2001,...) développement de Taylor de $g(\cdot)$.

Problème d'estimation de Σ^{-1} en grande dimension.

- Réduction de dimension en régression en dimension infinie Ferré and Yao (2005), Amato, Feiss et Antoniadis (2006), Cook et al (2007, 2008), Bernard-Michel, Gardes and Girard(2008)...

Estimation de l'EDR (cadre i.i.d.)

... alternatives la régression inverse...

Quid: lorsque $\Sigma^{-1}\text{var}(E(X|Y))$ n'est pas de plein rang?... voir dégénérée?

- SIR II (Li, 1991), SIR- α Saracco(1999,...) moment d'ordre ≥ 2 , PHD (Li, 1992) : la matrice hessienne de la fonction $g(\cdot), (m(x) = g(\phi_1'x, \dots, \phi_D'x))$.
- MAVE, OPG (Hirstache et al; 2001,...) développement de Taylor de $g(\cdot)$.

Problème d'estimation de Σ^{-1} en grande dimension.

- Réduction de dimension en régression en dimension infinie Ferré and Yao (2005), Amato, Feiss et Antoniadis (2006), Cook et al (2007, 2008), Bernard-Michel, Gardes and Girard(2008)...

Estimation de l'EDR

- L'estimation du modèle de réduction de dimension
⇒ a été étudié dans le cadre i.i.d.
- Que devient cet estimation par régression inverse
⇒ dans le cas de dépendance spatiale?

Régression spatiale

⇒ Estimation de la fonction de régression $m(\cdot)$:

$$Y = m(X) + \varepsilon,$$

⇒ A partir d'observations spatialement.

Régression spatiale, prédiction spatiale

- Estimation paramétrique: large littérature surtout en géostatistique, krigeage (Cressie; 1993, Wackernagel; 1995, ...), krigeage,...
- Moins de résultats dans un cadre non-paramétrique:

Régression et prédiction non-paramétrique: Lu & Chen (2004), Biau & Cadre (2004), Dabo-Niang & Yao (2007).

⇒ Estimateur étudié est une extension de l'estimateur à noyau du cas i.i.d.

⇒ Sa vitesse de convergence est également pénalisée par la dimension du régresseur: $h^k + \left(\frac{\log n}{nh_n^d}\right)^{1/2}$

Régression spatiale, prédiction spatiale

- Estimation paramétrique: large littérature surtout en géostatistique, krigeage (Cressie; 1993, Wackernagel; 1995, ...), krigeage,...
- Moins de résultats dans un cadre non-paramétrique:

Régression et prédiction non-paramétrique: Lu & Chen (2004), Biau & Cadre (2004), Dabo-Niang & Yao (2007).

⇒ Estimateur étudié est une extension de l'estimateur à noyau du cas i.i.d.

⇒ Sa vitesse de convergence est également pénalisée par la dimension du régresseur: $h^k + \left(\frac{\log n}{nh_n^d}\right)^{1/2}$

Régression spatiale, prédiction spatiale

- Estimation paramétrique: large littérature surtout en géostatistique, krigeage (Cressie; 1993, Wackernagel; 1995, ...), krigeage,...
- Moins de résultats dans un cadre non-paramétrique:

Régression et prédiction non-paramétrique: Lu & Chen (2004), Biau & Cadre (2004), Dabo-Niang & Yao (2007).

⇒ Estimateur étudié est une extension de l'estimateur à noyau du cas i.i.d.

⇒ Sa vitesse de convergence est également pénalisée par la dimension du régresseur: $h^k + \left(\frac{\log n}{nh_n^d}\right)^{1/2}$

Réduction de dimension

... en régression spatiale...

- Objectif: Etendre les méthodes d'estimation (en regression inverse) au cadre spatiale.
- Que devient l'estimation de l'EDR? $\implies \Sigma^{-1} \text{var}(E(X|Y))?$

Réduction de dimension

... en régression spatiale...

- Objectif: Etendre les méthodes d'estimation (en regression inverse) au cadre spatiale.
- Que devient l'estimation de l'EDR? $\implies \Sigma^{-1} \mathbf{var}(E(X|Y))?$

Notations

- $\mathbf{n} = (n_1, \dots, n_N) \implies \mathcal{I}_{\mathbf{n}} = \{i \in \mathbb{Z}^N : 1 \leq i_k \leq n_k, k = 1, \dots, N\}$.
- On dira que $\mathbf{n} \rightarrow +\infty$ si $\min_{i=1, \dots, N} n_i \rightarrow +\infty$ et $|n_i/n_k| < C$, $C > 0$.
- $\hat{\mathbf{n}} = n_1 \times \dots \times n_N$.

\implies Estimation de $\Sigma^{-1} \mathbf{var}(E(X|Y))$ à partir des observations:

$$(Z_i, i \in \mathcal{I}_{\mathbf{n}}), Z_i = (X_i, Y_i).$$

Notations

- $\mathbf{n} = (n_1, \dots, n_N) \implies \mathcal{I}_{\mathbf{n}} = \{\mathbf{i} \in \mathbb{Z}^N : 1 \leq i_k \leq n_k, k = 1, \dots, N\}$.
- On dira que $\mathbf{n} \rightarrow +\infty$ si $\min_{i=1, \dots, N} n_i \rightarrow +\infty$ et $|n_i/n_k| < C$, $C > 0$.
- $\hat{\mathbf{n}} = n_1 \times \dots \times n_N$.

\implies Estimation de $\Sigma^{-1} \mathbf{var}(E(X|Y))$ à partir des observations:

$$(Z_{\mathbf{i}}, \mathbf{i} \in \mathcal{I}_{\mathbf{n}}), Z_{\mathbf{i}} = (X_{\mathbf{i}}, Y_{\mathbf{i}}).$$

Estimateur en régression inverse

....cadre spatial...

On construit l'estimateur:

$$r_n(y) = \frac{\varphi_n(y)}{f_n(y)}, y \in \mathbb{R}$$

avec $f_n(y) = \frac{1}{\hat{n}h_n} \sum_{\mathbf{i} \in \mathcal{I}_n} K\left(\frac{y - Y_i}{h_n}\right)$ et $\varphi_n(y) = \frac{1}{\hat{n}h_n} \sum_{\mathbf{i} \in \mathcal{I}_n} X_i K\left(\frac{y - Y_i}{h_n}\right)$

où $\lim_{n \rightarrow +\infty} h_n = 0 (+)$ and $K : \mathbb{R}^d \rightarrow \mathbb{R}$ est un noyau.

Pour éviter les valeurs trop petite de f_n , on choisit de travailler avec:

$r_{e,n}(y) = \frac{\varphi_n(y)}{f_{e,n}(y)}$ où $f_{e,n}(y) = \max(e_n, f_n(y))$ et $\lim_{n \rightarrow \infty} e_n = 0$.

On construit l'estimateur de $\mathbf{Var}(\mathbf{E}(X|Y))$:

$$\Sigma_{e,n} = \frac{1}{\hat{n}} \sum r_{e,n}(Y_i) r_{e,n}(Y_i)^T - \bar{X} \bar{X}^T.$$

Mesure de dépendance spatiale

....Hypothèses...

- Condition de mélange:

$$\alpha(v) = \sup_{\mathbf{u}, \mathbf{u}' \in \mathbb{R}^N, \|\mathbf{u} - \mathbf{u}'\| = v} \alpha(\sigma(Z_{\mathbf{u}}), \sigma(Z_{\mathbf{u}'})), \quad v \geq 0,$$

où pour \mathcal{B} et \mathcal{C} deux sous σ -algèbre de \mathcal{A} ,

$$\alpha(\mathcal{B}, \mathcal{C}) = \sup_{B \in \mathcal{B}, C \in \mathcal{C}} |P(B \cap C) - P(B)P(C)|.$$

$$\lim_{u \rightarrow \infty} \alpha(u) = 0.$$

- Dépendance locale : Pour $\ell = 1, \dots, d$, il existe $\Delta > 0$ tel que pour tout $(X_i^{(\ell)}, X_j)$ et $((X_i^{(\ell)}, Y_i), (X_j^{(\ell)}, Y_j))$ tel que $\text{dist}(\mathbf{i}, \mathbf{j}) > \Delta$ et de densités $f_{i,j}$ et $g_{i,j}$ alors

$$|f_{i,j}(x, y) - f(x)f(y)| \leq C, \quad \forall x, y \in \mathbb{R}$$

$$|g_{i,j}(u, v) - g(u)g(v)| \leq C, \quad \forall u, v \in \mathbb{R}^2$$

Mesure de dépendance spatiale

....Hypothèses...

- Condition de mélange:

$$\alpha(v) = \sup_{\mathbf{u}, \mathbf{u}' \in \mathbb{R}^N, \|\mathbf{u} - \mathbf{u}'\| = v} \alpha(\sigma(Z_{\mathbf{u}}), \sigma(Z_{\mathbf{u}'})), \quad v \geq 0,$$

où pour \mathcal{B} et \mathcal{C} deux sous σ -algèbre de \mathcal{A} ,

$$\alpha(\mathcal{B}, \mathcal{C}) = \sup_{B \in \mathcal{B}, C \in \mathcal{C}} |P(B \cap C) - P(B)P(C)|.$$

$$\lim_{u \rightarrow \infty} \alpha(u) = 0.$$

- Dépendance locale : Pour $\ell = 1, \dots, d$, il existe $\Delta > 0$ tel que pour tout $(X_i^{(\ell)}, X_j)$ et $((X_i^{(\ell)}, Y_i), (X_j^{(\ell)}, Y_j))$ tel que $\text{dist}(\mathbf{i}, \mathbf{j}) > \Delta$ et de densités $f_{i,j}$ et $g_{i,j}$ alors

$$|f_{i,j}(x, y) - f(x)f(y)| \leq C, \quad \forall x, y \in \mathbb{R}$$

$$|g_{i,j}(u, v) - g(u)g(v)| \leq C, \quad \forall u, v \in \mathbb{R}^2$$

Estimateur à noyau de la régression

....cadre spatial...

Etudier par Carbon et al. (1997) Lu & Chen (2004), Biau & Cadre (2004), Dabo & Yao (2007)

Sous certaines hypothèses.

Théorème.

$$\sup_{y \in \mathbb{R}} |f_n(y) - f(y)| = \mathcal{O}_p \left(h_n^k + \frac{\sqrt{\log \hat{n}}}{\sqrt{\hat{n} h_n}} \right),$$

$\sup_{y \in \mathbb{R}} \|\varphi_n(y) - \varphi(y)\| = \mathcal{O}_p \left(h_n^k + \frac{\sqrt{\log \hat{n}}}{\sqrt{\hat{n} h_n}} \right)$ avec k entier lié à la régularité des fonction f et φ .

Estimateur à noyau de la régression

....cadre spatial...

Etudier par Carbon et al. (1997) Lu & Chen (2004), Biau & Cadre (2004), Dabo & Yao (2007)

Sous certaines hypothèses.

Théorème.

$$\sup_{y \in \mathbb{R}} |f_n(y) - f(y)| = \mathcal{O}_p \left(h_n^k + \frac{\sqrt{\log \hat{n}}}{\sqrt{\hat{n} h_n}} \right),$$

$\sup_{y \in \mathbb{R}} \|\varphi_n(y) - \varphi(y)\| = \mathcal{O}_p \left(h_n^k + \frac{\sqrt{\log \hat{n}}}{\sqrt{\hat{n} h_n}} \right)$ avec k entier lié à la régularité des fonction f et φ .

Estimateur de EDR

... Estimation de $\Sigma_e = \text{var}(\mathbf{E}X|Y)$...

Sous certaines conditions:

Théorème: si $\alpha(t) \leq Ct^{-\theta}$, $t > 0$, $\theta > 2N$ et si $\hat{n}h_n^3(\log \hat{n})^{-1} \rightarrow 0$, $\hat{n}h_n^{\theta_1}(\log \hat{n})^{-1} \rightarrow \infty$ avec $\theta_1 = \frac{4N+\theta}{\theta-2N}$, alors:

$$\Sigma_{e,n} - \Sigma_e = \mathcal{O}_p \left(e_n + h_n^k + \frac{\Psi_n^2}{e_n^2} \right)$$

Corollaire: Prennant $h \simeq \hat{n}^{-c_1}$, $e_n \simeq \hat{n}^{-c_2}$ pour des c_1 et c_2 tel que $\frac{c_2}{k} + \frac{1}{2k} < c_1 < \frac{1}{4} - c_2$, on a:

$$\Sigma_{e,n} - \Sigma_e = o_p \left(\frac{1}{\sqrt{\hat{n}}} \right) \text{ et } \sqrt{\hat{n}} (\Sigma_{e,n} - \Sigma_e) \xrightarrow{\mathcal{L}} \Lambda.$$

- Et par conséquent vitesse similaire pour $\Sigma_n^{-1} \Sigma_{e,n}$ tant que la dimension du régresseur reste raisonnable.

Predicteur spatial.

Soit $(\xi_{\mathbf{n}}, \mathbf{n} \in (\mathbb{N}^*)^N)$, $\xi_{\mathbf{n}} \in \mathbb{R}$, stationnaire et observé dans $\mathcal{O}_{\mathbf{n}} \subset \mathcal{I}_{\mathbf{n}}$

- Objectif: prédire la valeur ξ_{i_0} , en $i_0 \in \mathcal{I}_{\mathbf{n}} \setminus \mathcal{O}_{\mathbf{n}}$.
- On suppose que: ξ_{i_0} ne dépend que des valeurs ξ_i , $i \in \mathcal{V}_{i_0}$, $\mathcal{V}_{i_0} \subset \mathcal{O}_{\mathbf{n}}$
- Meilleur prédicteur de ξ_{i_0} au sens des moindres carré: $E(\xi_{i_0} | \xi_i, i \in \mathcal{V}_{i_0})$.

\implies Prédiction à partir d'une **estimation** de $E(\xi_{i_0} | \xi_i, i \in \mathcal{V}_{i_0})$.

Predicteur spatial.

Soit $(\xi_{\mathbf{n}}, \mathbf{n} \in (\mathbb{N}^*)^N)$, $\xi_{\mathbf{n}} \in \mathbb{R}$, stationnaire et observé dans $\mathcal{O}_{\mathbf{n}} \subset \mathcal{I}_{\mathbf{n}}$

- Objectif: prédire la valeur $\xi_{\mathbf{i}_0}$, en $\mathbf{i}_0 \in \mathcal{I}_{\mathbf{n}} \setminus \mathcal{O}_{\mathbf{n}}$.
- On suppose que: $\xi_{\mathbf{i}_0}$ ne dépend que des valeurs $\xi_{\mathbf{i}}$, $\mathbf{i} \in \mathcal{V}_{\mathbf{i}_0}$, $\mathcal{V}_{\mathbf{i}_0} \subset \mathcal{O}_{\mathbf{n}}$
- Meilleur prédicteur de $\xi_{\mathbf{i}_0}$ au sens des moindres carré: $E(\xi_{\mathbf{i}_0} | \xi_{\mathbf{i}}, \mathbf{i} \in \mathcal{V}_{\mathbf{i}_0})$.

\implies Prédiction à partir d'une **estimation** de $E(\xi_{\mathbf{i}_0} | \xi_{\mathbf{i}}, \mathbf{i} \in \mathcal{V}_{\mathbf{i}_0})$.

Predicteur spatial.

Soit $(\xi_{\mathbf{n}}, \mathbf{n} \in (\mathbb{N}^*)^N)$, $\xi_{\mathbf{n}} \in \mathbb{R}$, stationnaire et observé dans $\mathcal{O}_{\mathbf{n}} \subset \mathcal{I}_{\mathbf{n}}$

- Objectif: prédire la valeur $\xi_{\mathbf{i}_0}$, en $\mathbf{i}_0 \in \mathcal{I}_{\mathbf{n}} \setminus \mathcal{O}_{\mathbf{n}}$.
- On suppose que: $\xi_{\mathbf{i}_0}$ ne dépend que des valeurs $\xi_{\mathbf{i}}, \mathbf{i} \in \mathcal{V}_{\mathbf{i}_0}$, $\mathcal{V}_{\mathbf{i}_0} \subset \mathcal{O}_{\mathbf{n}}$
- Meilleur prédicteur de $\xi_{\mathbf{i}_0}$ au sens des moindres carré: $E(\xi_{\mathbf{i}_0} | \xi_{\mathbf{i}}, \mathbf{i} \in \mathcal{V}_{\mathbf{i}_0})$.

\implies Prédiction à partir d'une **estimation** de $E(\xi_{\mathbf{i}_0} | \xi_{\mathbf{i}}, \mathbf{i} \in \mathcal{V}_{\mathbf{i}_0})$.

Predicteur spatial.

Soit $(\xi_{\mathbf{n}}, \mathbf{n} \in (\mathbb{N}^*)^N)$, $\xi_{\mathbf{n}} \in \mathbb{R}$, stationnaire et observé dans $\mathcal{O}_{\mathbf{n}} \subset \mathcal{I}_{\mathbf{n}}$

- Objectif: prédire la valeur $\xi_{\mathbf{i}_0}$, en $\mathbf{i}_0 \in \mathcal{I}_{\mathbf{n}} \setminus \mathcal{O}_{\mathbf{n}}$.
- On suppose que: $\xi_{\mathbf{i}_0}$ ne dépend que des valeurs $\xi_{\mathbf{i}}, \mathbf{i} \in \mathcal{V}_{\mathbf{i}_0}$, $\mathcal{V}_{\mathbf{i}_0} \subset \mathcal{O}_{\mathbf{n}}$
- Meilleur prédicteur de $\xi_{\mathbf{i}_0}$ au sens des moindres carré: $E(\xi_{\mathbf{i}_0} | \xi_{\mathbf{i}}, \mathbf{i} \in \mathcal{V}_{\mathbf{i}_0})$.

\implies Prédiction à partir d'une **estimation** de $E(\xi_{\mathbf{i}_0} | \xi_{\mathbf{i}}, \mathbf{i} \in \mathcal{V}_{\mathbf{i}_0})$.

Predicteur spatial.

Soit $(\xi_{\mathbf{n}}, \mathbf{n} \in (\mathbb{N}^*)^N)$, $\xi_{\mathbf{n}} \in \mathbb{R}$, stationnaire et observé dans $\mathcal{O}_{\mathbf{n}} \subset \mathcal{I}_{\mathbf{n}}$

- Objectif: prédire la valeur $\xi_{\mathbf{i}_0}$, en $\mathbf{i}_0 \in \mathcal{I}_{\mathbf{n}} \setminus \mathcal{O}_{\mathbf{n}}$.
- On suppose que: $\xi_{\mathbf{i}_0}$ ne dépend que des valeurs $\xi_{\mathbf{i}}, \mathbf{i} \in \mathcal{V}_{\mathbf{i}_0}$, $\mathcal{V}_{\mathbf{i}_0} \subset \mathcal{O}_{\mathbf{n}}$
- Meilleur prédicteur de $\xi_{\mathbf{i}_0}$ au sens des moindres carré: $E(\xi_{\mathbf{i}_0} | \xi_{\mathbf{i}}, \mathbf{i} \in \mathcal{V}_{\mathbf{i}_0})$.

\implies Prédiction à partir d'une **estimation** de $E(\xi_{\mathbf{i}_0} | \xi_{\mathbf{i}}, \mathbf{i} \in \mathcal{V}_{\mathbf{i}_0})$.

Predicteur spatial.

Soit $(\xi_{\mathbf{n}}, \mathbf{n} \in (\mathbb{N}^*)^N)$, $\xi_{\mathbf{n}} \in \mathbb{R}$, stationnaire et observé dans $\mathcal{O}_{\mathbf{n}} \subset \mathcal{I}_{\mathbf{n}}$

- Pose: $d = \text{card}\{\mathcal{V}\}$, $\xi_{i_0}^d = (\xi_i, i \in \mathcal{V}_{i_0})$.
- Le problème de prédiction \iff estimation de $m(x) = E(\xi_{i_0} | \xi_{i_0}^d = x)$.
- Cas linéaire \implies Krigage (Cressie; 1991, Wackernagel; 1995),
- Cas non paramétrique Biau et Cadre (2004),
- \implies Application de la méthode précédente pour estimer $m(x) = g(\Phi.X)$.
- Permet d'estimer le nombre de voisins intéressant à la prédiction car puisque le processus est supposé markovien, la régression inverse: $r(y) = \mathbf{E}(\xi_{i_0}^d | \xi_{i_0} = y)$ permettra d'éliminer les éléments du voisinage (choisi) indépendants de ξ_{i_0} . Nous proposons un algorithme permettant de le faire.

Predicteur spatial.

Soit $(\xi_{\mathbf{n}}, \mathbf{n} \in (\mathbb{N}^*)^N)$, $\xi_{\mathbf{n}} \in \mathbb{R}$, stationnaire et observé dans $\mathcal{O}_{\mathbf{n}} \subset \mathcal{I}_{\mathbf{n}}$

- Pose: $d = \text{card}\{\mathcal{V}\}$, $\xi_{i_0}^d = (\xi_i, i \in \mathcal{V}_{i_0})$.
- Le problème de prédiction \iff estimation de $m(x) = E(\xi_{i_0} | \xi_{i_0}^d = x)$.
- Cas linéaire \implies Krigage (Cressie; 1991, Wackernagel; 1995),
- Cas non paramétrique Biau et Cadre (2004),
- \implies Application de la méthode précédente pour estimer $m(x) = g(\Phi.X)$.
- Permet d'estimer le nombre de voisins intéressant à la prédiction car puisque le processus est supposé markovien, la régression inverse: $r(y) = \mathbf{E}(\xi_{i_0}^d | \xi_{i_0} = y)$ permettra d'éliminer les éléments du voisinage (choisi) indépendants de ξ_{i_0} . Nous proposons un algorithme permettant de le faire.

Predicteur spatial.

Soit $(\xi_{\mathbf{n}}, \mathbf{n} \in (\mathbb{N}^*)^N)$, $\xi_{\mathbf{n}} \in \mathbb{R}$, stationnaire et observé dans $\mathcal{O}_{\mathbf{n}} \subset \mathcal{I}_{\mathbf{n}}$

- Pose: $d = \text{card}\{\mathcal{V}\}$, $\xi_{i_0}^d = (\xi_i, i \in \mathcal{V}_{i_0})$.
- Le problème de prédiction \iff estimation de $m(x) = E(\xi_{i_0} | \xi_{i_0}^d = x)$.
- Cas linéaire \implies Krigage (Cressie; 1991, Wackernagel; 1995),
- Cas non paramétrique Biau et Cadre (2004),
- \implies Application de la méthode précédente pour estimer $m(x) = g(\Phi.X)$.
- Permet d'estimer le nombre de voisins intéressant à la prédiction car puisque le processus est supposé markovien, la régression inverse: $r(y) = E(\xi_{i_0}^d | \xi_{i_0} = y)$ permettra d'éliminer les éléments du voisinage (choisi) indépendants de ξ_{i_0} . Nous proposons un algorithme permettant de le faire.

Predicteur spatial.

Soit $(\xi_{\mathbf{n}}, \mathbf{n} \in (\mathbb{N}^*)^N)$, $\xi_{\mathbf{n}} \in \mathbb{R}$, stationnaire et observé dans $\mathcal{O}_{\mathbf{n}} \subset \mathcal{I}_{\mathbf{n}}$

- Pose: $d = \text{card}\{\mathcal{V}\}$, $\xi_{i_0}^d = (\xi_i, i \in \mathcal{V}_{i_0})$.
- Le problème de prédiction \iff estimation de $m(x) = E(\xi_{i_0} | \xi_{i_0}^d = x)$.
- Cas linéaire \implies Krigage (Cressie; 1991, Wackernagel; 1995),
- Cas non paramétrique Biau et Cadre (2004),
- \implies Application de la méthode précédente pour estimer $m(x) = g(\Phi.X)$.
- Permet d'estimer le nombre de voisins intéressant à la prédiction car puisque le processus est supposé markovien, la régression inverse: $r(y) = E(\xi_{i_0}^d | \xi_{i_0} = y)$ permettra d'éliminer les éléments du voisinage (choisi) indépendants de ξ_{i_0} . Nous proposons un algorithme permettant de le faire.

Predicteur spatial.

Soit $(\xi_{\mathbf{n}}, \mathbf{n} \in (\mathbb{N}^*)^N)$, $\xi_{\mathbf{n}} \in \mathbb{R}$, stationnaire et observé dans $\mathcal{O}_{\mathbf{n}} \subset \mathcal{I}_{\mathbf{n}}$

- Pose: $d = \text{card}\{\mathcal{V}\}$, $\xi_{i_0}^d = (\xi_i, i \in \mathcal{V}_{i_0})$.
- Le problème de prédiction \iff estimation de $m(x) = E(\xi_{i_0} | \xi_{i_0}^d = x)$.
- Cas linéaire \implies Krigage (Cressie; 1991, Wackernagel; 1995),
- Cas non paramétrique Biau et Cadre (2004),
- \implies Application de la méthode précédente pour estimer $m(x) = g(\Phi.X)$.
- Permet d'estimer le nombre de voisins intéressant à la prédiction car puisque le processus est supposé markovien, la régression inverse: $r(y) = \mathbf{E}(\xi_{i_0}^d | \xi_{i_0} = y)$ permettra d'éliminer les éléments du voisinage (choisi) indépendants de ξ_{i_0} . Nous proposons un algorithme permettant de le faire.

Predicteur spatial.

Soit $(\xi_n, \mathbf{n} \in (\mathbb{N}^*)^N)$, $\xi_n \in \mathbb{R}$, stationnaire et observé dans $\mathcal{O}_n \subset \mathcal{I}_n$

- Pose: $d = \text{card}\{\mathcal{V}\}$, $\xi_{i_0}^d = (\xi_i, i \in \mathcal{V}_{i_0})$.
- Le problème de prédiction \iff estimation de $m(x) = E(\xi_{i_0} | \xi_{i_0}^d = x)$.
- Cas linéaire \implies Krigage (Cressie; 1991, Wackernagel; 1995),
- Cas non paramétrique Biau et Cadre (2004),
- \implies Application de la méthode précédente pour estimer $m(x) = g(\Phi.X)$.
- Permet d'estimer le nombre de voisins intéressant à la prédiction car puisque le processus est supposé markovien, la régression inverse: $r(y) = \mathbf{E}(\xi_{i_0}^d | \xi_{i_0} = y)$ permettra d'éliminer les éléments du voisinage (choisi) indépendants de ξ_{i_0} . Nous proposons un algorithme permettant de le faire.

Perspectives

- Applications sur des données.
- Continuer cette extension en regardant les alternatives: les problèmes en grande dimension.
 - comme alternative Régression fonctionnelle spatial (Dabo-Niang, Rachdi & Yao, 2008).
- Le cadre spatial continu.

Merci de votre attention!

Perspectives

- Applications sur des données.
- Continuer cette extension en regardant les alternatives: les problèmes en grande dimension.
 - comme alternative Régression fonctionnelle spatial (Dabo-Niang, Rachdi & Yao, 2008).
- Le cadre spatial continu.

Merci de votre attention!

Algorithm for estimation of d , the number of neighbors.

1. Initialization: specify a parameter $\delta > 0$ (small) and fix a site \mathbf{j}_0 ; set $k = 1$.

2. compute $r_{\mathbf{n}}^{(k)}(y) = \frac{\sum_{\mathbf{i} \in \mathcal{O}_{\mathbf{n}}, \mathcal{V}_{\mathbf{j}_0} \subset \mathcal{O}_{\mathbf{n}}} \xi_{\mathbf{i}}^{(k)} K_{h_{\mathbf{n}}}(y - \xi_{\mathbf{i}})}{\sum_{\mathbf{i} \in \mathcal{O}_{\mathbf{n}}, \mathcal{V}_{\mathbf{j}_0} \subset \mathcal{O}_{\mathbf{n}}} K_{h_{\mathbf{n}}}(y - \xi_{\mathbf{i}})}$, the kernel estimate of $r^{(k)}(y) = \mathbf{E}(X^{(k)} | Y = y)$

3. if $|(r_{\mathbf{n}}^{(k)}(y))| > \delta$, then $k = k + 1$ and continue with Step 2; otherwise terminate and $d = k$.

Then, we can compute a predictor based on $d = k$:

The dimension reduction predictor

To get the predictor, we suggest the following algorithm:

1. compute

$$r_n^*(y) = \frac{\sum_{i \in \mathcal{O}_n, \mathcal{Y}_{i_0} \subset \mathcal{O}_n} \xi_i^d K_{h_n}(y - \xi_i)}{\sum_{i \in \mathcal{O}_n, \mathcal{Y}_{i_0} \subset \mathcal{O}_n} K_{h_n}(y - \xi_i)}$$

2. compute

$$\Sigma_{e,n} = \frac{1}{\hat{n}} \sum_{i \in \mathcal{O}_n, \mathcal{Y}_{i_0} \subset \mathcal{O}_n} r_{e,n}^*(Y_i) r_{e,n}^*(Y_i)^T - \bar{X} \bar{X}^T.$$

3. Do the PCA of $\Sigma_n^{-1} \Sigma_{e,n}$ both to get a basis of $\text{Im}(\Sigma_n^{-1} \Sigma_{e,n})$ and estimation of the D , the dimension of $\text{Im}(\Phi)$ as suggested in the next remark
4. compute the predictor:

$$\hat{\xi}_{i_0} = g_n^*(\Phi_n^* \cdot X_{i_0}).$$

based on data $(Z_i, i \in \mathcal{O}_n)$; where g_n^* is the kernel estimate: