

Processus stationnaires sur des graphes

Thibault Espinasse

Université Paul Sabatier

6 mai 2010, JPS, Mont-Dore

Plan de l'exposé

- 1 Introduction
- 2 Modèle
- 3 Application : Maximum de vraisemblance

Table des Matières

- 1 Introduction
- 2 Modèle
- 3 Application : Maximum de vraisemblance

Origine du problème

Traffic routier : Prédire en temps réel des temps de parcours

- Capteurs sur la route : défaillance
- Données localisation GPS, téléphones : non homogènes
- **But** : Reconstituer les données

Actuellement : Pas d'exploitation de dépendance spatiale ni temporelle (Régression...)

Objectif

Proposer un modèle statique utilisant la dépendance spatiale, et des outils simples.

Origine du problème

Traffic routier : Prédire en temps réel des temps de parcours

- Capteurs sur la route : défaillance
- Données localisation GPS, téléphones : non homogènes
- **But** : Reconstituer les données

Actuellement : Pas d'exploitation de dépendance spatiale ni temporelle (Régression...)

Objectif

Proposer un modèle statique utilisant la dépendance spatiale, et des outils simples.

Origine du problème

Traffic routier : Prédire en temps réel des temps de parcours

- Capteurs sur la route : défaillance
- Données localisation GPS, téléphones : non homogènes
- **But** : Reconstituer les données

Actuellement : Pas d'exploitation de dépendance spatiale ni temporelle (Régression...)

Objectif

Proposer un modèle statique utilisant la dépendance spatiale, et des outils simples.

Origine du problème

Traffic routier : Prédire en temps réel des temps de parcours

- Capteurs sur la route : défaillance
- Données localisation GPS, téléphones : non homogènes
- **But** : Reconstituer les données

Actuellement : Pas d'exploitation de dépendance spatiale ni temporelle (Régression...)

Objectif

Proposer un modèle statique utilisant la dépendance spatiale, et des outils simples.

Origine du problème

Traffic routier : Prédire en temps réel des temps de parcours

- Capteurs sur la route : défaillance
- Données localisation GPS, téléphones : non homogènes
- **But** : Reconstituer les données

Actuellement : Pas d'exploitation de dépendance spatiale ni temporelle (Régression...)

Objectif

Proposer un modèle statique utilisant la dépendance spatiale, et des outils simples.

Origine du problème

Traffic routier : Prédire en temps réel des temps de parcours

- Capteurs sur la route : défaillance
- Données localisation GPS, téléphones : non homogènes
- **But** : Reconstituer les données

Actuellement : Pas d'exploitation de dépendance spatiale ni temporelle (Régression...)

Objectif

Proposer un modèle statique utilisant la dépendance spatiale, et des outils simples.

Table des Matières

- 1 Introduction
- 2 **Modèle**
- 3 Application : Maximum de vraisemblance

Présentation du problème

Observation : Comportement des conducteurs indépendant de la position dans le réseau

Idée : Proposer un modèle de covariance “stationnaire” et “isotrope” généralisant les notions suivantes :

- Sur \mathbb{Z} invariance par translation
- Sur \mathbb{Z}^d invariance par rotations/translations
- Arbres homogènes, graphes de Cayley...

⇒ invariance par automorphisme de graphe

Présentation du problème

Observation : Comportement des conducteurs indépendant de la position dans le réseau

Idée : Proposer un modèle de covariance “stationnaire” et “isotrope” généralisant les notions suivantes :

- Sur \mathbb{Z} invariance par translation
- Sur \mathbb{Z}^d invariance par rotations/translations
- Arbres homogènes, graphes de Cayley...

⇒ invariance par automorphisme de graphe

Présentation du problème

Observation : Comportement des conducteurs indépendant de la position dans le réseau

Idée : Proposer un modèle de covariance “stationnaire” et “isotrope” généralisant les notions suivantes :

- Sur \mathbb{Z} invariance par translation
- Sur \mathbb{Z}^d invariance par rotations/translations
- Arbres homogènes, graphes de Cayley...

⇒ invariance par automorphisme de graphe

Présentation du problème

Observation : Comportement des conducteurs indépendant de la position dans le réseau

Idée : Proposer un modèle de covariance “stationnaire” et “isotrope” généralisant les notions suivantes :

- Sur \mathbb{Z} invariance par translation
- Sur \mathbb{Z}^d invariance par rotations/translations
- Arbres homogènes, graphes de Cayley...

⇒ invariance par automorphisme de graphe

Définitions

$G = (S, W)$ graphe infini pondéré

- S sommets (infini dénombrable)
- $W \in \mathbb{R}^{S \times S}$ opérateur de poids

W agit sur $\ell^2(S)$

$H_0 : G$ de degré borné par d ,

Alors W borné en tant qu'opérateur $B_S := \ell^2(S) \rightarrow \ell^2(S)$

Définitions

$G = (S, W)$ graphe infini pondéré

- S sommets (infini dénombrable)
- $W \in \mathbb{R}^{S \times S}$ opérateur de poids

W agit sur $\ell^2(S)$

H_0 : G de degré borné par d ,

Alors W borné en tant qu'opérateur $B_S := \ell^2(S) \rightarrow \ell^2(S)$

Définitions

$G = (S, W)$ graphe infini pondéré

- S sommets (infini dénombrable)
- $W \in \mathbb{R}^{S \times S}$ opérateur de poids

W agit sur $\ell^2(S)$

H_0 : G de degré borné par d ,

Alors W borné en tant qu'opérateur $B_S := \ell^2(S) \rightarrow \ell^2(S)$

Démarche

Cadre : Gaussien centré

⇒ Définir classes de covariances de processus stationnaires

- Covariance dans B_S
- Invariance par automorphisme si il en existe
- Contient fonctions positives de W , D opérateur de degrés,
 $L = D - W$ Laplacien discret...

Démarche

Cadre : Gaussien centré

⇒ Définir classes de covariances de processus stationnaires

- Covariance dans B_S
- Invariance par automorphisme si il en existe
- Contient fonctions positives de W , D opérateur de degrés,
 $L = D - W$ Laplacien discret...

Démarche

Cadre : Gaussien centré

⇒ Définir classes de covariances de processus stationnaires

- Covariance dans B_S
- Invariance par automorphisme si il en existe
- Contient fonctions positives de W , D opérateur de degrés,
 $L = D - W$ Laplacien discret...

Idée : Invariance par automorphisme

Démarche

Cadre : Gaussien centré

⇒ Définir classes de covariances de processus stationnaires

- Covariance dans B_S
- Invariance par automorphisme si il en existe
- Contient fonctions positives de W , D opérateur de degrés,
 $L = D - W$ Laplacien discret...

Problème : Pas d'automorphisme non triviaux généralement

Démarche

Cadre : Gaussien centré

⇒ Définir classes de covariances de processus stationnaires

- Covariance dans B_S
- Invariance par automorphisme si il en existe
- Contient fonctions positives de W , D opérateur de degrés,
 $L = D - W$ Laplacien discret...

Idee : Prendre fonctions de W , L ...

Démarche

Cadre : Gaussien centré

⇒ Définir classes de covariances de processus stationnaires

- Covariance dans B_S
- Invariance par automorphisme si il en existe
- Contient fonctions positives de W , D opérateur de degrés,
 $L = D - W$ Laplacien discret...

Problème : Choix arbitraire

Démarche

Cadre : Gaussien centré

⇒ Définir classes de covariances de processus stationnaires

- Covariance dans B_S
- Invariance par automorphisme si il en existe
- Contient fonctions positives de W , D opérateur de degrés,
 $L = D - W$ Laplacien discret...

Idée : Construire opérateurs de ce type

Définition (Fonctions invariantes I_S)

Φ de B_S dans B_S invariante si



$$\forall \sigma \in \mathcal{S}, \forall W \in B_S, \Phi(W \circ \sigma) = \Phi(W) \circ \sigma$$



$$\forall W \in B_S, \Phi(W^T) = (\Phi(W))^T$$

Remarque : Conditions de symétries sur les variables

Définition

$(X_i)_{i \in G}$ de covariance K Gaussien stationnaire si

$$\exists \Phi \in I_S, K = \Phi(W)$$

Définition (Fonctions invariantes I_S)

Φ de B_S dans B_S invariante si



$$\forall \sigma \in \mathcal{S}, \forall W \in B_S, \Phi(W \circ \sigma) = \Phi(W) \circ \sigma$$



$$\forall W \in B_S, \Phi(W^T) = (\Phi(W))^T$$

Remarque : Conditions de symétries sur les variables

Définition

$(X_i)_{i \in G}$ de covariance K Gaussien stationnaire si

$$\exists \Phi \in I_S, K = \Phi(W)$$

Définition (Fonctions invariantes I_S)

Φ de B_S dans B_S invariante si



$$\forall \sigma \in \mathcal{S}, \forall W \in B_S, \Phi(W \circ \sigma) = \Phi(W) \circ \sigma$$



$$\forall W \in B_S, \Phi(W^T) = (\Phi(W))^T$$

Remarque : Conditions de symétries sur les variables

Définition

$(X_i)_{i \in G}$ de covariance K Gaussien stationnaire si

$$\exists \Phi \in I_S, K = \Phi(W)$$

Définition (Fonctions invariantes I_S)

Φ de B_S dans B_S invariante si



$$\forall \sigma \in \mathcal{S}, \forall W \in B_S, \Phi(W \circ \sigma) = \Phi(W) \circ \sigma$$



$$\forall W \in B_S, \Phi(W^T) = (\Phi(W))^T$$

Remarque : Conditions de symétries sur les variables

Définition

$(X_i)_{i \in G}$ de covariance K Gaussien stationnaire si

$$\exists \Phi \in I_S, K = \Phi(W)$$

Remarque :

- Compatibilité avec définitions existantes
- Contient L, \tilde{L}, W, \dots

Soit $A = \Phi(W)$, $\Phi \in I_S$, tel que

$$W_{ij} = 0 \Rightarrow A_{ij} = 0$$

Processus MA_A

$(X_i)_{i \in G}$ de covariance K est MA_A si

$$\exists f, K = \sigma^2 P(A)^T P(A)$$

Remarque :

- Comme pour \mathbb{Z} , propagation locale de erreurs.
- $\sigma^2 P^2$ est la densité du processus

Remarque :

- Compatibilité avec définitions existantes
- Contient L, \tilde{L}, W, \dots

Soit $A = \Phi(W)$, $\Phi \in I_S$, tel que

$$W_{ij} = 0 \Rightarrow A_{ij} = 0$$

Processus MA_A

$(X_i)_{i \in G}$ de covariance K est MA_A si

$$\exists f, K = \sigma^2 P(A)^T P(A)$$

Remarque :

- Comme pour \mathbb{Z} , propagation locale de erreurs.
- $\sigma^2 P^2$ est la densité du processus

Remarque :

- Compatibilité avec définitions existantes
- Contient L, \tilde{L}, W, \dots

Soit $A = \Phi(W)$, $\Phi \in I_S$, tel que

$$W_{ij} = 0 \Rightarrow A_{ij} = 0$$

Processus MA_A

$(X_i)_{i \in G}$ de covariance K est MA_A si

$$\exists f, K = \sigma^2 P(A)^T P(A)$$

Remarque :

- Comme pour \mathbb{Z} , propagation locale de erreurs.
- $\sigma^2 P^2$ est la densité du processus

Remarque :

- Compatibilité avec définitions existantes
- Contient L, \tilde{L}, W, \dots

Soit $A = \Phi(W)$, $\Phi \in I_S$, tel que

$$W_{ij} = 0 \Rightarrow A_{ij} = 0$$

Processus MA_A

$(X_i)_{i \in G}$ de covariance K est MA_A si

$$\exists f, K = \sigma^2 P(A)^T P(A)$$

Remarque :

- Comme pour \mathbb{Z} , propagation locale de erreurs.
- $\sigma^2 P^2$ est la densité du processus

Table des Matières

- 1 Introduction
- 2 Modèle
- 3 Application : Maximum de vraisemblance**

Position du problème

Problème :

- $(f_\theta)_{\theta \in \Theta}$ famille paramétrique de densités
- G_N suite de sous graphes emboîtés
- $(X_i)_{i \in G}$ MA_A de densité f_{θ_0} observé sur G_N

On veut **estimer** θ_0 par max de vraisemblance

$K_N(f)$: covariance du processus de densité f restreint à G_N
(comme pour Toeplitz)

H_1 : Convergence étroite de la mesure spectrale empirique de A sur G_N vers μ

Position du problème

Problème :

- $(f_\theta)_{\theta \in \Theta}$ famille paramétrique de densités
- G_N suite de sous graphes emboîtés
- $(X_i)_{i \in G}$ MA_A de densité f_{θ_0} observé sur G_N

On veut **estimer** θ_0 par max de vraisemblance

$K_N(f)$: covariance du processus de densité f restreint à G_N
(comme pour Toeplitz)

H_1 : Convergence étroite de la mesure spectrale empirique de A sur G_N vers μ

Position du problème

Problème :

- $(f_\theta)_{\theta \in \Theta}$ famille paramétrique de densités
- G_N suite de sous graphes emboîtés
- $(X_i)_{i \in G}$ MA_A de densité f_{θ_0} observé sur G_N

On veut **estimer** θ_0 par max de vraisemblance

$K_N(f)$: covariance du processus de densité f restreint à G_N
(comme pour Toeplitz)

H_1 : Convergence étroite de la mesure spectrale empirique de A sur G_N vers μ

Position du problème

Problème :

- $(f_\theta)_{\theta \in \Theta}$ famille paramétrique de densités
- G_N suite de sous graphes emboîtés
- $(X_i)_{i \in G}$ MA_A de densité f_{θ_0} observé sur G_N

On veut **estimer** θ_0 par max de vraisemblance

$K_N(f)$: covariance du processus de densité f restreint à G_N
(comme pour Toeplitz)

H_1 : Convergence étroite de la mesure spectrale empirique de A sur G_N vers μ

Généralisation de \mathbb{Z}

- $\mathbb{Z}, [1, N]$
 - $\mu = \frac{1}{2\pi} \lambda$ sur \mathbb{T}
 - $2 = o(N)$
 - $A_{ij} = \mathbf{1}_{j=i+1}$
 - $T(f) = \sigma^2 P(A)^T P(A),$
 $f = \sigma^2 |P|^2$
 - $\Delta_k = k, \alpha(f) = \sum_k k |f_k|$
- G, G_N
 - H_1 : Mesure spectrale μ
 - H_2 : $\#\partial G_N = o(\#G_N)$
 - ✓ $A \in S_1$
 - ✓ $K(f) = \sigma^2 P(A)^T P(A),$
 $f = \sigma^2 |P|^2$
 - ✓ $\alpha(f) = \sum_k \Delta_k |f_k|$

Généralisation de \mathbb{Z}

- $\mathbb{Z}, [1, N]$
 - $\mu = \frac{1}{2\pi} \lambda$ sur \mathbb{T}
 - $2 = o(N)$
 - $A_{ij} = \mathbf{1}_{j=i+1}$
 - $T(f) = \sigma^2 P(A)^T P(A),$
 $f = \sigma^2 |P|^2$
 - $\Delta_k = k, \alpha(f) = \sum_k k |f_k|$
- G, G_N
 - H_1 : Mesure spectrale μ
 - H_2 : $\#\partial G_N = o(\#G_N)$
 - ✓ $A \in S_1$
 - ✓ $K(f) = \sigma^2 P(A)^T P(A),$
 $f = \sigma^2 |P|^2$
 - ✓ $\alpha(f) = \sum_k \Delta_k |f_k|$

Généralisation de \mathbb{Z}

- $\mathbb{Z}, [1, N]$
 - $\mu = \frac{1}{2\pi} \lambda$ sur \mathbb{T}
 - $2 = o(N)$
 - $A_{ij} = \mathbf{1}_{j=i+1}$
 - $T(f) = \sigma^2 P(A)^T P(A),$
 $f = \sigma^2 |P|^2$
 - $\Delta_k = k, \alpha(f) = \sum_k k |f_k|$
- G, G_N
 - H_1 : Mesure spectrale μ
 - H_2 : $\# \partial G_N = o(\# G_N)$
 - ✓ $A \in S_1$
 - ✓ $K(f) = \sigma^2 P(A)^T P(A),$
 $f = \sigma^2 |P|^2$
 - ✓ $\alpha(f) = \sum_k \Delta_k |f_k|$

Généralisation de \mathbb{Z}

- $\mathbb{Z}, [1, N]$
 - $\mu = \frac{1}{2\pi} \lambda$ sur \mathbb{T}
 - $2 = o(N)$
 - $A_{ij} = \mathbf{1}_{j=i+1}$
 - $T(f) = \sigma^2 P(A)^T P(A),$
 $f = \sigma^2 |P|^2$
 - $\Delta_k = k, \alpha(f) = \sum_k k |f_k|$
- G, G_N
 - H_1 : Mesure spectrale μ
 - H_2 : $\# \partial G_N = o(\# G_N)$
 - ✓ $A \in S_1$
 - ✓ $K(f) = \sigma^2 P(A)^T P(A),$
 $f = \sigma^2 |P|^2$
 - ✓ $\alpha(f) = \sum_k \Delta_k |f_k|$

Généralisation de \mathbb{Z}

- $\mathbb{Z}, [1, N]$
 - $\mu = \frac{1}{2\pi} \lambda$ sur \mathbb{T}
 - $2 = o(N)$
 - $A_{ij} = \mathbf{1}_{j=i+1}$
 - $T(f) = \sigma^2 P(A)^T P(A),$
 $f = \sigma^2 |P|^2$
 - $\Delta_k = k, \alpha(f) = \sum_k k |f_k|$
- G, G_N
 - H_1 : Mesure spectrale μ
 - H_2 : $\# \partial G_N = o(\# G_N)$
 - ✓ $A \in S_1$
 - ✓ $K(f) = \sigma^2 P(A)^T P(A),$
 $f = \sigma^2 |P|^2$
 - ✓ $\alpha(f) = \sum_k \Delta_k |f_k|$

Généralisation de \mathbb{Z}

- $\mathbb{Z}, [1, N]$
 - $\mu = \frac{1}{2\pi} \lambda$ sur \mathbb{T}
 - $2 = o(N)$
 - $A_{ij} = \mathbf{1}_{j=i+1}$
 - $T(f) = \sigma^2 P(A)^T P(A),$
 $f = \sigma^2 |P|^2$
 - $\Delta_k = k, \alpha(f) = \sum_k k |f_k|$
- G, G_N
 - H_1 : Mesure spectrale μ
 - H_2 : $\# \partial G_N = o(\# G_N)$
 - ✓ $A \in S_1$
 - ✓ $K(f) = \sigma^2 P(A)^T P(A),$
 $f = \sigma^2 |P|^2$
 - ✓ $\alpha(f) = \sum_k \Delta_k |f_k|$

Lemmes de Szegő

\mathbb{Z} :

$$\frac{1}{N} \log (\det (T_N(f))) \rightarrow \int \log (f(\lambda)) d\mu(\lambda)$$

Lemmes de Szegö

Lemme du determinant

$$\frac{1}{\#G_N} \log (\det (K_N(f))) \rightarrow \int \log (f(\lambda)) d\mu(\lambda)$$

Lemmes de Szegö

Lemme du déterminant

$$\frac{1}{\#G_N} \log (\det (K_N(f))) \rightarrow \int \log (f(\lambda)) d\mu(\lambda)$$

\mathbb{Z} :

$$T_N(f)^{-1} \approx T_N\left(\frac{1}{f}\right)$$

Lemmes de Szegö

Lemme du déterminant

$$\frac{1}{\#G_N} \log (\det (K_N(f))) \rightarrow \int \log (f(\lambda)) d\mu(\lambda)$$

Lemme d'inversion

$$K_N(f)^{-1} \approx K_N\left(\frac{1}{f}\right)$$

Lemmes de Szegö

Lemme du déterminant

$$\frac{1}{\#G_N} \log (\det (K_N(f))) \rightarrow \int \log (f(\lambda)) d\mu(\lambda)$$

Lemme d'inversion

$$K_N(f)^{-1} \approx K_N\left(\frac{1}{f}\right)$$

⇒ Convergence des estimateurs

On construit les vraisemblances approchées utilisant les deux lemmes précédents.

Théorème

*Sous des hypothèses “classiques”, et pour des classes de densités assez régulières, **tous les estimateurs** de max de vraisemblances approchées **convergent** vers la vraie valeur.*

On construit les vraisemblances approchées utilisant les deux lemmes précédents.

Théorème

*Sous des hypothèses “classiques”, et pour des classes de densités assez régulières, **tous les estimateurs** de max de vraisemblances approchées **convergent** vers la vraie valeur.*

Pistes de recherche

Problèmes connexes

- Extension aux cas de densités moins régulières (longue mémoire...)
- Efficacité
- Estimation du générateur A
- Grandes déviations

Utilisation du modèle

- Généralisations aux processus non-réguliers
- Graphes aléatoires
- Filtrage–Prédiction
- ...

Pistes de recherche

Problèmes connexes

- Extension aux cas de densités moins régulières (longue mémoire...)
- Efficacité
- Estimation du générateur A
- Grandes déviations

Utilisation du modèle

- Généralisations aux processus non-réguliers
- Graphes aléatoires
- Filtrage–Prédiction
- ...

Pistes de recherche

Problèmes connexes

- Extension aux cas de densités moins régulières (longue mémoire...)
- Efficacité
- Estimation du générateur A
- Grandes déviations

Utilisation du modèle

- Généralisations aux processus non-réguliers
- Graphes aléatoires
- Filtrage–Prédiction
- ...

Pistes de recherche

Problèmes connexes

- Extension aux cas de densités moins régulières (longue mémoire...)
- Efficacité
- Estimation du générateur A
- Grandes déviations

Utilisation du modèle

- Généralisations aux processus non-réguliers
- Graphes aléatoires
- Filtrage–Prédiction
- ...

Pistes de recherche

Problèmes connexes

- Extension aux cas de densités moins régulières (longue mémoire...)
- Efficacité
- Estimation du générateur A
- Grandes déviations

Utilisation du modèle

- Généralisations aux processus non-réguliers
- Graphes aléatoires
- Filtrage–Prédiction
- ...

Pistes de recherche

Problèmes connexes

- Extension aux cas de densités moins régulières (longue mémoire...)
- Efficacité
- Estimation du générateur A
- Grandes déviations

Utilisation du modèle

- Généralisations aux processus non-réguliers
- Graphes aléatoires
- Filtrage–Prédiction
- ...

Pistes de recherche

Problèmes connexes

- Extension aux cas de densités moins régulières (longue mémoire...)
- Efficacité
- Estimation du générateur A
- Grandes déviations

Utilisation du modèle

- Généralisations aux processus non-réguliers
- Graphes aléatoires
- Filtrage–Prédiction
- ...

Merci

Lemmes de Szegö

Comme pour \mathbb{Z} , deux lemmes nécessaires

Lemme (Lemme du déterminant)

$$\frac{1}{\#G_N} \log (\det (K_N(f))) \rightarrow \int \log (f(\lambda)) d\mu(\lambda)$$

Lemmes de Szegő

Comme pour \mathbb{Z} , deux lemmes nécessaires

Lemme (Lemme du déterminant)

$$\frac{1}{\#G_N} \log (\det (K_N(f))) \rightarrow \int \log (f(\lambda)) d\mu(\lambda)$$

Lemme (Lemme d'inversion)

$$(K_N(f))^{-1} \approx K_N\left(\frac{1}{f}\right)$$

Lemmes de Szegö

Comme pour \mathbb{Z} , deux lemmes nécessaires

Lemme (Lemme du déterminant)

$$\frac{1}{\#G_N} \log(\det(K_N(f))) \rightarrow \int \log(f(\lambda)) d\mu(\lambda)$$

Lemme (Lemme d'inversion)

$$(K_N(f))^{-1} \approx K_N\left(\frac{1}{f}\right)$$

Remarque : En réalité, contrôle du biais (norme infinie b) entre $K_N(f)K_N(g)$ et $K_N(fg)$

Lemmes de Szegö

Comme pour \mathbb{Z} , deux lemmes nécessaires

Lemme (Lemme du déterminant)

$$\frac{1}{\#G_N} \log (\det (K_N(f))) \rightarrow \int \log (f(\lambda)) d\mu(\lambda)$$

\mathbb{Z} :

$$b(T_N(f) T_N(g) - T_N(fg)) \leq \alpha(f)\alpha(g)$$

Lemmes de Szegő

Comme pour \mathbb{Z} , deux lemmes nécessaires

Lemme (Lemme du déterminant)

$$\frac{1}{\#G_N} \log(\det(K_N(f))) \rightarrow \int \log(f(\lambda)) d\mu(\lambda)$$

Lemme de quasi-homomorphisme

$$\frac{1}{\#\partial G_N} b(K_N(f)K_N(g) - K_N(fg)) \leq \frac{1}{2}\alpha(f)\alpha(g)$$

Hypothèses (H_3)

- Θ est compact
- L'application $\nu \rightarrow f_\nu$ est injective



$$\exists \rho, \forall \nu \in \Theta, \alpha(f_\nu) \leq \rho, \alpha\left(\frac{1}{f_\nu}\right) \leq \rho$$



$$\exists m > 0, \forall \nu \in \Theta, \forall x, m \leq f_\nu(x) \leq \frac{1}{m}$$

- Continuité de $f_\nu(\lambda)$ en ν

Théorème

Sous l'hypothèse H_3 , les estimateurs $\nu_n, \bar{\nu}_n$ et $\tilde{\nu}_n$ convergent P_{f_ν} -p.s. vers la vraie valeur ν quelque soit $\nu \in \Theta$

Hypothèses (H_3)

- Θ est compact
- L'application $\nu \rightarrow f_\nu$ est injective



$$\exists \rho, \forall \nu \in \Theta, \alpha(f_\nu) \leq \rho, \alpha\left(\frac{1}{f_\nu}\right) \leq \rho$$



$$\exists m > 0, \forall \nu \in \Theta, \forall x, m \leq f_\nu(x) \leq \frac{1}{m}$$

- Continuité de $f_\nu(\lambda)$ en ν

Théorème

Sous l'hypothèse H_3 , les estimateurs $\nu_n, \bar{\nu}_n$ et $\tilde{\nu}_n$ convergent P_{f_ν} -p.s. vers la vraie valeur ν quelque soit $\nu \in \Theta$