

Détection et classification de cibles multispectrales dans l'infrarouge

Florian Maire

ONERA / Telecom SudParis

Soutenu le 14 Février 2014 devant le jury composé de :

M. Jean-Michel MARIN	Université Montpellier 2	Rapporteur
M ^{me} . Stéphanie ALLASSONNIÈRE	Ecole Polytechnique	Examineur
M. Jacques BLANC-TALON	DGA - MRIS	Examineur
M. Christian ROBERT	Université Paris-Dauphine	Examineur
M. Olivier WINTENBERGER	Université Paris 6	Examineur
M. Randal DOUC	Telecom SudParis	Directeur de thèse
M. Eric MOULINES	Télécom ParisTech	Directeur de thèse
M ^{me} . Sidonie LEFEBVRE	ONERA	Encadrante

Plan de la présentation

- 1 Contexte, problématique & résultats
 - Introduction
 - Détection de SIR multispectrales
 - Classification de SIR multispectrales
- 2 Deux problèmes de méthodologie statistique
 - Apprentissage séquentiel dans les modèles à données manquantes
 - Comparaison de chaînes de Markov inhomogènes
- 3 Questions ouvertes

Plan de la présentation

1 Contexte, problématique & résultats

- Introduction
- Détection de SIR multispectrales
- Classification de SIR multispectrales

2 Deux problèmes de méthodologie statistique

- Apprentissage séquentiel dans les modèles à données manquantes
- Comparaison de chaînes de Markov inhomogènes

3 Questions ouvertes

Plan de la présentation

1 Contexte, problématique & résultats

■ Introduction

- Détection de SIR multispectrales
- Classification de SIR multispectrales


2 Deux problèmes de méthodologie statistique

- Apprentissage séquentiel dans les modèles à données manquantes
- Comparaison de chaînes de Markov inhomogènes

3 Questions ouvertes

Contexte

- Surveillance de sites sensibles contre des menaces aériennes
- Utilisation d'images infrarouge




Capteurs mono/multispectral

détecteur infrarouge **monospectral**




scène

Réponse détecteur




Capteurs mono/multispectral


détecteur infrarouge **monospectral**




Réponse détecteur




Capteurs mono/multispectral




Réponse détecteur




Capteurs mono/multispectral




Réponse détecteur




Capteurs mono/multispectral




Réponse détecteur




Capteurs mono/multispectral




Réponse détecteur




Capteurs mono/multispectral




Réponse détecteur



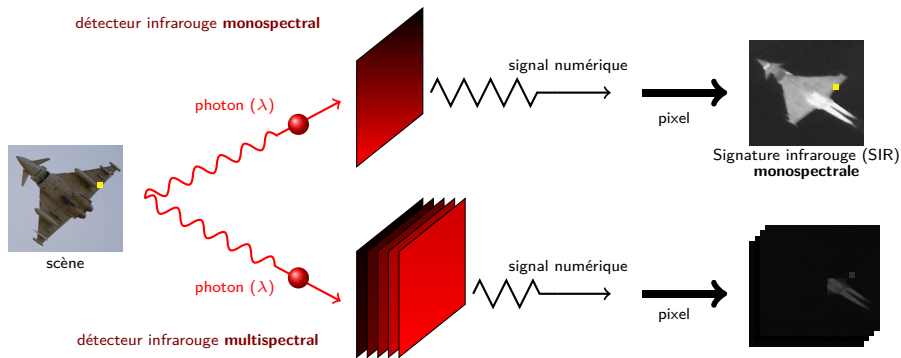
Capteurs mono/multispectral




Réponse détecteur




Capteurs mono/multispectral




Réponse détecteur




Capteurs mono/multispectral




Réponse détecteur



Capteurs mono/multispectral




Réponse détecteur




Intérêt du multispectral?

Rayonnement infrarouge hypothétique d'un avion




Réponse détecteur **monospectral** et **multispectral**




⇒ (i) Augmenter le rapport signal à bruit

Intérêt du multispectral?

Rayonnement infrarouge hypothétique d'un avion





Réponse détecteur **monospectral** et **multispectral**



⇒ (i) Augmenter le rapport signal à bruit

Rayonnement infrarouge hypothétique de 2 avions **différents**



⇒ (ii) Discriminer différentes cibles

Objectifs de la thèse

(i) **détecter** des aéronefs à partir de signature infrarouge,

Objectifs de la thèse

- (i) **détecter** des aéronefs à partir de signature infrarouge,
- (ii) **classifier** des aéronefs à partir de leur signature infrarouge,


Objectifs de la thèse

- (i) **détecter** des aéronefs à partir de signature infrarouge,
- (ii) **classifier** des aéronefs à partir de leur signature infrarouge,
- (iii) **spécifier les bandes infrarouge** préférables pour ces applications.

Besoin de données...

- Signatures d'aéronefs *expérimentales* impossibles à obtenir
- Simulateur de signatures **mono/multispectral** développé par l'ONERA

Simulation d'une SIR
monospectrale ⇒



Simulation d'une SIR **multispectrale** (7 bandes)

Données correspondant au scénario...

- Distance cible/capteur \Rightarrow **faible résolution** :


SIR haute résolution
 1024×1024



Données correspondant au scénario...

- Distance cible/capteur \Rightarrow **faible résolution** :

SIR haute résolution
 1024×1024





SIR faible résolution
 16×16

Données correspondant au scénario...


- Distance cible/capteur \Rightarrow **faible résolution** :

SIR haute résolution
 1024×1024



SIR faible résolution
 16×16


- Fond de ciel \Rightarrow **présence de bruit** :



Données correspondant au scénario...


- Distance cible/capteur \Rightarrow **faible résolution** :

SIR haute résolution
 1024×1024



SIR faible résolution
 16×16

- Fond de ciel \Rightarrow **présence de bruit** :



σ_1



σ_2

Variabilité des signatures

- Incertitude paramètres scénario \Rightarrow variabilité des signatures


Variabilité des signatures

- Incertitude paramètres scénario \Rightarrow variabilité des signatures
- Deux origines de la dispersion :

Variabilité des signatures

- Incertitude paramètres scénario \Rightarrow variabilité des signatures
- Deux origines de la dispersion :


(i) Dispersion géométrique (spatiale)




Variabilité des signatures

- Incertitude paramètres scénario \Rightarrow variabilité des signatures
- Deux origines de la dispersion :

(i) Dispersion géométrique (spatiale)



(ii) Dispersion photométrique (spectrale)



Challenges

Les méthodes statistiques doivent :

Challenges

Les méthodes statistiques doivent :

- (i) intégrer simultanément les **dispersions spectrales et spatiales**

Challenges

Les méthodes statistiques doivent :

- (i) intégrer simultanément les **dispersions spectrales et spatiales**
- (ii) être adaptées aux données de (très) **faible résolution** et **bruitées**

Challenges

Les méthodes statistiques doivent :

- (i) intégrer simultanément les **dispersions spectrales et spatiales**
- (ii) être adaptées aux données de (très) **faible résolution** et **bruitées**
- (iii) permettre un traitement des données de façon **séquentielle** et en ***quasi-temps réel***

Plan de la présentation

1 Contexte, problématique & résultats

- Introduction
- Détection de SIR multispectrales
- Classification de SIR multispectrales

2 Deux problèmes de méthodologie statistique

- Apprentissage séquentiel dans les modèles à données manquantes
- Comparaison de chaînes de Markov inhomogènes

3 Questions ouvertes

Position du problème

- Observations $\{Y_n, n \in \mathbb{N}\}$ v.a. sur $(Y, \mathcal{Y}, \mathbb{P})$ où

$$\begin{cases} Y_n | Y_n \in \mathcal{H}_0 \sim \mathbb{P}_0 \\ Y_n | Y_n \in \mathcal{H}_1 \sim \mathbb{P}_1 \end{cases}$$

- Test à deux hypothèses $\Phi : Y \rightarrow \{\mathcal{H}_0, \mathcal{H}_1\}$ tel que :
 - (i) $P_{\text{FA}}(\Phi) = \mathbb{P}[\Phi(Y) \in \mathcal{H}_1 | Y \in \mathcal{H}_0]$ soit minimale
 - (ii) $P_{\text{D}}(\Phi) = \mathbb{P}[\Phi(Y) \in \mathcal{H}_1 | Y \in \mathcal{H}_1]$ soit maximale
- Hypothèses : \mathbb{P}_0 connue, \mathbb{P}_1 inconnue

⇒ Approche détection d'anomalie

Détecteur RX (Reed & Xiaoli, 1990)

- Images multispectrales à K bandes de dimension P
- $Y \in \mathcal{Y}$, $Y = \{y_j \in \mathbb{R}^K, 1 \leq j \leq P\}$
- Modèle de fond
 - (i) indépendant spatialement : $\mathbb{P}_0 = \bigotimes_{j=1}^P \mu_0$
 - (ii) corrélé spectralement : $\mu_0 = \mathcal{N}(0_K, \Sigma)$
- Distance de Mahalanobis :

$$\forall y \in \mathbb{R}^K, \quad D_M(y, \mu_0) = (y - \mu_0)^T \Sigma^{-1} (y - \mu_0)$$

- Détecteur RX :
$$\phi_{\text{RX}}(Y) \rightarrow \begin{cases} \mathcal{H}_0 & \text{si } \max_j D_M(y_j, \mu_0) \leq \eta \\ \mathcal{H}_1 & \text{si } \max_j D_M(y_j, \mu_0) > \eta \end{cases}$$

Un nouveau détecteur d'anomalies spectrales / spatiales

limite de ϕ_{RX} : pixels étudiés de façon indépendante
 \Rightarrow néglige la dispersion spatiale des cibles

(i) **Interpolation** de la fonction

$$\forall x \in \mathbb{R}^2, \quad I_Y(x) = \sum_{j=1}^P D_M(y_j, \mu_0) \psi_j(x),$$


(ii) Etude des **ensembles de niveau** $\eta > 0$ de la fonction I_Y

$$\forall Y \in \mathcal{Y}, \quad A_\eta(Y) = \{x \in \mathbb{R}^2, I_Y(x) > \eta\},$$


$$\text{Test de détection } \phi(Y) \rightarrow \begin{cases} \mathcal{H}_0 & \text{si } \max(\text{Per}(A_\eta(Y))) \leq \nu \\ \mathcal{H}_1 & \text{si } \max(\text{Per}(A_\eta(Y))) > \nu \end{cases}$$

Illustration sur une image "facile"

une image multispectrale $Y \in \mathcal{Y}$



$$\{D_M(y_j, \mu_0), 1 \leq j \leq P\}$$



$$(i) x \rightarrow I_Y(x)$$



$$(ii) \{A_\eta, \eta > 0\}$$







Illustration sur une image "facile"

une image multispectrale $Y \in \mathcal{Y}$



$$\{D_M(y_j, \mu_0), 1 \leq j \leq P\}$$



$$(i) x \rightarrow I_Y(x)$$



$$(ii) \{A_\eta, \eta > 0\}$$







Illustration sur une image "facile"


une image multispectrale $Y \in \mathcal{Y}$



$$\{D_M(y_j, \mu_0), 1 \leq j \leq P\}$$



$$(i) x \rightarrow I_Y(x)$$



$$(ii) \{A_\eta, \eta > 0\}$$







Illustration sur une image "difficile"

une image multispectrale $Y \in \mathcal{Y}$



$$\{D_M(y_j, \mu_0), 1 \leq j \leq P\}$$



$$(i) x \rightarrow I_Y(x)$$



$$(ii) \{A_\eta, \eta > 0\}$$








Illustration sur une image "difficile"

une image multispectrale $Y \in \mathcal{Y}$



$$\{D_M(y_j, \mu_0), 1 \leq j \leq P\}$$



$$(i) x \rightarrow I_Y(x)$$




$$(ii) \{A_\eta, \eta > 0\}$$




Illustration sur une image "difficile"


une image multispectrale $Y \in \mathcal{Y}$





$$\{D_M(y_j, \mu_0), 1 \leq j \leq P\}$$



$$(i) x \rightarrow I_Y(x)$$


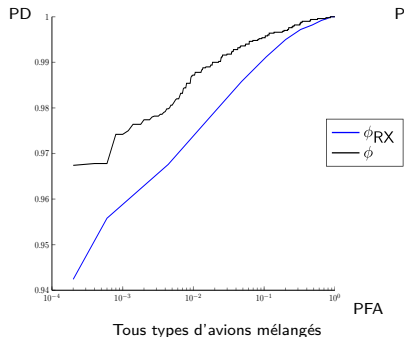


$$(ii) \{A_\eta, \eta > 0\}$$



Résultats

Comparaison de la courbe PD/PFA des détecteurs ϕ_{RX} et ϕ



⇒ L'intérêt de ϕ est plus évident pour les avions ayant un *faible* rayonnement IR (donc plus durs à détecter!)

Un détecteur robuste

Le détecteur ϕ permet de :

- (i) détecter les SIR avec un faible rayonnement IR...
- (ii) ... tout en conservant un taux de fausse alarme acceptable
- (iii) donner une information contextuelle
 - ⇒ sur la position (spatiale) de la cible dans l'image
 - ⇒ donner une information sur la géométrie de la cible

mais est limité par :

- (i) le manque d'expression exacte des seuils correspondant à une P_{FA} donnée
- (ii) les performances d'un point de vue calculatoire

Plan de la présentation

1 Contexte, problématique & résultats

- Introduction
- Détection de SIR multispectrales
- Classification de SIR multispectrales

2 Deux problèmes de méthodologie statistique

- Apprentissage séquentiel dans les modèles à données manquantes
- Comparaison de chaînes de Markov inhomogènes

3 Questions ouvertes

Une première remarque...

- Analogie avec un problème de reconnaissance de caractère...

 Y_1  Y_2  Y_3

$$d(Y_1, Y_2) \gg d(Y_1, Y_3)$$

d distance sur \mathbb{R}^P

Une première remarque...

- Analogie avec un problème de reconnaissance de caractère...

 Y_1  Y_2  Y_3

$$d(Y_1, Y_2) \gg d(Y_1, Y_3)$$

d distance sur \mathbb{R}^P

- Données variant au niveau du contexte / de l'information



Une première remarque...

- Analogie avec un problème de reconnaissance de caractère...

 Y_1  Y_2  Y_3


$$d(Y_1, Y_2) \gg d(Y_1, Y_3)$$

d distance sur \mathbb{R}^P


- Données variant au niveau du contexte / de l'information



- Clusters obtenus par deux méthodes classiques de classification :



4 modes principaux obtenus par ACP



4 modes principaux obtenus par K-means

Un premier constat...

- ⇒ Nécessiter d'**estimer les déformations** afin de recalibrer les données entre elles.
- ⇒ **Décontextualiser** l'information



Un premier constat...

- ⇒ Nécessiter d'**estimer les déformations** afin de recalibrer les données entre elles.
- ⇒ **Décontextualiser** l'information



Objectif:



Une approche Bayésienne de la classification

- Observations : v.a. $\{Y_n, n \in \mathbb{N}\}$ def. sur (Y, \mathcal{Y})
- Modèle de mélange :

$$\forall A \in \mathcal{Y}, \quad \mathbb{P}[Y_n \in A] = \sum_{i \in I} \mathbb{P}_i(A) \omega_i ,$$

\mathbb{P}_i : la distribution de Y_n cond. à $I_n = i$

ω_i : loi *a priori* de $I_n = i$.

- Classification d'une observation $Y_n \in Y$ par la classe $\hat{Q}_n \in I$:

$$\hat{Q}_n = \arg \max_{i \in I} \mathbb{P}[I_n = i | Y_n] = \arg \max_{i \in I} \mathbb{P}_i(Y_n) \omega_i ,$$

Problématique sous-jacente :

explorer les distributions conditionnelles $\{\mathbb{P}_i, i \in I\}$

Modèle d'observation : **Modèle à prototype déformable**

Hypothèses :

- Existence de fonctions $\{\mathcal{Y}_n : \mathbb{R}^2 \rightarrow \mathbb{R}, n \in \mathbb{N}\}$ t.q. :

$$\{\mathcal{Y}_n, n \in \mathbb{N}\} \xrightarrow[\text{sur grille de pixels}]{\text{discrétisation}} \{Y_n, n \in \mathbb{N}\}$$

- $\forall n \in \mathbb{N}$, \mathcal{Y}_n dérive d'une même fonction **déterministe (prototype)**

$$\mathcal{T} : \mathbb{R}^2 \rightarrow \mathbb{R}$$

par :

- (i) un processus de déformation aléatoire du plan $D_n : \mathbb{R}^2 \rightarrow \mathbb{R}^2$,
- (ii) un processus de bruit additif $\mathcal{W}_n : \mathbb{R}^2 \rightarrow \mathbb{R}$


$$\forall u \in \mathbb{R}^2, \quad \mathcal{Y}_n(u) = \mathcal{T} \circ D_n(u) + \mathcal{W}_n(u).$$

Adaptation à un modèle de mélange

- Existence de **plusieurs** prototypes $\{\mathcal{T}^{(i)}, i \in I\}$

sachant que $l_n = i$, $\mathcal{Y}_n = \mathcal{T}^{(i)} \circ D_n^{(i)} + \mathcal{W}_n^{(i)}$.

- Illustration sur un mélange de 5 classes :




5 prototypes

Adaptation à un modèle de mélange

- Existence de **plusieurs** prototypes $\{\mathcal{T}^{(i)}, i \in I\}$

sachant que $l_n = i$, $\mathcal{Y}_n = \mathcal{T}^{(i)} \circ D_n^{(i)} + \mathcal{W}_n^{(i)}$.

- Illustration sur un mélange de 5 classes :




5 prototypes

Adaptation à un modèle de mélange

- Existence de **plusieurs** prototypes $\{\mathcal{T}^{(i)}, i \in I\}$

sachant que $l_n = i$, $\mathcal{Y}_n = \mathcal{T}^{(i)} \circ D_n^{(i)} + \mathcal{W}_n^{(i)}$.

- Illustration sur un mélange de 5 classes :




Adaptation à un modèle de mélange

- Existence de **plusieurs** prototypes $\{\mathcal{T}^{(i)}, i \in I\}$

sachant que $l_n = i$, $\mathcal{Y}_n = \mathcal{T}^{(i)} \circ D_n^{(i)} + \mathcal{W}_n^{(i)}$.

- Illustration sur un mélange de 5 classes :




Adaptation à un modèle de mélange

- Existence de **plusieurs** prototypes $\{\mathcal{T}^{(i)}, i \in I\}$

sachant que $l_n = i$, $\mathcal{Y}_n = \mathcal{T}^{(i)} \circ D_n^{(i)} + \mathcal{W}_n^{(i)}$.

- Illustration sur un mélange de 5 classes :

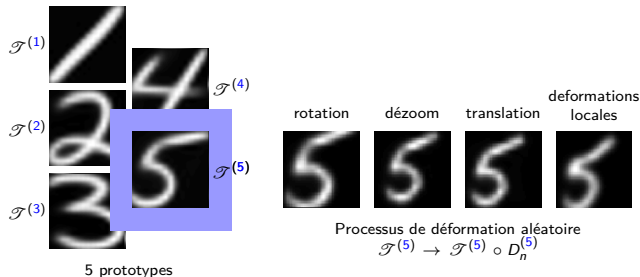


Adaptation à un modèle de mélange

- Existence de **plusieurs** prototypes $\{\mathcal{T}^{(i)}, i \in I\}$

sachant que $l_n = i$, $\mathcal{Y}_n = \mathcal{T}^{(i)} \circ D_n^{(i)} + \mathcal{W}_n^{(i)}$.

- Illustration sur un mélange de 5 classes :




Adaptation à un modèle de mélange

- Existence de **plusieurs** prototypes $\{\mathcal{T}^{(i)}, i \in I\}$

sachant que $I_n = i$, $\mathcal{Y}_n = \mathcal{T}^{(i)} \circ D_n^{(i)} + \mathcal{W}_n^{(i)}$.

- Illustration sur un mélange de 5 classes :




Adaptation à un modèle de mélange

- Existence de **plusieurs** prototypes $\{\mathcal{T}^{(i)}, i \in I\}$

sachant que $l_n = i$, $\mathcal{Y}_n = \mathcal{T}^{(i)} \circ D_n^{(i)} + \mathcal{W}_n^{(i)}$.

- Illustration sur un mélange de 5 classes :




Adaptation à un modèle de mélange

- Existence de **plusieurs** prototypes $\{\mathcal{T}^{(i)}, i \in I\}$

sachant que $l_n = i$, $\mathcal{Y}_n = \mathcal{T}^{(i)} \circ D_n^{(i)} + \mathcal{W}_n^{(i)}$.

- Illustration sur un mélange de 5 classes :




Adaptation à un modèle de mélange

- Existence de **plusieurs** prototypes $\{\mathcal{T}^{(i)}, i \in I\}$

sachant que $l_n = i$, $\mathcal{Y}_n = \mathcal{T}^{(i)} \circ D_n^{(i)} + \mathcal{W}_n^{(i)}$.

- Illustration sur un mélange de 5 classes :




Adaptation à un modèle de mélange

- Existence de **plusieurs** prototypes $\{\mathcal{T}^{(i)}, i \in I\}$

sachant que $I_n = i$, $\mathcal{Y}_n = \mathcal{T}^{(i)} \circ D_n^{(i)} + \mathcal{W}_n^{(i)}$.

- Illustration sur un mélange de 5 classes :

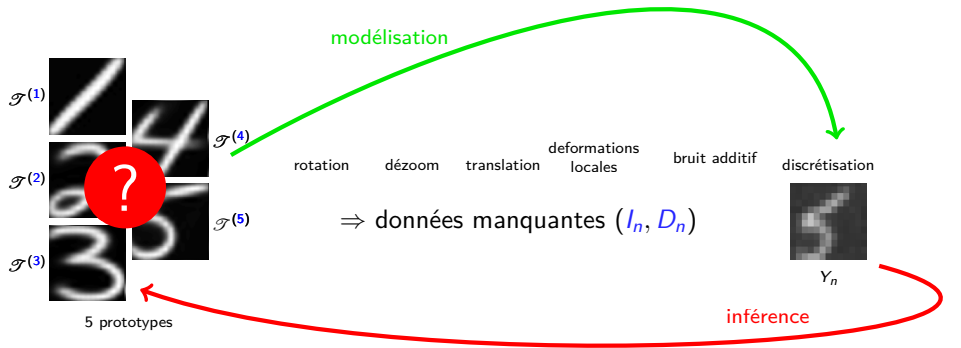


Adaptation à un modèle de mélange

- Existence de **plusieurs** prototypes $\{\mathcal{T}^{(i)}, i \in I\}$

sachant que $l_n = i$, $\mathcal{Y}_n = \mathcal{T}^{(i)} \circ D_n^{(i)} + \mathcal{W}_n^{(i)}$.

- Illustration sur un mélange de 5 classes :




Modèle de déformation dans le cas des SIR

(1) Déformation du plan

$$D = D_{\beta} \begin{cases} \text{rotation} \\ \text{translation} \\ \text{déformation locale} \end{cases} \quad \beta \in B \subseteq \mathbb{R}^d$$

$$\beta | i \sim p_{\gamma^{(i)}} \quad \gamma = (\gamma^{(1)}, \dots, \gamma^{(C)})$$

(2) Déformation dans l'espace de mesure



⇒ facteur d'ajustement en amplitude $\lambda > 0$ $\lambda \sim \text{Gamma}(a, b)$

Modèle de SIR multispectrales

SIR multispectrale à K bandes $Y_n = (Y_{n,1}, \dots, Y_{n,K})$ où $\{Y_{n,k} \in Y\}_{k=1}^K$

- Un prototype \mathcal{T}_k par bande spectrale

$$\mathcal{T}_k \rightarrow \mathcal{T}_{\alpha_k} = \sum_{\ell=1}^m \alpha_{k,\ell} \phi_{\ell}, \quad \alpha_k \in A \subseteq \mathbb{R}^m,$$

- Une variance de bruit $\{\sigma_k^2\}_{k=1}^K$ par bande spectrale,
- Même paramètres i, β, λ pour toutes les bandes spectrales,
- Modèle d'observation, **conditionnellement** à i_n, β_n, λ_n :

$$\begin{cases} \mathcal{Y}_n = (\mathcal{Y}_{n,1}, \dots, \mathcal{Y}_{n,K}), \\ \mathcal{Y}_{n,k} = \lambda_n \mathcal{T}_{\alpha_k(i_n)} \circ D_{\beta_n} + \sigma_k \mathcal{W}_{n,k}. \end{cases}$$

Problème initial : explorer les distributions \mathbb{P}_i

- Exploration des $\{\mathbb{P}_i, i \in I\} \iff$ Estimation du vecteur de paramètres $\theta \in \Theta \subset \mathbb{R}^p$

$$\theta = \left(\left\{ \alpha_1^{(i)}, \dots, \alpha_K^{(i)}, \gamma^{(i)}, \omega^{(i)} \right\}_{i \in I}, \sigma_1, \dots, \sigma_K \right),$$

↙
↙
↘
↘


Prototypes Loi *a priori* β Loi *a priori* l Variance bruit

- Estimation séquentielle de θ : Approximation stochastique de l'EM (partie II)


$$\{\hat{\theta}_n, n \in \mathbb{N}\} \rightarrow \hat{\theta},$$

Approximation des distributions conditionnelles $\{\mathbb{P}_i, i \in I\}$ par $\{\mathbb{P}_{\hat{\theta}^{(i)}}, i \in I\}$


Illustration apprentissage



Exemples de données
 $\{Y_n, n \in \mathbb{N}\}$



Prototypes estimés
 $\mathcal{I}_{\hat{\theta}^{(1)}}$, $\mathcal{I}_{\hat{\theta}^{(2)}}$ et $\mathcal{I}_{\hat{\theta}^{(3)}}$



Données simulées par le
 modèle appris $Y \sim \mathbb{P}_{\hat{\theta}}$

Quelques résultats de classification...

En monospectral :

Prédiction \ Réalité	Avion 1	Alphajet
Avion 1	0.912	0.060
Alphajet	0.088	0.940

Prédiction \ Réalité	Avion 1	Alphajet
Avion 1	0.718	0.092
Alphajet	0.282	0.908

semi-supervisé / non-supervisé & σ_2

Quelques résultats de classification...

En monospectral :

Prédiction \ Réalité	Avion 1	Alphajet
Avion 1	0.912	0.060
Alphajet	0.088	0.940

Prédiction \ Réalité	Avion 1	Alphajet
Avion 1	0.718	0.092
Alphajet	0.282	0.908

semi-supervisé / non-supervisé & σ_2

En multispectral :

Prédiction \ Réalité	Avion 1	Alphajet
Avion 1	0.89	0.07
Alphajet	0.11	0.93

non-supervisé & σ_2

Plan de la présentation

- 1 Contexte, problématique & résultats
 - Introduction
 - Détection de SIR multispectrales
 - Classification de SIR multispectrales
- 2 Deux problèmes de méthodologie statistique
 - Apprentissage séquentiel dans les modèles à données manquantes
 - Comparaison de chaînes de Markov inhomogènes
- 3 Questions ouvertes

Plan de la présentation

- 1 Contexte, problématique & résultats
 - Introduction
 - Détection de SIR multispectrales
 - Classification de SIR multispectrales
- 2 Deux problèmes de méthodologie statistique
 - Apprentissage séquentiel dans les modèles à données manquantes
 - Comparaison de chaînes de Markov inhomogènes
- 3 Questions ouvertes

Cadre de travail

(i) $\{Y_n, n \in \mathbb{N}\}$ observations *i.i.d.* d'une loi \mathbb{P}_\star **inconnue** sur (Y, \mathcal{Y}) ,

Cadre de travail

- (i) $\{Y_n, n \in \mathbb{N}\}$ observations *i.i.d.* d'une loi \mathbb{P}_* **inconnue** sur (Y, \mathcal{Y}) ,
- (ii) Présence d'un **processus latent** $\{X_n \in X, n \in \mathbb{N}\}$,

Cadre de travail

- (i) $\{Y_n, n \in \mathbb{N}\}$ observations *i.i.d.* d'une loi \mathbb{P}_* **inconnue** sur (Y, \mathcal{Y}) ,
- (ii) Présence d'un **processus latent** $\{X_n \in X, n \in \mathbb{N}\}$,
- (iii) **Modèle** données complètes $f_\theta : (X, Y) \rightarrow \mathbb{R}^+$ t.q. $\forall A \in \mathcal{Y}$

$$\mathbb{P}[Y_n \in A] = \mathbb{P}_\theta(A) = \int_A \underbrace{\int_X f_\theta(x_n, y_n) dx_n}_{f_\theta(y_n) \text{ (incalculable)}} dy_n,$$

Cadre de travail

- (i) $\{Y_n, n \in \mathbb{N}\}$ observations *i.i.d.* d'une loi \mathbb{P}_* **inconnue** sur (Y, \mathcal{Y}) ,
- (ii) Présence d'un **processus latent** $\{X_n \in X, n \in \mathbb{N}\}$,
- (iii) **Modèle** données complètes $f_\theta : (X, Y) \rightarrow \mathbb{R}^+$ t.q. $\forall A \in \mathcal{Y}$

$$\mathbb{P}[Y_n \in A] = \mathbb{P}_\theta(A) = \int_A \underbrace{\int_X f_\theta(x_n, y_n) dx_n}_{f_\theta(y_n) \text{ (incalculable)}} dy_n,$$

- (iv) Modèle **exponentiel**

$$\log f_\theta(x, y) = \psi(\theta) + S(x, y)^\top \phi(\theta),$$

Cadre de travail

- (i) $\{Y_n, n \in \mathbb{N}\}$ observations *i.i.d.* d'une loi \mathbb{P}_* **inconnue** sur (Y, \mathcal{Y}) ,
- (ii) Présence d'un **processus latent** $\{X_n \in X, n \in \mathbb{N}\}$,
- (iii) **Modèle** données complètes $f_\theta : (X, Y) \rightarrow \mathbb{R}^+$ t.q. $\forall A \in \mathcal{Y}$

$$\mathbb{P}[Y_n \in A] = \mathbb{P}_\theta(A) = \int_A \underbrace{\int_X f_\theta(x_n, y_n) dx_n}_{f_\theta(y_n) \text{ (incalculable)}} dy_n,$$

- (iv) Modèle **exponentiel**

$$\log f_\theta(x, y) = \psi(\theta) + S(x, y)^\top \phi(\theta),$$

- (v) Une **unique** observation est disponible à chaque instant (puis oubliée)

Cadre de travail

- (i) $\{Y_n, n \in \mathbb{N}\}$ observations *i.i.d.* d'une loi \mathbb{P}_\star **inconnue** sur (Y, \mathcal{Y}) ,
- (ii) Présence d'un **processus latent** $\{X_n \in X, n \in \mathbb{N}\}$,
- (iii) **Modèle** données complètes $f_\theta : (X, Y) \rightarrow \mathbb{R}^+$ t.q. $\forall A \in \mathcal{Y}$

$$\mathbb{P}[Y_n \in A] = \mathbb{P}_\theta(A) = \int_A \underbrace{\int_X f_\theta(x_n, y_n) dx_n}_{f_\theta(y_n) \text{ (incalculable)}} dy_n,$$

- (iv) Modèle **exponentiel**

$$\log f_\theta(x, y) = \psi(\theta) + S(x, y)^\top \phi(\theta),$$

- (v) Une **unique** observation est disponible à chaque instant (puis oubliée)

Problématique : trouver $\theta^\star \in \Theta$ t.q. $\mathbb{P}_{\theta^\star} \approx \mathbb{P}_\star$

Famille d'algorithmes Expectation-Maximization (EM)

- Densité de la distribution des données complètes vue par l'algorithme :

$$\pi_{\theta}(x, y) = \pi(y) \underbrace{\pi_{\theta}(x | y)}_{\propto f_{\theta}(x, y)},$$

- Séquence d'estimateurs $\{s_k, k \in \mathbb{N}\}$

$$s_0 \in S, \quad s_{k+1} = \bar{s} \circ \bar{\theta}(s_k) \quad \text{où} \quad \begin{cases} \bar{s} : \theta \rightarrow \mathbb{E}_{\pi_{\theta}} [S(X, Y)] \\ \bar{\theta} : s \rightarrow \arg \max_{\theta \in \Theta} \psi(\theta) + s^{\top} \phi(\theta) \end{cases}$$

- Si n observations $\{Y_1, \dots, Y_n\} \in Y^n$ constamment disponibles

$$\Rightarrow \pi(y) = (1/n) \sum_{k=1}^n \delta_{\{y_k\}}(y) \Rightarrow \text{EM "classique" (Dempster et al, 1977)}$$

$$\Rightarrow s_k \rightarrow s^* \in S_{\ell}^* := \{s \in S, \nabla_s \ell(\bar{\theta}(s) | Y_1, \dots, Y_n) = 0\}$$

Cas séquentiel

Dans ce cas on a $\pi(y) = \mathbb{P}_*(dy)$ (qui est inconnue)

- L'algorithme standard n'existe pas car

$$s_k = \int_Y \mathbb{E}_{\bar{\theta}(s_{k-1})}[S(X, Y) | Y = y] \mathbb{P}_*(dy)$$

- L'online EM (Cappé & Moulines, 2009), une **approximation stochastique** : séquence $\{\hat{s}_k, k \in \mathbb{N}\}$

$$\hat{s}_k = \hat{s}_{k-1} + \rho_k (\mathbb{E}_{\bar{\theta}(\hat{s}_{k-1})}[S(X_k, Y_k) | Y_k] - \hat{s}_{k-1}), \quad Y_k \sim \mathbb{P}_*$$

- Convergence

$$\hat{s}_k \rightarrow \hat{s}^* \in S_{\text{KL}}^* := \{s \in S, \nabla_s \text{KL}(\mathbb{P}_* \| \mathbb{P}_{\bar{\theta}(s)}) = 0\},$$

- Cas où $s \rightarrow \mathbb{E}_{\bar{\theta}(s)}[S(X_k, Y_k) | Y_k]$ non-calculable??

Monte-Carlo online EM (MCoEM)

- MCoEM : séquence $\{\tilde{s}_k, k \in \mathbb{N}\}$

$$(i) \quad Y_k \sim \mathbb{P}_*, \quad X_k^{(r)} \sim \pi_{\bar{\theta}(\tilde{s}_{k-1})}(\cdot | Y_k),$$

$$(ii) \quad \tilde{s}_k = \tilde{s}_{k-1} + \rho_k \left(\frac{1}{R} \sum_{r=1}^R S(X_k^{(r)}, Y_k) - \tilde{s}_{k-1} \right),$$

$(1/R) \sum_{r=1}^R S(X_k^{(r)}, Y_k)$ observation bruitée de s_k

- Convergence dans le cas où $\{X_k^{(1)}, \dots, X_k^{(R)}\} \stackrel{i.i.d.}{\sim} \pi_{\bar{\theta}(\tilde{s}_{k-1})}(\cdot | Y_k)$

$$\tilde{s}_k \rightarrow \tilde{s}^* \in S_{\text{KL}}^* .$$

Application à un mélange de modèles déformables

- Modèle vectoriel sachant $I_n = i \in \{1, \dots, C\}$, $\beta_n = \beta \in B$:

$$Y_n = \Phi_\beta \alpha_i + \sigma^2 W_n, \quad W_n \sim \mathcal{N}(0, \text{Id}_{|Y|})$$

- Loi *a posteriori* :

$$\pi_\theta(i, \beta | Y = y) \propto f_\theta(i, \beta, y) = g(y; \Phi_\beta \alpha_i, \sigma^2 \text{Id}_{|Y|}) p_{\gamma(i)}(\beta) \omega_i,$$

- Implémentation MCoEM pour modèles à prototype déformable :

$$\begin{aligned} (I^{(r)}, \beta^{(r)}) &\stackrel{i.i.d.}{\not\sim} \pi_\theta(\cdot | Y) \\ &\Downarrow \\ (I^{(r)}, \beta^{(r)}) &\sim P_\theta^{(r)}((i^{(0)}, \beta^{(0)}); \cdot | Y) \end{aligned}$$

Simulation des données manquantes par Carlin et Chib

- MCMC usuels (Gibbs, Metropolis) inefficaces sur l'espace $X = I \times B$

Simulation des données manquantes par Carlin et Chib

- MCMC usuels (Gibbs, Metropolis) inefficaces sur l'espace $X = I \times B$
- (Carlin & Chib, 1995) : MCMC sur $\tilde{X} = (I \times \underbrace{B \times \dots \times B}_C)$ visant

$$\forall (i, \beta_1, \dots, \beta_C) \in \tilde{X}, \quad \tilde{\pi}_\theta(i, \beta_1, \dots, \beta_C | Y) = \pi_\theta(i, \beta_i | Y) \prod_{j \neq i} \xi_j(\beta_j),$$

Simulation des données manquantes par Carlin et Chib

- MCMC usuels (Gibbs, Metropolis) inefficaces sur l'espace $X = I \times B$
- (Carlin & Chib, 1995) : MCMC sur $\tilde{X} = (I \times \underbrace{B \times \dots \times B}_C)$ visant

$$\forall (i, \beta_1, \dots, \beta_C) \in \tilde{X}, \quad \tilde{\pi}_\theta(i, \beta_1, \dots, \beta_C | Y) = \pi_\theta(i, \beta_i | Y) \prod_{j \neq i} \xi_j(\beta_j),$$

- **Pseudo-priors** : $\{\xi_i, i \in I\}$ densités sur (B, \mathcal{B})

$$\xi_i \approx \pi_\theta(\cdot | Y, i),$$

Simulation des données manquantes par Carlin et Chib

- MCMC usuels (Gibbs, Metropolis) inefficaces sur l'espace $X = I \times B$
- (Carlin & Chib, 1995) : MCMC sur $\tilde{X} = (I \times \underbrace{B \times \dots \times B}_C)$ visant

$$\forall (i, \beta_1, \dots, \beta_C) \in \tilde{X}, \quad \tilde{\pi}_\theta(i, \beta_1, \dots, \beta_C | Y) = \pi_\theta(i, \beta_i | Y) \prod_{j \neq i} \xi_j(\beta_j),$$

- **Pseudo-priors** : $\{\xi_i, i \in I\}$ densités sur (B, \mathcal{B})

$$\xi_i \approx \pi_\theta(\cdot | Y, i),$$

- Carlin et Chib est un Gibbs sur \tilde{X}

$$\{I^{(r)}, \beta_1^{(r)}, \dots, \beta_C^{(r)}, r \in \mathbb{N}\} \sim \tilde{\pi}_\theta(\cdot | Y) \implies \{I^{(r)}, \beta_{I^{(r)}}^{(r)}, r \in \mathbb{N}\} \sim \pi_\theta(\cdot | Y).$$

Illustration sur des images de chiffres manuscrits

Quatre *implémentations*

	Déformation	prior β	prior θ	nb Data
❶ MCoEM	locale	$\beta i \sim \mathcal{N}_{ \beta }(0, \gamma_i \text{Id}_{ \beta })$	non	3000
❷ MCoEM	locale + rigide	$\beta i \sim \mathcal{N}_{ \beta }(0, \gamma_i \text{Id}_{ \beta })$	non	3000
❸ MCoEM	locale	$\beta i \sim \mathcal{N}_{ \beta }(0, \Gamma_i)$	oui	3000
❹ SAEM	locale	$\beta i \sim \mathcal{N}_{ \beta }(0, \Gamma_i)$	oui	100

Illustration sur des images de chiffres manuscrits

Quatre implémentations

	Déformation	prior β	prior θ	nb Data
① MCoEM	locale	$\beta i \sim \mathcal{N}_{ \beta }(0, \gamma_i \text{Id}_{ \beta })$	non	3000
② MCoEM	locale + rigide	$\beta i \sim \mathcal{N}_{ \beta }(0, \gamma_i \text{Id}_{ \beta })$	non	3000
③ MCoEM	locale	$\beta i \sim \mathcal{N}_{ \beta }(0, \Gamma_i)$	oui	3000
④ SAEM	locale	$\beta i \sim \mathcal{N}_{ \beta }(0, \Gamma_i)$	oui	100



① - $\hat{\theta}_{3000}$




② - $\hat{\theta}_{3000}$


Illustration sur des images de chiffres manuscrits

Quatre implémentations

	Déformation	prior β	prior θ	nb Data
❶ MCoEM	locale	$\beta i \sim \mathcal{N}_{ \beta }(0, \gamma_i \text{Id}_{ \beta })$	non	3000
❷ MCoEM	locale + rigide	$\beta i \sim \mathcal{N}_{ \beta }(0, \gamma_i \text{Id}_{ \beta })$	non	3000
❸ MCoEM	locale	$\beta i \sim \mathcal{N}_{ \beta }(0, \Gamma_i)$	oui	3000
❹ SAEM	locale	$\beta i \sim \mathcal{N}_{ \beta }(0, \Gamma_i)$	oui	100




❶ - $\hat{\theta}_{3000}$



❸ - $\hat{\theta}_{3000}$



❷ - $\hat{\theta}_{3000}$



❹ - $\hat{\theta}_{100}$

Conclusion

■ Avantage du MCoEM

- + Cadre d'application plus général que l'online EM ,
- + Rapidité comparé au SAEM,
- + Complexité indépendante de n ,
- + Évaluer des tendances...

■ Limites

- Sensibilité Y ,
- Sensibilité $(I, \beta) \sim \pi_{\theta}(\cdot | Y)$,
- Convergence théorique $\hat{s}_k \rightarrow \hat{s}^* \in S_{KL}^*$ à prouver dans le cas non iid...

Plan de la présentation

- 1 Contexte, problématique & résultats
 - Introduction
 - Détection de SIR multispectrales
 - Classification de SIR multispectrales
- 2 Deux problèmes de méthodologie statistique
 - Apprentissage séquentiel dans les modèles à données manquantes
 - Comparaison de chaînes de Markov inhomogènes
- 3 Questions ouvertes

Définitions

- Soit π une distribution sur (X, \mathcal{X}) ,

$$\pi f := \int f(x)\pi(dx), \quad (\text{Quantité incalculable})$$

- MCMC : à partir d'un noyau de Markov $P : (X, \mathcal{X}) \rightarrow (0, 1)$

$$\widehat{\pi f}_n := \frac{1}{n} \sum_{k=1}^n f(X_k) \approx \pi f, \quad \text{où } X_k \sim P^k(x_0, \cdot)$$

- (Au minimum) $P : \pi$ -stationnaire *i.e*

$$\pi(A) = \int \pi(dx)P(x, A), \quad (\pi P = \pi)$$

- (Au mieux) $P : \pi$ -réversible *i.e*

$$\int_A \pi(dx)P(x, B) = \int_B \pi(dx)P(x, A).$$

Comparaison

Pour une quantité πf à estimer, un grand nombre de MCMC possibles

- P_0 et P_1 deux noyaux π -réversible
- Trouver une condition sur P_0 et P_1 telle que $\forall f \in \mathcal{F} \subseteq L_2(\pi)$:

$$v(f, P_0) \leq v(f, P_1),$$

où

$$v(f, P) := \lim_{n \rightarrow \infty} \frac{1}{n} \text{Var} \left(\sum_{k=0}^{n-1} f(X_k) \right) = \lim_{n \rightarrow \infty} \sqrt{n} \text{Var} (\hat{\pi}_n f) .$$

Comparer des noyaux?

- ordre **hors-diagonal** $P_1 \succeq P_0$:

$$\forall (x, A) \in (X, \mathcal{X}), \quad P_1(x, A \setminus \{x\}) \geq P_0(x, A \setminus \{x\}),$$

- ordre de **covariance** (d'ordre 1) $P_1 \succcurlyeq_1 P_0$:

$$\forall f \in L_2(\pi), \quad \langle f, P_1 f \rangle \leq \langle f, P_0 f \rangle,$$

$$\text{où } \langle f, g \rangle = \int f(x)g(x)\pi(dx).$$

Théorèmes (Peskun, 1973) & (Tierney, 1998) :

$$P_1 \succeq P_0 \implies P_1 \succcurlyeq_1 P_0 \implies v(f, P_1) \leq v(f, P_0)$$

Que peut-on dire pour les chaînes de Markov inhomogènes?

- Chaînes inhomogènes : $\{X_k, k \in \mathbb{N}\}$ évoluent suivant le schéma

$$\pi \sim X_0^{(i)} \xrightarrow{P_i} X_1^{(i)} \xrightarrow{Q_i} X_2^{(i)} \xrightarrow{P_i} X_3^{(i)} \xrightarrow{Q_i} \dots$$

- A-t-on un résultat *équivalent* à Tierney?
- Et si oui pour quel ensemble de fonctions $f \in F \subseteq L_2(\pi)$?

Théorème (Maire, Douc & Olsson, 2013) :

$$\left\{ \begin{array}{l} \forall f \in F \\ (P_0, P_1) \pi\text{-réversibles} \quad P_1 \succeq P_0 \\ (Q_0, Q_1) \pi\text{-réversibles} \quad Q_1 \succeq Q_0 \end{array} \right. \implies v(f, P_1, Q_1) \leq v(f, P_0, Q_0)$$

Une nouvelle preuve du Théorème de Tierney

- Tierney : décomposition spectrale des opérateurs auto-adjoints
(\Rightarrow restriction aux cas des chaînes homogènes...)
- Avec une hypothèse supplémentaire (qui définit F) pour $i \in \{0, 1\}$

$$(H1) \quad \sum_{k=1}^{\infty} \left(|\text{Cov}(f(X_0^{(i)}), f(X_k^{(i)}))| + |\text{Cov}(f(X_1^{(i)}), f(X_{k+1}^{(i)}))| \right) < \infty ,$$

on démontre le résultat de Tierney sans recours à la théorie spectrale avec bien sûr

(H2)-a P_1 et P_0 π -réversibles ,

(H2)-b $P_1 \succeq P_0$.

Squelette de la preuve...

(1) Pour $f \in F$ (H1) et P π -réversible (H2)

$$v(f, P) = \pi f^2 - \pi^2 f + 2 \sum_{n=0}^{\infty} \underbrace{\text{Cov}(f(X_1), f(X_n))}_{\langle f, P^n f \rangle},$$

(2) Définissons

$$\begin{cases} \forall \alpha \in (0, 1) & P_\alpha = (1 - \alpha)P_0 + \alpha P_1, \\ \forall \lambda \in (0, 1) & w_\lambda(f, P_\alpha) = \sum_{n=1}^{\infty} \lambda^n \langle f, P_\alpha^n f \rangle \end{cases}$$

(3) et montrons que $\forall \lambda \in (0, 1)$, $\alpha \rightarrow w_\lambda(f, P_\alpha)$ décroissante sur $(0, 1)$.

(4) Concluons par un théorème de convergence dominée $\lambda \rightarrow 1$:

$$\langle f, P_1^n f \rangle \leq \langle f, P_0^n f \rangle .$$

Corollaire pour schémas de Data Augmentation

- Data Augmentation :

$$\forall x \in X, x = \begin{bmatrix} z \in Z & \text{(paramètre d'intérêt)} \\ u \in U & \text{(variable auxiliaire)} \end{bmatrix}$$

- Problème : estimer πf , ($f \in F$) où

$$\forall x \in X, f(x) = f(z),$$

- $\{X_k^{(i)} = (Z_k^{(i)}, U_k^{(i)}), k \in \mathbb{N}\}$ de noyau $K^{(i)}$ non π -réversible
- $\{\tilde{X}_k^{(i)}, k \in \mathbb{N}\}$ de noyaux $(P^{(i)}, Q^{(i)})$ π -réversibles, t.q.

$$\forall k \in \mathbb{N}, \tilde{X}_{2k}^{(i)} = X_k^{(i)},$$

- Notre théorème donne :

$$\begin{cases} P^{(1)} \succeq P^{(0)} \\ Q^{(1)} \succeq Q^{(0)} \end{cases} \implies v(f, K^{(1)}) \leq v(f, K^{(0)}).$$

Utilité de ce résultat?

- Comparer des MCMC existants en les mettant sous le schéma $P \rightarrow Q \rightarrow P \rightarrow \dots$
 - ⇒ Possible de comparer des chaînes qui sont *a priori* homogènes et non réversibles
- Créer des MCMC
 - ⇒ En augmentant le taux de mélange dans la chaîne (par ex. en ajoutant des variables auxiliaires)
- Applications :
 - ⇒ Méthodes de Data-Augmentation,
 - ⇒ Algorithmes Pseudo-Marginal,
 - ⇒ MCMC pour des modèles de mélange (Carlin et Chib),
 - ⇒ Approximate Bayesian Computation,
 - ⇒ ...

Plan de la présentation

1 Contexte, problématique & résultats

- Introduction
- Détection de SIR multispectrales
- Classification de SIR multispectrales

2 Deux problèmes de méthodologie statistique

- Apprentissage séquentiel dans les modèles à données manquantes
- Comparaison de chaînes de Markov inhomogènes

3 Questions ouvertes

Détection & classification multispectrale

- Vers un modèle de prototype spectro-spatial...

$$Y_{n,k} = \int_{\nu_k}^{\nu_{k+1}} D \circ \mathcal{T}(u, \nu) d\nu + \sigma_k^2$$

- Pour une meilleure exploitation de l'information spectrale discriminante

Questions méthodologiques

- Vers une convergence théorique du MCoEM couplé avec un MCMC
- Cas des chaînes de Markov inhomogènes alternant entre n noyaux de transition

Des tests de détection non appropriés

- Test de rapport de vraisemblances (Neyman & Pearson, 1992) :

$$\phi(Y) \rightarrow \begin{cases} \mathcal{H}_0 & \text{si } \Lambda(Y) \leq \eta \\ \mathcal{H}_1 & \text{si } \Lambda(Y) > \eta \end{cases} \quad \text{où } \Lambda(Y) = \frac{\mu_1(Y)}{\mu_0(Y)} .$$

- D'autres tests nécessitent **une base d'apprentissage** pour estimer μ_1 ce que nous n'avons pas... (e.g GLRT)
- Test du Filtre adapté (Manolakis et al., 2003) : hypothèse que μ_1 est **Gaussienne** (non acceptable dans notre cas...)

Calibrage du test (1/2)

■ Contrôle du taux de fausse alarme :

⇒ Comme pour ϕ_{RX} , on souhaite connaître f telle que $(\eta, \nu) = f(p)$, où $p = P_{FA}(\phi)$

$$\begin{aligned} p &= \mathbb{P}[\max \text{Per}\{A_\eta(Y)\} > \nu \mid Y \in \mathcal{H}_0] , \\ &= \mathbb{P}\left[\underbrace{\max \text{Per}\{x \in \mathbb{R}^2, \sum_{j=1}^P \alpha_j \psi_j(x) > \eta\}}_{G_{\eta, \nu}(\alpha)} > \nu\right] \quad \text{où } \alpha_j \stackrel{iid}{\sim} \chi_K^2, \\ &= \mathbb{E}[\mathbb{1}_{G_{\eta, \nu}(\alpha)}] = \int \cdots \int \mathbb{1}_{G_{\eta, \nu}(\alpha)} \prod_{j=1}^P \chi_K^2(d\alpha_j) = h(\eta, \nu). \end{aligned}$$

- h n'est pas calculable explicitement, donc $f := h^{-1}$ (si h est inversible) non plus.

Calibrage du test (2/2)

- $p = h(\eta, \nu)$ non calculable
- Approximation de h par la fonction $(\hat{h}_n)_n$ telle que $\hat{h}_n \rightarrow h$ (convergence simple presque-sûrement par la LGN)


$$\hat{h}_n(\eta, \nu) := n^{-1} \sum_{\ell=1}^n \mathbb{1}_{G_{\eta, \nu}(\alpha^{(\ell)})}, \quad \alpha^{(\ell)} = (\alpha_1^{(\ell)}, \dots, \alpha_P^{(\ell)}) \sim \otimes_{\ell=1}^P \chi_K^2,$$

- Pour un taux de fausse alarme $p^* > 0$ fixé, calculer les seuils $\hat{\eta}_n^* > 0$ et $\hat{\nu}_n^* > 0$ définis par :

$$\hat{f}_n(p^*) := (\hat{\eta}_n^*, \hat{\nu}_n^*) := \arg \min_{\eta > 0, \nu > 0} |\hat{h}_n(\eta, \nu) - p^*|.$$

Information spatiale

Localisation d'une cible dans une image de taille 60×60 par ϕ




Y




$$\{D_M(y_j, \mu_0), 1 \leq j \leq P\}$$

Information spatiale

Localisation d'une cible dans une image de taille 60×60 par ϕ




Y




$\{D_M(y_j, \mu_0), 1 \leq j \leq P\}$

Information spatiale


Localisation d'une cible dans une image de taille 60×60 par ϕ



Y




$\{D_M(y_j, \mu_0), 1 \leq j \leq P\}$



$A_\eta(Y)$

Information spatiale


Localisation d'une cible dans une image de taille 60×60 par ϕ




Y



$\{D_M(y_j, \mu_0), 1 \leq j \leq P\}$




$A_\eta(Y)$




$\text{Per } A_\eta(Y) > \nu$

Information spatiale


Localisation d'une cible dans une image de taille 60×60 par ϕ




Y



$\{D_M(y_j, \mu_0), 1 \leq j \leq P\}$



$A_\eta(Y)$



$\text{Per } A_\eta(Y) > \nu$

	Niveau pixel		Niveau image	
	$P_D(\phi)$	$P_{FA}(\phi)$	$P_D(\phi)$	$P_{FA}(\phi)$
data mélangé	0.4	0.003	0.976	0.003
data : avion A	0.4	0.004	0.982	0.004
data : avion B	0.5	0.002	0.971	0.005

Approximation Stochastique

Rechercher les racines d'une fonction non connue explicitement

- Soit $h : S \rightarrow \mathbb{R}$

$$S^* = \{s \in S, \quad h(s) = 0\}$$

- Approximation stochastique (Robbins & Monro, 1951)

$$\hat{s}_0 \in S, \quad \hat{s}_{n+1} = \hat{s}_n + \rho_{n+1} \underbrace{(h(s_n) + \zeta_n)}_{\hat{h}_n},$$

où

- \hat{h}_n est une observation bruitée de $h(s_n)$,
- $\{\rho_n, n \in \mathbb{N}\}$ une séquence décroissante de nombres positifs,

$$\begin{cases} \rho_n \rightarrow 0 \\ \sum_{n \geq 1} \rho_n = \infty \end{cases}$$

- $\{\zeta_n, n \in \mathbb{N}\}$ un processus aléatoire de bruit.

Convergence Approximation Stochastique

Théorème de convergence (Andrieu, Moulines & Priouret, 2005)

Principales conditions :

- Existence d'une fonction de Lyapunov $w : S \rightarrow \mathbb{R}$ pour h t.q.

$$\forall s \in S, \quad \langle \nabla_s w(s), h(s) \rangle \leq 0 \quad \& \quad \langle \nabla_s w(s), h(s) \rangle = 0 \Leftrightarrow h(s) = 0$$

- Contrôle du bruit

$$\lim_{n \rightarrow \infty} \sup_{\ell \geq k} \left| \sum_{k=n}^{\ell} \rho_k \zeta_k \right| = 0$$

Alors

$$s_n \rightarrow s^* \in S^* \quad \text{w.p.1}$$

■ Soit $h = \bar{s} \circ \bar{\theta} - Id$

$$\forall s \in S, \quad h(s) = 0 \iff \nabla_s \ell(\bar{\theta}(s) | Y_1, \dots, Y_n) = 0,$$

EM stochastique

- Soit $h = \bar{s} \circ \bar{\theta} - Id$

$$\forall s \in S, \quad h(s) = 0 \iff \nabla_s \ell(\bar{\theta}(s) | Y_1, \dots, Y_n) = 0,$$

Hypothèses:

- (i) $\bar{s} : \theta \rightarrow \sum_{i=1}^n \mathbb{E}_\theta [S(X_i, Y_i) | Y_i]$ non calculable
- (ii) versions bruitées $\tilde{s}(\theta_k) = \bar{s}(\theta_k) + \zeta_k$ observées

EM stochastique

- Soit $h = \bar{s} \circ \bar{\theta} - Id$

$$\forall s \in S, \quad h(s) = 0 \iff \nabla_s \ell(\bar{\theta}(s) | Y_1, \dots, Y_n) = 0,$$

Hypothèses:

- (i) $\bar{s} : \theta \rightarrow \sum_{i=1}^n \mathbb{E}_\theta [S(X_i, Y_i) | Y_i]$ non calculable
 - (ii) versions bruitées $\tilde{s}(\theta_k) = \bar{s}(\theta_k) + \zeta_k$ observées
- Possible de trouver les racines de h à partir de \tilde{s} en remplaçant

$$s_k = \bar{s}(\theta_k) \quad \text{par} \quad \hat{s}_k = \hat{s}_{k-1} + \rho_k(\tilde{s}(\theta_{k-1}) - \hat{s}_{k-1}),$$

EM stochastique

- Soit $h = \bar{s} \circ \bar{\theta} - Id$

$$\forall s \in S, \quad h(s) = 0 \iff \nabla_s \ell(\bar{\theta}(s) | Y_1, \dots, Y_n) = 0,$$

Hypothèses:

- (i) $\bar{s} : \theta \rightarrow \sum_{i=1}^n \mathbb{E}_\theta [S(X_i, Y_i) | Y_i]$ non calculable
 - (ii) versions bruitées $\tilde{s}(\theta_k) = \bar{s}(\theta_k) + \zeta_k$ observées
- Possible de trouver les racines de h à partir de \tilde{s} en remplaçant

$$s_k = \bar{s}(\theta_k) \quad \text{par} \quad \hat{s}_k = \hat{s}_{k-1} + \rho_k(\tilde{s}(\theta_{k-1}) - \hat{s}_{k-1}),$$

- Preuve de convergence de $\{\hat{s}_k, k \in \mathbb{N}\}$ vers $S^* := \{s \in S, h(s) = 0\}$
(Robbins-Monro)

EM stochastique

- Soit $h = \bar{s} \circ \bar{\theta} - Id$

$$\forall s \in S, \quad h(s) = 0 \iff \nabla_s \ell(\bar{\theta}(s) | Y_1, \dots, Y_n) = 0,$$

Hypothèses:

- (i) $\bar{s} : \theta \rightarrow \sum_{i=1}^n \mathbb{E}_\theta [S(X_i, Y_i) | Y_i]$ non calculable
 - (ii) versions bruitées $\tilde{s}(\theta_k) = \bar{s}(\theta_k) + \zeta_k$ observées
- Possible de trouver les racines de h à partir de \tilde{s} en remplaçant

$$s_k = \bar{s}(\theta_k) \quad \text{par} \quad \hat{s}_k = \hat{s}_{k-1} + \rho_k(\tilde{s}(\theta_{k-1}) - \hat{s}_{k-1}),$$

- Preuve de convergence de $\{\hat{s}_k, k \in \mathbb{N}\}$ vers $S^* := \{s \in S, h(s) = 0\}$ (Robbins-Monro)
- $\{\hat{\theta}_k, k \in \mathbb{N}\}$ devient **stochastique** \Rightarrow SAEM, SAEM-MCMC...

Reformulation

- Soit π la loi des données utilisées lors de l'inférence

Reformulation

- Soit π la loi des données utilisées lors de l'inférence
- Dans le cas de EM : loi uniforme sur (Y_1, \dots, Y_n) ,

$$\pi^{(n)}(dy) = 1/n \sum_{k=1}^n \delta_{Y_k}(dy) ,$$

Reformulation

- Soit π la loi des données utilisées lors de l'inférence
- Dans le cas de EM : loi uniforme sur (Y_1, \dots, Y_n) ,

$$\pi^{(n)}(dy) = 1/n \sum_{k=1}^n \delta_{Y_k}(dy) ,$$

- Remarque :

$$\bar{s} \circ \bar{\theta}(s) = \frac{1}{n} \sum_{k=1}^n \int_{\mathcal{X}} S(x_k, Y_k) \pi_{\bar{\theta}(s)}(dx_k | Y_k) = \iint_{\mathcal{Y}\mathcal{X}} S(x, y) \pi^{(n)}(dx, dy) ,$$

$$\text{où } \pi^{(n)}(dx, dy) = \pi^{(n)}(dy) \pi_{\bar{\theta}(s)}(dx | y)$$

Reformulation

- Soit π la loi des données utilisées lors de l'inférence
- Dans le cas de EM : loi uniforme sur (Y_1, \dots, Y_n) ,

$$\pi^{(n)}(dy) = 1/n \sum_{k=1}^n \delta_{Y_k}(dy) ,$$

- Remarque :

$$\bar{s} \circ \bar{\theta}(s) = \frac{1}{n} \sum_{k=1}^n \int_{\mathcal{X}} S(x_k, Y_k) \pi_{\bar{\theta}(s)}(dx_k | Y_k) = \iint_{\mathcal{Y} \times \mathcal{X}} S(x, y) \pi^{(n)}(dx, dy) ,$$

$$\text{où } \pi^{(n)}(dx, dy) = \pi^{(n)}(dy) \pi_{\bar{\theta}(s)}(dx | y)$$

- Réécriture de h :

$$h(s) = (1/n) \sum_{k=1}^n \mathbb{E}_{\bar{\theta}(s)}[S(X_k, Y_k) | Y_k] - s = \mathbb{E}_{\text{inf}, \bar{\theta}(s)}^{(n)}[S(X, Y)] - s .$$

Equivalence en apprentissage séquentiel

- Dans le cas séquentiel à l'itération n , une seule observation $Y_n \sim \mathbb{P}_*$

$$\pi(dy) = \mathbb{P}_*(dy) ,$$

Equivalence en apprentissage séquentiel

- Dans le cas séquentiel à l'itération n , une seule observation $Y_n \sim \mathbb{P}_*$

$$\pi(dy) = \mathbb{P}_*(dy) ,$$

- h incalculable car \mathbb{P}_* inconnue

$$h(s) = \int_Y \int_X S(x, y) \pi_{\bar{\theta}(s)}(dx | y) \mathbb{P}_*(dy) - s ,$$

Equivalence en apprentissage séquentiel

- Dans le cas séquentiel à l'itération n , une seule observation $Y_n \sim \mathbb{P}_*$

$$\pi(dy) = \mathbb{P}_*(dy),$$

- h incalculable car \mathbb{P}_* inconnue

$$h(s) = \int_Y \int_X S(x, y) \pi_{\bar{\theta}(s)}(dx | y) \mathbb{P}_*(dy) - s,$$

- online EM : approximation stochastique de h par

$$\tilde{h}(s) = \int_X S(x, Y_n) \pi_{\bar{\theta}(s)}(dx | Y_n) - s,$$

Double approximation stochastique : MCoEM

- **Deux** intégrales incalculables

$$h(s) = \int_Y \int_X S(x, y) \pi_{\bar{\theta}(s)}(dx | y) \mathbb{P}_*(dy) - s ,$$

Double approximation stochastique : MCoEM

- **Deux** intégrales incalculables

$$h(s) = \int_Y \int_X S(x, y) \pi_{\bar{\theta}(s)}(dx | y) \mathbb{P}_*(dy) - s ,$$

- MCoEM: *Double approximation stochastique* de h par

$$\check{h}(s) = \frac{1}{R} \sum_{r=1}^R S(X_n^{(r)}, Y_n) - s , \quad Y_n \sim \mathbb{P}_*, \quad X_n^{(r)} \sim \pi_{\bar{\theta}(s)}(\cdot | Y_n) ,$$

Double approximation stochastique : MCoEM

- Deux intégrales incalculables

$$h(s) = \int_Y \int_X S(x, y) \pi_{\bar{\theta}(s)}(dx | y) \mathbb{P}_*(dy) - s ,$$

- MCoEM: Double approximation stochastique de h par

$$\check{h}(s) = \frac{1}{R} \sum_{r=1}^R S(X_n^{(r)}, Y_n) - s , \quad Y_n \sim \mathbb{P}_*, X_n^{(r)} \sim \pi_{\bar{\theta}(s)}(\cdot | Y_n) ,$$

- Convergence dans le cas où $\{X_n^{(1)}, \dots, X_n^{(R)}\} \stackrel{i.i.d.}{\sim} \pi_{\hat{\theta}_{n-1}}(\cdot | Y_n)$

$$\hat{\theta}_n \rightarrow \theta^* \in \Theta_{\text{KL}}^* := \{\theta \in \Theta, \nabla_{\theta} \text{KL}(\mathbb{P}_* \| \mathbb{P}_{\theta}) = 0\} ,$$

Comparaison bloc / en ligne

$$h(s) = \mathbb{E}_\pi \mathbb{E}_{\tilde{\theta}(s)} [S(X, Y) | Y] - s$$

	En bloc		En ligne	
distribution obs. propriété convergence dynamique (argument)	$\pi^{(n)}(dy) = n^{-1} \sum_{k=1}^n \delta_{Y_k}(dy)$ $h(s) = 0 \Leftrightarrow \nabla_\theta \ell(\theta Y_1, \dots, Y_n) = 0$ $\{\theta_k, k \in \mathbb{N}\} \rightarrow \nabla_\theta \ell(\theta Y_1, \dots, Y_n) = 0$ $\ell(\theta_{k+1} Y_1, \dots, Y_n) \leq \ell(\theta_k Y_1, \dots, Y_n)$ (inégalité Jensen)		$\pi(dy) = \mathbb{P}_*(dy)$ $h(s) = 0 \Leftrightarrow \nabla_\theta \text{KL}(\mathbb{P}_* \ \mathbb{P}_\theta) = 0$ $\{\theta_k, k \in \mathbb{N}\} \rightarrow \nabla_\theta \text{KL}(\mathbb{P}_* \ \mathbb{P}_\theta) = 0$ $\text{KL}(\mathbb{P}_* \ \mathbb{P}_{\theta_{k+1}}) \leq \text{KL}(\mathbb{P}_* \ \mathbb{P}_{\theta_k})$ (existence fonction de Lyapunov)	
algorithmes	EM	SAEM	online EM	MCoEM
$\mathbb{E}_{\text{inf}}[G(Y)]$ $\mathbb{E}_\theta[S(X, Y) Y]$ Approx. sto.	exacte exacte non	exacte $\approx \frac{1}{R} \sum_{k=1}^R S(X^{(r)}, Y)$ oui	$\approx G(Y_n)$ exacte oui	$\approx G(Y_n)$ $\approx \frac{1}{R} \sum_{k=1}^R S(X_n^{(r)}, Y_n)$ oui

Simulation Pseudo-priors

- Heuristique : $\{X_r^{(i)}, r \in \mathbb{N}\}$ visant $\pi_{\hat{\theta}}(\cdot | Y, i)$
- $\varrho_i = \mathcal{N}(\hat{\mu}^{(i)}, \hat{\Sigma}^{(i)})$





Illustration Carlin & Chib



Gibbs / Carlin & Chib





Illustration échantillonnage

En régime stationnaire




Illustration échantillonnage

En régime stationnaire

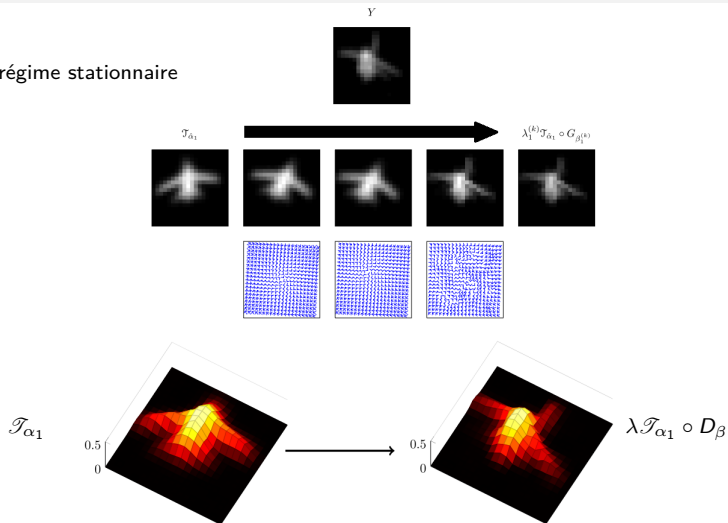


Illustration échantillonnage

En régime stationnaire

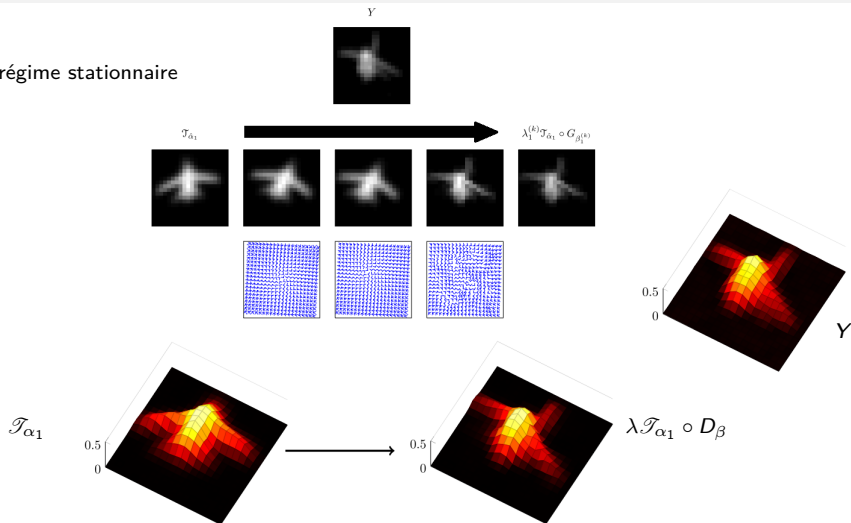



Illustration apprentissage (monospectral & semi-supervisé)

Estimation des prototypes pour deux niveaux de bruit et $C = 3$ classes




Exemples d'observations traitées

Evolution des estimateurs

Illustration apprentissage (monospectral & semi-supervisé)

Estimation des prototypes pour deux niveaux de bruit et $C = 3$ classes




Exemples d'observations traitées


Evolution des estimateurs

Illustration apprentissage (non-supervisé)

En monospectral :
($C = 2$)




σ_1




σ_2

Illustration apprentissage (non-supervisé)

En monospectral :
($C = 2$)




σ_1




σ_2

En multispectral :
($C = 4$)




σ_2



The mixture Model problem

Rewriting the Gibbs and the Carlin and Chib samplers:

$$P_G \begin{cases} I_n^{(G)} \sim \pi(\cdot | x) \\ X_n^{(G)} \sim \delta_x(\cdot) \end{cases} \qquad Q_G \begin{cases} I_{n+1}^{(G)} \sim \delta_{i'}(\cdot) \\ X_{n+1}^{(G)} \sim \pi(\cdot | i') \end{cases}$$



$$P_{CC} \begin{cases} \forall i \neq j \ U_i \sim \zeta_i(\cdot) \\ U_j \sim \delta_x(\cdot) \\ I_n^{(CC)} \sim \pi(\cdot | u_1, \dots, u_C) \end{cases} \qquad Q_{CC} \begin{cases} I_{n+1}^{(CC)} \sim \delta_{i'}(\cdot) \\ X_{n+1}^{(CC)} \sim \pi(\cdot | i') \end{cases}$$

(i) P_{CC} is π -reversible, (ii) $Q_{CC} = Q_G$, (iii) $P_{CC} \stackrel{?}{\succeq} P_G \Rightarrow v(f, CC) \leq v(f, G)$.

Pseudo-Marginal Algorithms

Pseudo-Marginal (Andrieu & Robert, 2009): no exact expression of the target distribution π e.g

$$\pi(x) = \int \pi(x, du)$$

for all $(x, x') \in X^2$, $\pi(x)/\pi(x')$ intractable

⇒ Idea: simulate a Markov chain targeting

$$\tilde{\pi}(dx, du) = \underbrace{\pi(dx)w_u(x)}_{\hat{\pi}_u(dx), \text{calculable}} \underbrace{R(x, du)}_{\text{samplable}}$$

(note that $\int \tilde{\pi}(x, du) = \pi(x)$)

For example, use Importance Sampling estimate:

$$\hat{\pi}_u(x) = \frac{1}{n} \sum_{k=1}^n \frac{\pi(x, u^{(k)})}{R(x, u^{(k)})}, \quad U^{(k)} \stackrel{i.i.d}{\sim} R(x, \cdot).$$

Monte Carlo within Metropolis (MCWM)

A Markov chain $\{X_n, n \in \mathbb{N}\}$ on (X, \mathcal{X}) : given $X_n = x$, X_{n+1} is obtained as follows

- (i) propose $X' \sim K(x, \cdot)$
- (ii) simulate aux. var. for both states X_n and X' :
 $U \sim R(x, \cdot), U' \sim R(x', \cdot)$
- (iii) accept $X_{n+1} = x'$ w.p

$$\hat{\alpha}(x, x', u, u') = 1 \wedge \frac{\hat{\pi}_{u'}(x')K(x', x)}{\hat{\pi}_u(x)K(x, x')}$$

MCWM is not π -reversible but targets an approximate of $\pi(x)$...
 \Rightarrow noisy algorithm!

Grouped-Independence Metropolis Hastings (GIMH)

A Markov chain $\{(X_n, U_n), n \in \mathbb{N}\}$ targeting $\tilde{\pi}$ such that given $(X_n, U_n) = (x, u)$, (X_{n+1}, U_{n+1}) is obtained as follows

- (i) propose $X' \sim K(x, \cdot)$
- (ii) simulate aux. var. for the state X' : $U' \sim R(x', \cdot)$
- (iii) accept $(X_{n+1}, U_{n+1}) = (x', u')$ w.p

$$\hat{\alpha}((x, u), (x', u')) = 1 \wedge \frac{\hat{\pi}_{u'}(x')K(x', x)}{\hat{\pi}_u(x)K(x, x')}$$

GIMH is **Metropolis-Hastings** algorithm $\Rightarrow \tilde{\pi}$ -reversible.

Remark

- MCWM & GIMH cannot be properly compared with Tierney's Theorem
- They may be rewritten artificially as:

$$\text{MCWM:} \quad \begin{pmatrix} X_n^{(M)} \\ U \end{pmatrix} \xrightarrow{P_M} \begin{pmatrix} X_n^{(M)} \\ U \end{pmatrix} \xrightarrow{Q} \begin{pmatrix} X_{n+1}^{(M)} \\ U \end{pmatrix} \xrightarrow{P_M} \dots$$

$$\text{GIMH:} \quad \begin{pmatrix} X_n^{(G)} \\ U_n^{(G)} \end{pmatrix} \xrightarrow{P_G} \begin{pmatrix} X_n^{(G)} \\ U_n^{(G)} \end{pmatrix} \xrightarrow{Q} \begin{pmatrix} X_{n+1}^{(G)} \\ U_{n+1}^{(G)} \end{pmatrix} \xrightarrow{P_G} \dots$$

A Random-Refreshment Pseudo Marginal algorithm

A Markov chain $\{(X_n, U_n), n \in \mathbb{N}\}$ targeting $\tilde{\pi}$ such that given $(X_n, U_n) = (x, u)$, (X_{n+1}, U_{n+1}) is obtained as follows:

- (i) (a) propose a new aux. var. for state X ; $\tilde{U} \sim R(x, \cdot)$
(b) refresh the aux. var. U_n by \tilde{U} with a certain probability $\omega_{u, \tilde{u}}$
- (ii) propose $X' \sim K(x, \cdot)$
- (iii) simulate aux. var. for the state X' : $U' \sim R(x', \cdot)$
- (iv) accept $(X_{n+1}, U_{n+1}) = (x', u')$ w.p

$$\hat{\alpha}((x, u), (x', u')) = 1 \wedge \frac{\hat{\pi}_{u'}(x')K(x', x)}{\hat{\pi}_u(x)K(x, x')}$$

Comparing GIMH & Random Refreshment

GIMH:
$$\begin{pmatrix} X_n^{(G)} \\ U_n^{(G)} \end{pmatrix} \xrightarrow{P_G} \begin{pmatrix} X_n^{(G)} \\ U_n^{(G)} \end{pmatrix} \xrightarrow{Q} \begin{pmatrix} X_{n+1}^{(G)} \\ U_{n+1}^{(G)} \end{pmatrix} \xrightarrow{P_G} \dots$$

Random Refreshment:
$$\begin{pmatrix} X_n^{(R)} \\ U_n^{(R)} \end{pmatrix} \xrightarrow{P_R} \begin{pmatrix} X_n^{(R)} \\ \tilde{U} \end{pmatrix} \xrightarrow{Q} \begin{pmatrix} X_{n+1}^{(R)} \\ U_{n+1}^{(R)} \end{pmatrix} \xrightarrow{P_G} \dots$$

Our Theorem holds and show that for any $f \in F$

$$v(f, R) \leq v(f, G) .$$