Contributions à l'analyse de données temporelles

Ahlame Douzal

AMA
Laboratoire d'Informatique de Grenoble
Université Joseph Fourier

29 Novembre 2012

Introduction

Données temporelles

Définition

- Un cas particulier de données de séquences :
  - une suite ordonnée d'observations
  - critère d'ordre temporel

Omniprésence des données temporelles

- Analyse de comportements d'utilisateurs du web
- Analyse de l'évolution structurelle ou informationnelle au sein de réseaux sociaux
- Analyse de courbes de charge de consommation d'énergie
- Analyse de données issues de réseaux de capteurs

Données temporelles

Définition

- Un cas particulier de données de séquences :
  - une suite ordonnée d'observations
  - critère d'ordre temporel

Omniprésence des données temporelles

- Analyse de comportements d'utilisateurs du web
- Analyse de l'évolution structurelle ou informationnelle au sein de réseaux sociaux
- Analyse de courbes de charge de consommation d'énergie
- Analyse de données issues de réseaux de capteurs

Positionnement : analyse de données et structures *a priori*

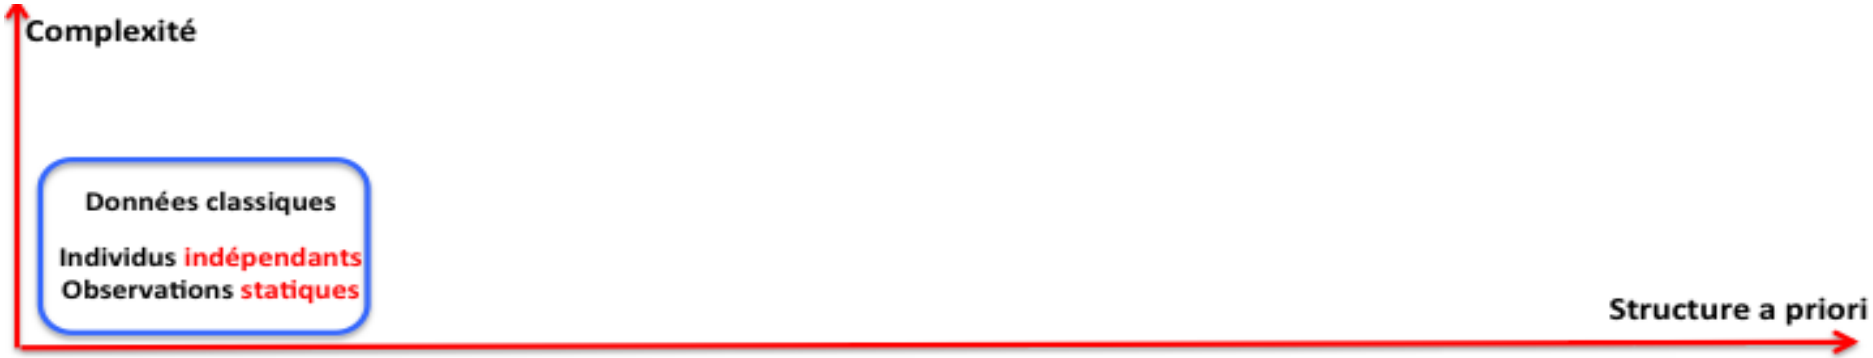

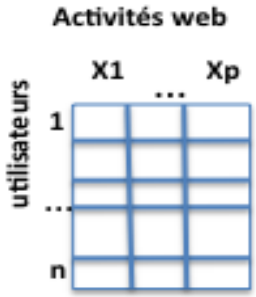

- Identifier des classes d'usage du web
- Mesurer des dépendances entre type d'activités

Positionnement : analyse de données et structures *a priori*

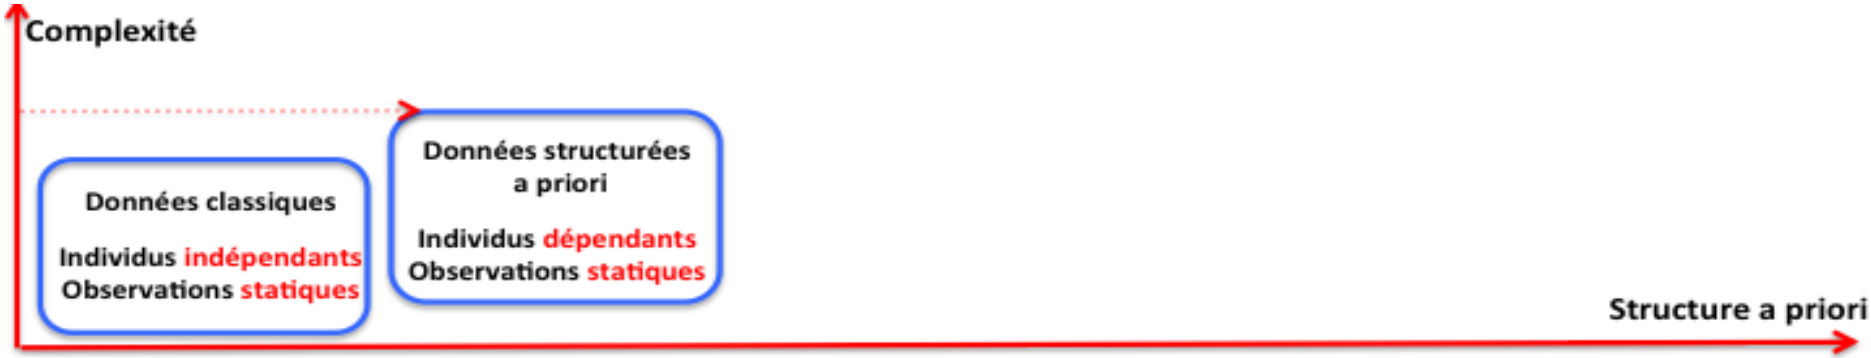

Activités web

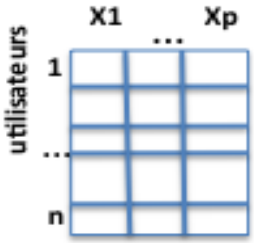

- Identifier des classes d'usage du web
- Mesurer des dépendances entre type d'activités

Liens entre utilisateurs

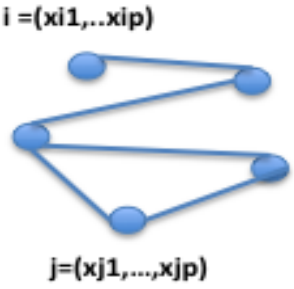

- Mesurer la dépendance entre l'information structurelle et informationnelle
- Identifier les activités homogènes dans les voisinage (hot spot)

Positionnement : analyse de données et structures *a priori*

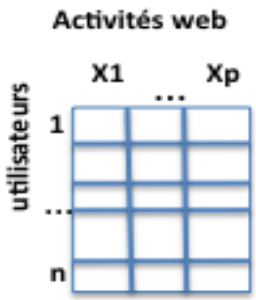

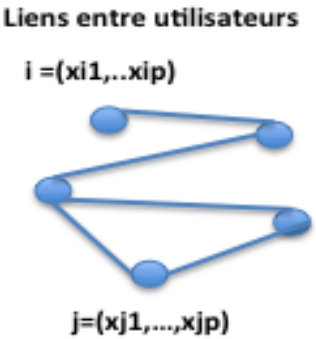

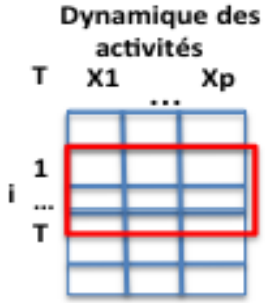

- Identifier des classes d'usage du web
- Mesurer des dépendances entre type d'activités

- Mesurer la dépendance entre l'information structurelle et informationnelle
- Identifier les activités homogènes dans les voisinage (hot spot)

- Prédire un comportement type d'usage
- Identifier les caractéristiques dynamiques d'une classe d'usage

Positionnement : analyse de données et structures *a priori*

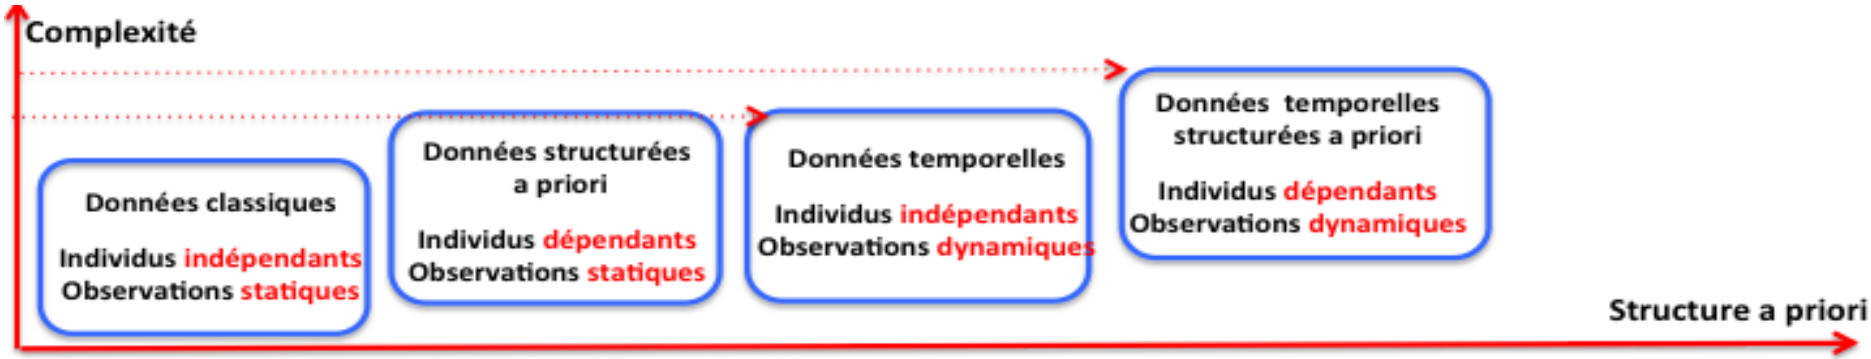

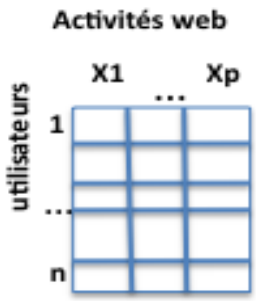

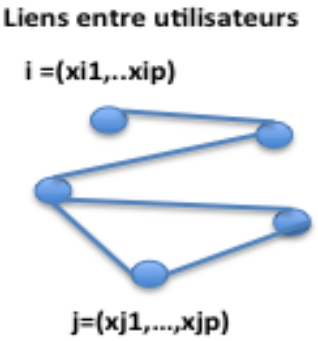

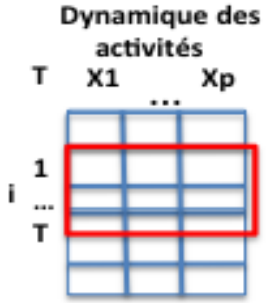

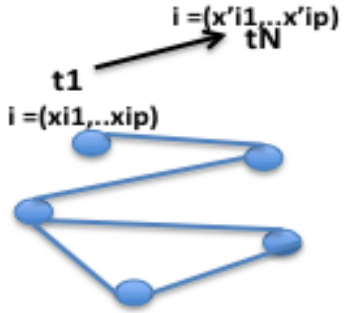

- Identifier des classes d'usage du web
- Mesurer des dépendances entre type d'activités

- Mesurer la dépendance entre l'information structurelle et informationnelle
- Identifier les activités homogènes dans les voisinage (hot spot)

- Prédire un comportement type d'usage
- Identifier les caractéristiques dynamiques d'une classe d'usage

- Mesurer la dépendance entre les dynamiques observées et la structure
- Définir une cartographie des dynamiques

Positionnement : analyse de données et structures *a priori*

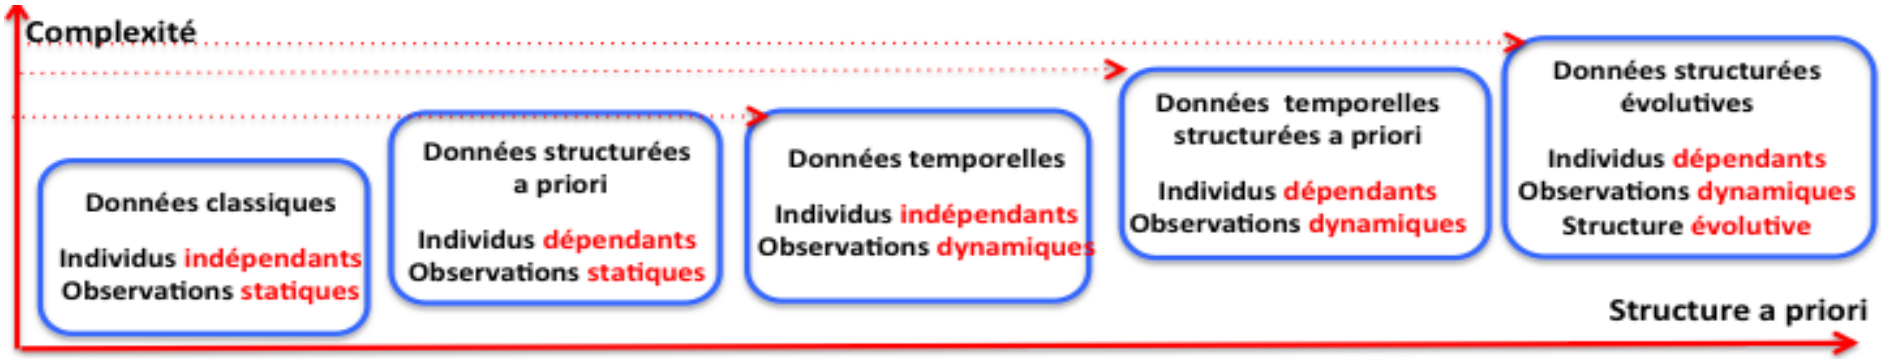

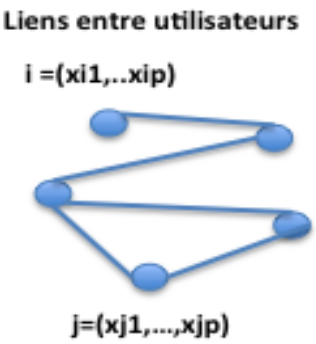

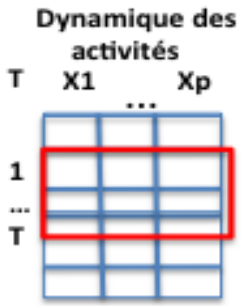

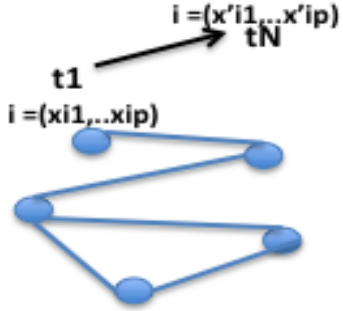

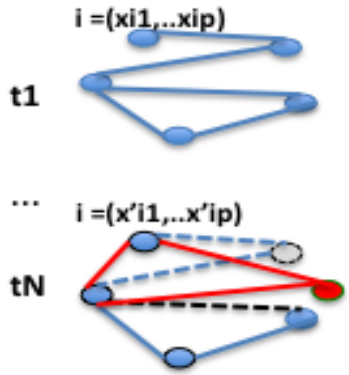

- Identifier des classes d'usage du web
- Mesurer des dépendances entre type d'activités

- Mesurer la dépendance entre l'information structurelle et informationnelle
- Identifier les activités homogènes dans les voisinage (hot spot)

- Prédire un comportement type d'usage
- Identifier les caractéristiques dynamiques d'une classe d'usage

- Mesurer la dépendance entre les dynamiques observées et la structure
- Définir une cartographie des dynamiques

- Identifier les relations ou structures stables
- Mesurer l'effet de la structure évolutive sur les observations
- Prédire l'apparition de liens ou nœuds

Positionnement : analyse de données et structures *a priori*

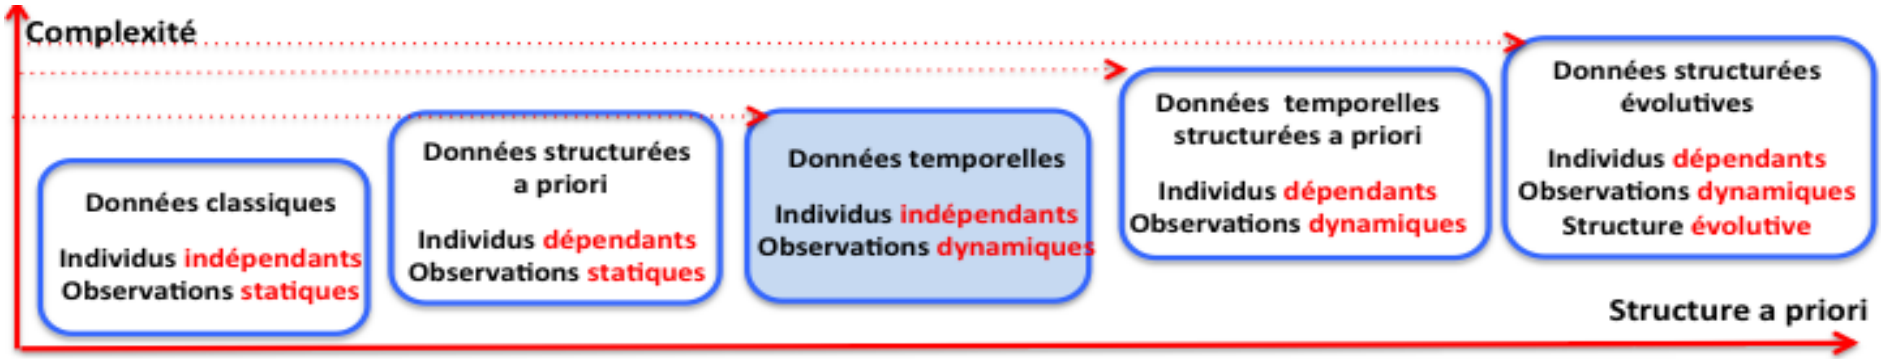

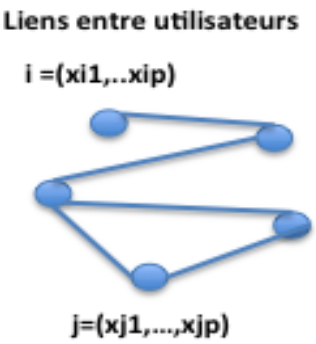

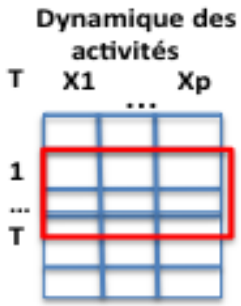

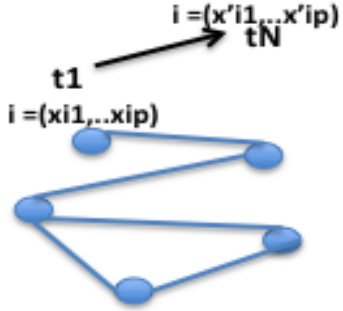

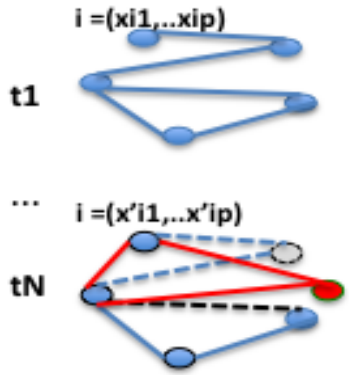

- Identifier des classes d'usage du web
- Mesurer des dépendances entre type d'activités

- Mesurer la dépendance entre l'information structurelle et informationnelle
- Identifier les activités homogènes dans les voisinage (hot spot)

- Prédire un comportement type d'usage
- Identifier les caractéristiques dynamiques d'une classe d'usage

- Mesurer la dépendance entre les dynamiques observées et la structure
- Définir une cartographie des dynamiques

- Identifier les relations ou structures stables
- Mesurer l'effet de la structure évolutive sur les observations
- Prédire l'apparition de liens ou nœuds

Analyse de données temporelles

- **Représentation des données temporelles**
- **Définition et apprentissage de métriques**
- **Classification et prédiction de données temporelles**

Analyse de données temporelles

Représentation des données temporelles

- Segmentation : représentation compacte de séries multivariées
  - Collaborations avec G. Benchetrit PRETA (TIMC-IMAG) et C. Garbay, encadrements de masters 2R

Métriques associées aux données temporelles

- Appariements discriminants : discrimination de classes de séries
  - Thèse C. Frambourg (MENRT, soutenance janvier 2013)
  - Co-direction avec J. Demongeot (TIMC-IMAG)
  - Collaboration avec E. Gaussier
- "Forme" des séries : métriques intégrant la forme des séries
  - Thèse A. Diallo (soutenue en 2010)
  - Co-direction avec F. Giroud (TIMC-IMAG)
  - Collaboration avec P. Nagabhushan (Université de Mysore), encadrement de masters 2R

Classification et prédiction de données temporelles

- Classification par arbre : extension des arbres de classification à des séries
  - Collaboration avec C. Amblard (AMA), encadrement de masters 2R

Analyse de données temporelles

Représentation des données temporelles

- Segmentation : représentation compacte de séries multivariées
  - Collaborations avec G. Benchetrit PRETA (TIMC-IMAG) et C. Garbay, encadrements de masters 2R

Métriques associées aux données temporelles

- Appariements discriminants : discrimination de classes de séries
  - Thèse C. Frambourg (MENRT, soutenance janvier 2013)
  - Co-direction avec J. Demongeot (TIMC-IMAG)
  - Collaboration avec E. Gaussier
- "Forme" des séries : métriques intégrant la forme des séries
  - Thèse A. Diallo (soutenue en 2010)
  - Co-direction avec F. Giroud (TIMC-IMAG)
  - Collaboration avec P. Nagabhushan (Université de Mysore), encadrement de masters 2R

Classification et prédiction de données temporelles

- Classification par arbre : extension des arbres de classification à des séries
  - Collaboration avec C. Amblard (AMA), encadrement de masters 2R

Analyse de données temporelles

Représentation des données temporelles

- Segmentation : représentation compacte de séries multivariées
  - Collaborations avec G. Benchetrit PRETA (TIMC-IMAG) et C. Garbay, encadrements de masters 2R

Métriques associées aux données temporelles

- Appariements discriminants : discrimination de classes de séries
  - Thèse C. Frambourg (MENRT, soutenance janvier 2013)
  - Co-direction avec J. Demongeot (TIMC-IMAG)
  - Collaboration avec E. Gaussier
- "Forme" des séries : métriques intégrant la forme des séries
  - Thèse A. Diallo (soutenue en 2010)
  - Co-direction avec F. Giroud (TIMC-IMAG)
  - Collaboration avec P. Nagabhushan (Université de Mysore), encadrement de masters 2R

Classification et prédiction de données temporelles

- Classification par arbre : extension des arbres de classification à des séries
  - Collaboration avec C. Amblard (AMA), encadrement de masters 2R

Analyse de données temporelles

Représentation des données temporelles

- Segmentation : représentation compacte de séries multivariées
  - Collaborations avec G. Benchetrit PRETA (TIMC-IMAG) et C. Garbay, encadrements de masters 2R

Métriques associées aux données temporelles

- Appariements discriminants : discrimination de classes de séries
  - Thèse C. Frambourg (MENRT, soutenance janvier 2013)
  - Co-direction avec J. Demongeot (TIMC-IMAG)
  - Collaboration avec E. Gaussier
- "Forme" des séries : métriques intégrant la forme des séries
  - Thèse A. Diallo (soutenue en 2010)
  - Co-direction avec F. Giroud (TIMC-IMAG)
  - Collaboration avec P. Nagabhushan (Université de Mysore), encadrement de masters 2R

Classification et prédiction de données temporelles

- Classification par arbre : extension des arbres de classification à des séries
  - Collaboration avec C. Amblard (AMA), encadrement de masters 2R

Introduction : analyse de la dépendance (1)

- **Données indépendantes**

$X_{(n\times p)}$: la matrice de description de n individus par p variables, $V(X)$ la matrice de variance covariance associée :

$$V(X) \quad = \quad X^t(I - UP)^t P(I - UP)X$$

$I_{(n\times n)}$ la matrice diagonale identité, $U_{(n\times n)}$ la matrice unité, et P la matrice diagonale des poids des individus $p_i = \frac{1}{n}$ (cas équipondéré).

- $U_{(n\times n)}$: une matrice d'adjacence où toutes les observations sont voisines (coïncidence entre indépendance totale et dépendance totale des observations)
- $U_{(n\times n)}$ introduit un centrage par rapport à la moyenne globale

Introduction : analyse de la dépendance (2)

- **Données dépendantes**

$M_{(n,n)}(m_{ii'})$ une matrice d'adjacence avec $m_{ii'} = 1$ si i et i' contigus, 0 sinon.

La matrice de variance/covariance locale $V_M(X)$:
(Moran 1948, Geary 1954, Cliff et Ord 1973, Lebart 1969)

$$V_M(X) \quad = \quad X^t(I - M')^t P(I - M')X$$

- M' (M normée en ligne) introduit un centrage par rapport à la moyenne de voisinage

$$v_{jl} \quad = \quad \frac{1}{2\,m} \sum_{i,i'} m_{ii'}(x_{ij} - x_{i'j})(x_{il} - x_{i'l})$$

Introduction : analyse de la dépendance (3)

- **Approches classiques d'analyse de la dépendance (analyse globale/locale)**
  (Banet & Lebart 1984, Wartenberg 1985, Mom 1988, Thioulouse et al. 1995)
  - Structure de contiguïté d'origine spatiale, géographique..., rarement temporelle
  - Structure connue *a priori*

- **Nos travaux**
  - Étudier les concepts classiques dans un contexte de dépendance temporelle et mise en évidence de propriétés utiles à l'analyse des séries
  - Explorer le cadre de structures de dépendance non connues mais apprises

Introduction : analyse de la dépendance (3)

- **Approches classiques d'analyse de la dépendance (analyse globale/locale)**
  (Banet & Lebart 1984, Wartenberg 1985, Mom 1988, Thioulouse et al. 1995)
  - Structure de contiguïté d'origine spatiale, géographique..., rarement temporelle
  - Structure connue *a priori*

- **Nos travaux**
  - Étudier les concepts classiques dans un contexte de dépendance temporelle et mise en évidence de propriétés utiles à l'analyse des séries
  - Explorer le cadre de structures de dépendance non connues mais apprises

Introduction : analyse de la dépendance (3)

- **Approches classiques d'analyse de la dépendance (analyse globale/locale)**
  (Banet & Lebart 1984, Wartenberg 1985, Mom 1988, Thioulouse et al. 1995)
  - Structure de contiguïté d'origine spatiale, géographique..., rarement temporelle
  - Structure connue *a priori*

- **Nos travaux**
  - Étudier les concepts classiques dans un contexte de dépendance temporelle et mise en évidence de propriétés utiles à l'analyse des séries
  - Explorer le cadre de structures de dépendance non connues mais apprises

Introduction : analyse de la dépendance (3)

- **Approches classiques d'analyse de la dépendance (analyse globale/locale)**
  (Banet & Lebart 1984, Wartenberg 1985, Mom 1988, Thioulouse et al. 1995)
  - Structure de contiguïté d'origine spatiale, géographique..., rarement temporelle
  - Structure connue *a priori*

- **Nos travaux**
  - Étudier les concepts classiques dans un contexte de dépendance temporelle et mise en évidence de propriétés utiles à l'analyse des séries
  - Explorer le cadre de structures de dépendance non connues mais apprises

Première partie

Représentation compacte de séries temporelles
par segmentation

Problème et objectif

- **Problème & objectif**
  - Analyser de longues séries multivariées (Nb. d'obs./séries $\approx 10^3$)
  - Nombre d'observations constitue une limite à l'analyse
  - **Objectif** : Réduction du nombre d'observations des séries multivariées par segmentation
- **Limites des approches existantes**
  - Dédiées à la segmentation de séries univariées
  - Critères de segmentation non fondés sur la dépendances des variables
- **Contribution**
  - Segmentation de séries multivariées préservant les corrélations des variables, information fondamentale en analyse des données

Problème et objectif

- **Problème & objectif**
  - Analyser de longues séries multivariées (Nb. d'obs./séries $\approx 10^3$)
  - Nombre d'observations constitue une limite à l'analyse
  - **Objectif** : Réduction du nombre d'observations des séries multivariées par segmentation
- **Limites des approches existantes**
  - Dédiées à la segmentation de séries univariées
  - Critères de segmentation non fondés sur la dépendances des variables
- **Contribution**
  - Segmentation de séries multivariées préservant les corrélations des variables, information fondamentale en analyse des données

Problème et objectif

- **Problème & objectif**
  - Analyser de longues séries multivariées (Nb. d'obs./séries $\approx 10^3$)
  - Nombre d'observations constitue une limite à l'analyse
  - **Objectif** : Réduction du nombre d'observations des séries multivariées par segmentation
- **Limites des approches existantes**
  - Dédiées à la segmentation de séries univariées
  - Critères de segmentation non fondés sur la dépendances des variables
- **Contribution**
  - Segmentation de séries multivariées préservant les corrélations des variables, information fondamentale en analyse des données

Problème et objectif

- **Problème & objectif**
  - Analyser de longues séries multivariées (Nb. d'obs./séries $\approx 10^3$)
  - Nombre d'observations constitue une limite à l'analyse
  - **Objectif** : Réduction du nombre d'observations des séries multivariées par segmentation
- **Limites des approches existantes**
  - Dédiées à la segmentation de séries univariées
  - Critères de segmentation non fondés sur la dépendances des variables
- **Contribution**
  - Segmentation de séries multivariées préservant les corrélations des variables, information fondamentale en analyse des données

La segmentation : état de l'art

Problème de segmentation

- Recherche de $u_1, ..., u_k$ instants (k connu ou estimé) visant à optimiser un des deux critères :

Des points de changements significatifs des caractéristiques de distributions (gaussiennes)

- Estimation du rapport de vraisemblance (Basevilles 1993, Gustafsson 2000, Guralnik 1999), comparaison des densités de probabilités estimées (Brodsky 1993, Csörgö 1988), mesure Kulback empirique (Kawahara et al. 2009)

Des points minimisant les résidus de modèles a priori estimés sur les segments (linéaires)

- Localisation spatiale de *hot spot* Fused-Lasso (Tibshirani 2008), détection de multiples points de changement d'une ou de plusieurs séries (Harchaoui et al. 2010, Vert et al. 2010)

La segmentation : état de l'art

Problème de segmentation

- Recherche de $u_1, ..., u_k$ instants (k connu ou estimé) visant à optimiser un des deux critères :

Des points de changements significatifs des caractéristiques de distributions (gaussiennes)

- Estimation du rapport de vraisemblance (Basevilles 1993, Gustafsson 2000, Guralnik 1999), comparaison des densités de probabilités estimées (Brodsky 1993, Csörgö 1988), mesure Kulback empirique (Kawahara et al. 2009)

Des points minimisant les résidus de modèles a priori estimés sur les segments (linéaires)

- Localisation spatiale de *hot spot* Fused-Lasso (Tibshirani 2008), détection de multiples points de changement d'une ou de plusieurs séries (Harchaoui et al. 2010, Vert et al. 2010)

La segmentation : état de l'art

Problème de segmentation

- Recherche de $u_1, ..., u_k$ instants (k connu ou estimé) visant à optimiser un des deux critères :

Des points de changements significatifs des caractéristiques de distributions (gaussiennes)

- Estimation du rapport de vraisemblance (Basevilles 1993, Gustafsson 2000, Guralnik 1999), comparaison des densités de probabilités estimées (Brodsky 1993, Csörgö 1988), mesure Kulback empirique (Kawahara et al. 2009)

Des points minimisant les résidus de modèles a priori estimés sur les segments (linéaires)

- Localisation spatiale de *hot spot* Fused-Lasso (Tibshirani 2008), détection de multiples points de changement d'une ou de plusieurs séries (Harchaoui et al. 2010, Vert et al. 2010)

Contribution

Caractéristiques des critères classiques

- Recherche de points changements de caractéristiques (moyenne, variance), ne rend pas compte de la dépendance temporelle des observations,
- Prise en compte de la dépendance des observations fondée sur des modèles a priori,
- Approches souvent limitées à des séries univariées, nombre de segments connu (estimé)

Contribution

- Un nouveau critère de segmentation de séries multivariées tenant compte de la dépendance temporelle des observations (variance temporelle)
- Approche locale (fenêtre glissante) pour l'extraction de segments, de nombre inconnu, de variances temporelles équivalentes
- Une segmentation guidée par la préservation des corrélations entre les variables

Contribution

Caractéristiques des critères classiques

- Recherche de points changements de caractéristiques (moyenne, variance), ne rend pas compte de la dépendance temporelle des observations,
- Prise en compte de la dépendance des observations fondée sur des modèles a priori,
- Approches souvent limitées à des séries univariées, nombre de segments connu (estimé)

Contribution

- Un nouveau critère de segmentation de séries multivariées tenant compte de la dépendance temporelle des observations (variance temporelle)
- Approche locale (fenêtre glissante) pour l'extraction de segments, de nombre inconnu, de variances temporelles équivalentes
- Une segmentation guidée par la préservation des corrélations entre les variables

Variance/Covariance : dépendance temporelle

S une série multivariée portant sur n observations

La variance/covariance temporelle $V_T(S)$ (ordre r) : $V_T(S) = V_M(S)$

$M_{(n,n)}(m_{ii'})$: $m_{ii'} = 1$ si $|i - i'| \leq r$, 0 sinon

Variance/Covariance : dépendance temporelle

S une série multivariée portant sur n observations

La variance/covariance temporelle $V_T(S)$ (ordre r) : $V_T(S) = V_M(S)$

$M_{(n,n)}(m_{ii'})$: $m_{ii'} = 1$ si $|i - i'| \leq r$, 0 sinon

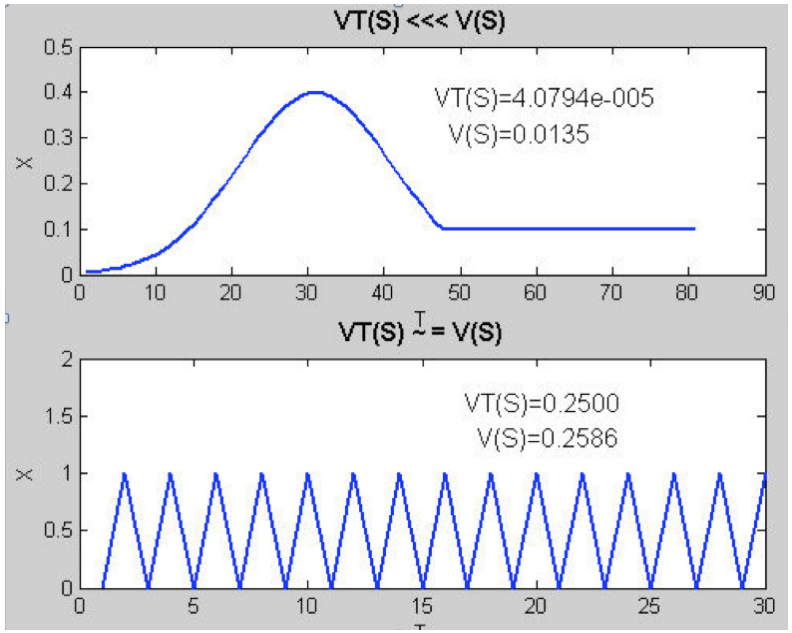

Définitions et propriétés

S : une séries multivariée à T instants, s_k un segment de S à n_k obs,
s_i^j : le segment couvrant la période $[i, j]$, $1 \leq i < j \leq T$

Inertie de S

$$I(S) = Tr(V_T(S)) \; ; \; (\|V_T(S)\|_F)$$

Contribution de s_k à l'inertie de S

$$C_S(s_k) = \frac{n_k - 1}{T - 1} Tr(V_T(s_k)) = \frac{n_k - 1}{T - 1} I(s_k)$$

C_S : additive, monotone croissante

Pour toute segmentation de S en K segments $s_1, ..., s_K$

$$I(S) = C_S(S) = \sum_{k=1}^{K} C_S(s_k)$$

$$\forall \, j < l \qquad C_S(s_i^j) \leq C_S(s_i^l)$$

Définitions et propriétés

S : une séries multivariée à T instants, s_k un segment de S à n_k obs,
s_i^j : le segment couvrant la période $[i, j]$, $1 \leq i < j \leq T$

Inertie de S

$$I(S) = Tr(V_T(S)) \; ; \; (\|V_T(S)\|_F)$$

Contribution de s_k à l'inertie de S

$$C_S(s_k) = \frac{n_k - 1}{T - 1} Tr(V_T(s_k)) = \frac{n_k - 1}{T - 1} I(s_k)$$

C_S : additive, monotone croissante

Pour toute segmentation de S en K segments $s_1, ..., s_K$

$$I(S) = C_S(S) = \sum_{k=1}^{K} C_S(s_k)$$

$$\forall\, j < l \qquad C_S(s_i^j) \leq C_S(s_i^l)$$

Définitions et propriétés

S : une séries multivariée à T instants, s_k un segment de S à n_k obs,
s_i^j : le segment couvrant la période $[i, j]$, $1 \leq i < j \leq T$

Inertie de S

$$I(S) = Tr(V_T(S)) \; ; \; (\|V_T(S)\|_F)$$

Contribution de s_k à l'inertie de S

$$C_S(s_k) \quad = \quad \frac{n_k - 1}{T - 1} Tr(V_T(s_k)) = \frac{n_k - 1}{T - 1} I(s_k)$$

C_S : **additive, monotone croissante**
Pour toute segmentation de S en K segments $s_1, ..., s_K$

$$I(S) \quad = \quad C_S(S) = \sum_{k=1}^{K} C_S(s_k)$$

$$\forall \, j < l \qquad C_S(s_i^j) \leq C_S(s_i^l)$$

Définitions et propriétés

S : une séries multivariée à T instants, s_k un segment de S à n_k obs,
s_i^j : le segment couvrant la période $[i, j]$, $1 \leq i < j \leq T$

Inertie de S

$$I(S) = Tr(V_T(S)) \; ; \; (\|V_T(S)\|_F)$$

Contribution de s_k à l'inertie de S

$$C_S(s_k) \quad = \quad \frac{n_k - 1}{T - 1} Tr(V_T(s_k)) = \frac{n_k - 1}{T - 1} I(s_k)$$

C_S **: additive, monotone croissante**
Pour toute segmentation de S en K segments $s_1, ..., s_K$

$$I(S) \quad = \quad C_S(S) = \sum_{k=1}^{K} C_S(s_k)$$

$$\forall \, j < l \qquad C_S(s_i^j) \leq C_S(s_i^l)$$

Définitions et propriétés

S : une séries multivariée à T instants, s_k un segment de S à n_k obs,
s_i^j : le segment couvrant la période $[i, j]$, $1 \leq i < j \leq T$

Inertie de S

$$I(S) = Tr(V_T(S)) \; ; \; (\|V_T(S)\|_F)$$

Contribution de s_k à l'inertie de S

$$C_S(s_k) \quad = \quad \frac{n_k - 1}{T - 1} Tr(V_T(s_k)) = \frac{n_k - 1}{T - 1} I(s_k)$$

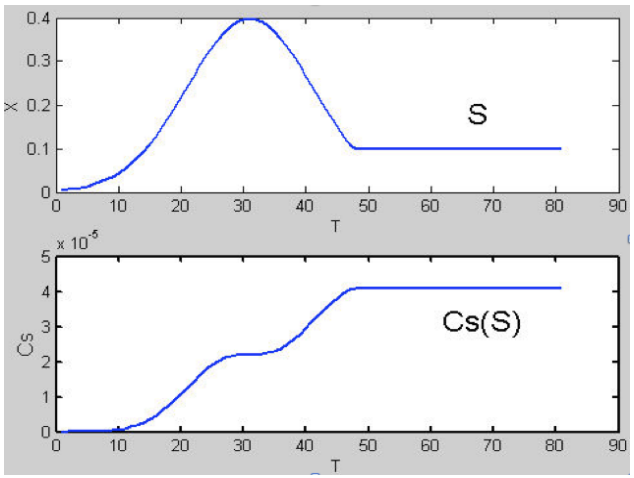

C_S : **additive, monotone croissante**
Pour toute segmentation de S en K segments $s_1, ..., s_K$

$$I(S) \quad = \quad C_S(S) = \sum_{k=1}^{K} C_S(s_k)$$

$$\forall \, j < l \qquad C_S(s_i^j) \leq C_S(s_i^l)$$

Segmentation pour la réduction du nombre d'observations

1. Initialisation : S, $\alpha \in [0,1]$ perte de corrélations, $\alpha_{C_S} \in [0,1]$ seuil de contribution à $I(S)$

2. Segmentation : Extraction de $s_1^{j_1}, s_{j_1+1}^{j_2} \ldots$

$$C_S(s_{j_{k-1}+1}^{j_k}) \leq \alpha_{C_S} I(S) \leq C_S(s_{j_{k-1}+1}^{j_k+1})$$

3. Regression linéaire multiple :
- Régression sur chaque segment extrait
- Décrire chaque segment par deux valeurs estimées aux bornes (S' la série réduite)

$O(n\,p^2)$

4. Estimation de la perte de corrélation

$$e(S,S') = \frac{\|Cor(S) - Cor(S')\|_F}{\|Cor(S)\|_F}$$

5. Ajustement de α_{C_S}
- Augmenter α_{C_S} si $e(S,S') < \alpha$, le diminuer sinon
- Réitèrer les étapes 2 à 4 jusqu'à la réduction maximale de S préservant les corrélations au seuil $1-\alpha$

Segmentation pour la réduction du nombre d'observations

1. Initialisation : S, $\alpha \in [0,1]$ perte de corrélations, $\alpha_{C_S} \in [0,1]$ seuil de contribution à $I(S)$

2. Segmentation : Extraction de $s_1^{j_1}, s_{j_1+1}^{j_2} \ldots$

$$C_S(s_{j_{k-1}+1}^{j_k}) \leq \alpha_{C_S} I(S) \leq C_S(s_{j_{k-1}+1}^{j_k+1})$$

3. Regression linéaire multiple :
- Régression sur chaque segment extrait
- Décrire chaque segment par deux valeurs estimées aux bornes (S' la série réduite)

4. Estimation de la perte de corrélation

$$e(S,S') = \frac{\|Cor(S) - Cor(S')\|_F}{\|Cor(S)\|_F}$$

5. Ajustement de α_{C_S}
- Augmenter α_{C_S} si $e(S,S') < \alpha$, le diminuer sinon
- Réitérer les étapes 2 à 4 jusqu'à la réduction maximale de S préservant les corrélations au seuil $1-\alpha$

$O(n\,p^2)$

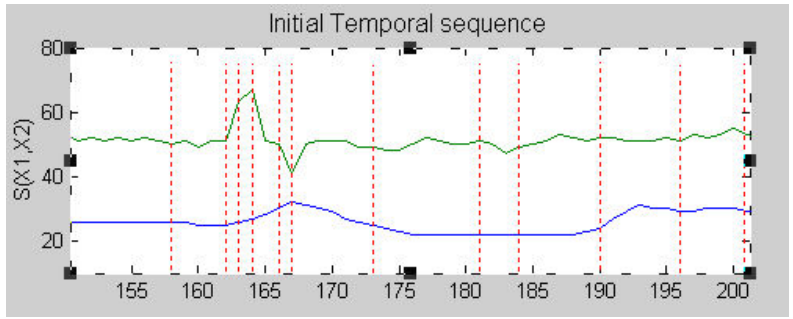

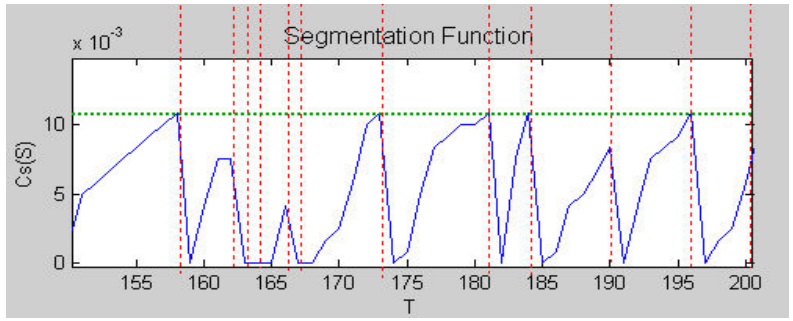

Segmentation pour la réduction du nombre d'observations

1. Initialisation : S, $\alpha \in [0,1]$ perte de corrélations, $\alpha_{C_S} \in [0,1]$ seuil de contribution à $I(S)$

2. Segmentation : Extraction de $s_1^{j_1}, s_{j_1+1}^{j_2} \ldots$

$$C_S(s_{j_{k-1}+1}^{j_k}) \leq \alpha_{C_S} I(S) \leq C_S(s_{j_{k-1}+1}^{j_k+1})$$

3. Regression linéaire multiple :
- Régression sur chaque segment extrait
- Décrire chaque segment par deux valeurs estimées aux bornes (S' la série réduite)

4. Estimation de la perte de corrélation

$$e(S,S') = \frac{\|Cor(S) - Cor(S')\|_F}{\|Cor(S)\|_F}$$

5. Ajustement de α_{C_S}
- Augmenter α_{C_S} si $e(S,S') < \alpha$, le diminuer sinon
- Réitérer les étapes 2 à 4 jusqu'à la réduction maximale de S préservant les corrélations au seuil $1-\alpha$

$O(np^2)$

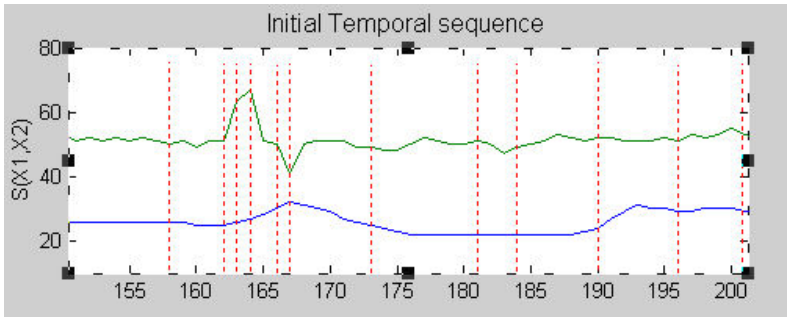

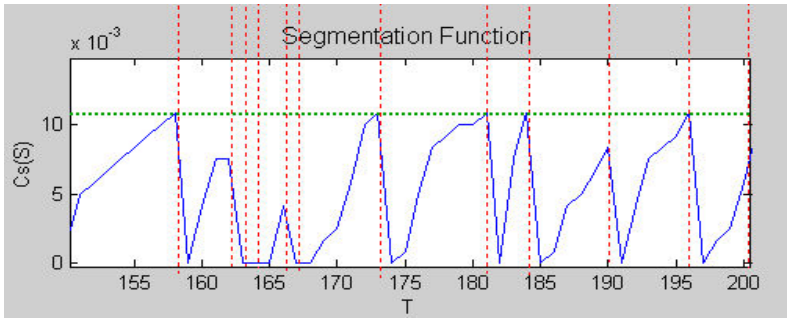

Segmentation pour la réduction du nombre d'observations

1. Initialisation : S, $\alpha \in [0,1]$ perte de corrélations, $\alpha_{C_S} \in [0,1]$ seuil de contribution à $I(S)$

2. Segmentation : Extraction de $s_1^{j_1}, s_{j_1+1}^{j_2} \ldots$

$$C_S(s_{j_{k-1}+1}^{j_k}) \leq \alpha_{C_S} I(S) \leq C_S(s_{j_{k-1}+1}^{j_k+1})$$

$O(n\,p^2)$

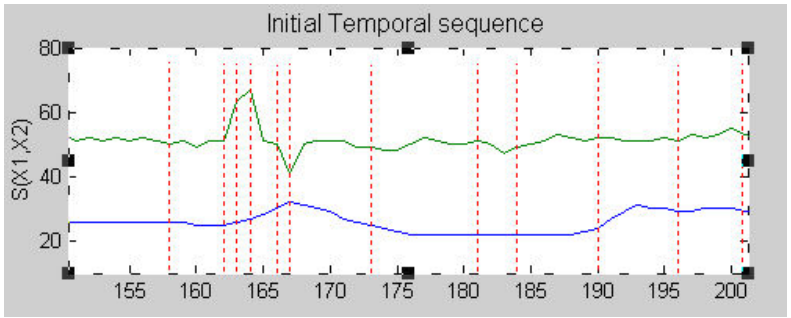

3. Regression linéaire multiple :
- Régression sur chaque segment extrait
- Décrire chaque segment par deux valeurs estimées aux bornes (S' la série réduite)

4. Estimation de la perte de corrélation

$$e(S,S') = \frac{\|Cor(S) - Cor(S')\|_F}{\|Cor(S)\|_F}$$

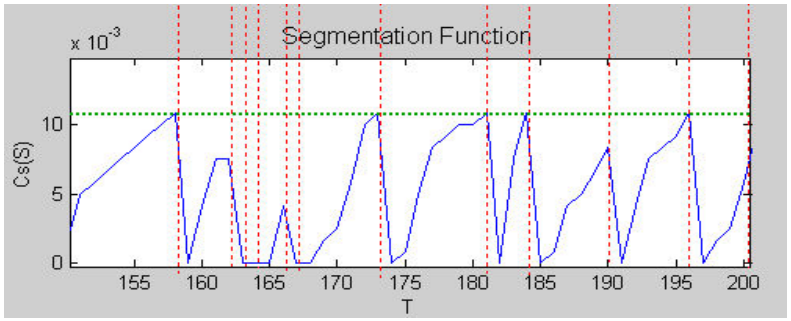

5. Ajustement de α_{C_S}
- Augmenter α_{C_S} si $e(S,S') < \alpha$, le diminuer sinon
- Réitérer les étapes 2 à 4 jusqu'à la réduction maximale de S préservant les corrélations au seuil $1-\alpha$

Segmentation pour la réduction du nombre d'observations

1. Initialisation : S, $\alpha \in [0,1]$ perte de corrélations, $\alpha_{C_S} \in [0,1]$ seuil de contribution à $I(S)$

2. Segmentation : Extraction de $s_1^{j_1}, s_{j_1+1}^{j_2} \ldots$

$$C_S(s_{j_{k-1}+1}^{j_k}) \leq \alpha_{C_S} I(S) \leq C_S(s_{j_{k-1}+1}^{j_k+1})$$

$O(n\,p^2)$

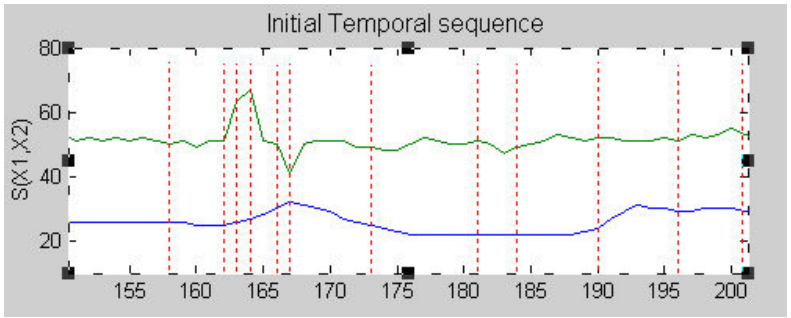

3. Regression linéaire multiple :
- Régression sur chaque segment extrait
- Décrire chaque segment par deux valeurs estimées aux bornes (S' la série réduite)

4. Estimation de la perte de corrélation

$$e(S,S') = \frac{\|Cor(S) - Cor(S')\|_F}{\|Cor(S)\|_F}$$

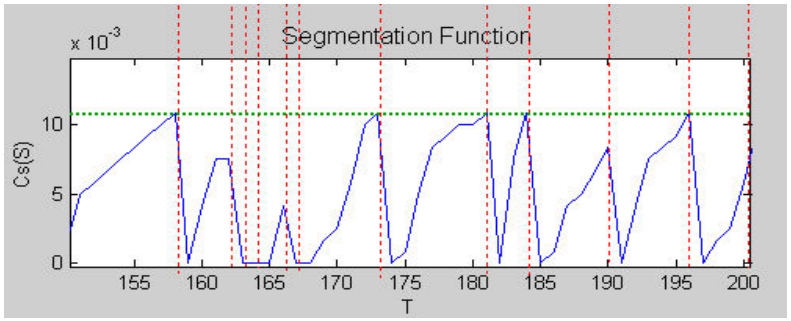

5. Ajustement de α_{C_S}
- Augmenter α_{C_S} si $e(S,S') < \alpha$, le diminuer sinon
- Réitérer les étapes 2 à 4 jusqu'à la réduction maximale de S préservant les corrélations au seuil $1-\alpha$

Segmentation pour la réduction du nombre d'observations

1. Initialisation : S, $\alpha \in [0,1]$ perte de corrélations, $\alpha_{C_S} \in [0,1]$ seuil de contribution à $I(S)$

2. Segmentation : Extraction de $s_1^{j_1}, s_{j_1+1}^{j_2} \ldots$ $O(n\,p^2)$

$$C_S(s_{j_{k-1}+1}^{j_k}) \leq \alpha_{C_S} I(S) \leq C_S(s_{j_{k-1}+1}^{j_k+1})$$

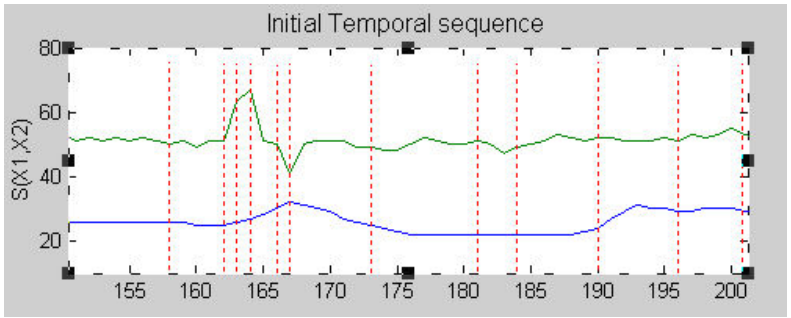

3. Regression linéaire multiple :
- Régression sur chaque segment extrait
- Décrire chaque segment par deux valeurs estimées aux bornes (S' la série réduite)

4. Estimation de la perte de corrélation

$$e(S,S') = \frac{\|Cor(S) - Cor(S')\|_F}{\|Cor(S)\|_F}$$

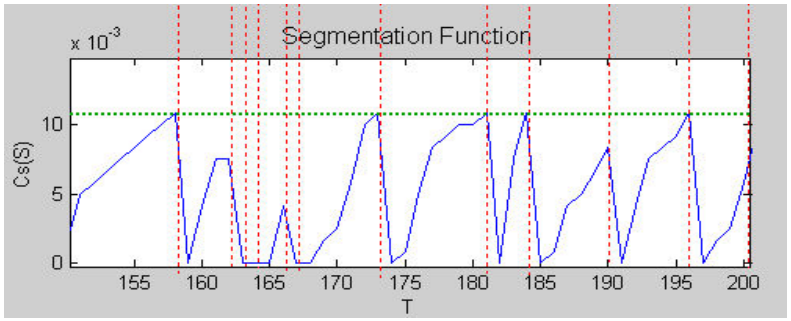

5. Ajustement de α_{C_S}
- Augmenter α_{C_S} si $e(S,S') < \alpha$, le diminuer sinon
- Réitérer les étapes 2 à 4 jusqu'à la réduction maximale de S préservant les corrélations au seuil $1-\alpha$

Resultats : données de monitoring en anesthésie-réanimation

PRETA (TIMC-IMAG)

$p = 11, n \approx 5000,$
Nb. itérations ≈ 5

- Réduction de la série de 5000 à 388 obs. (taux réduction 92%, perte des corrélations 10%)

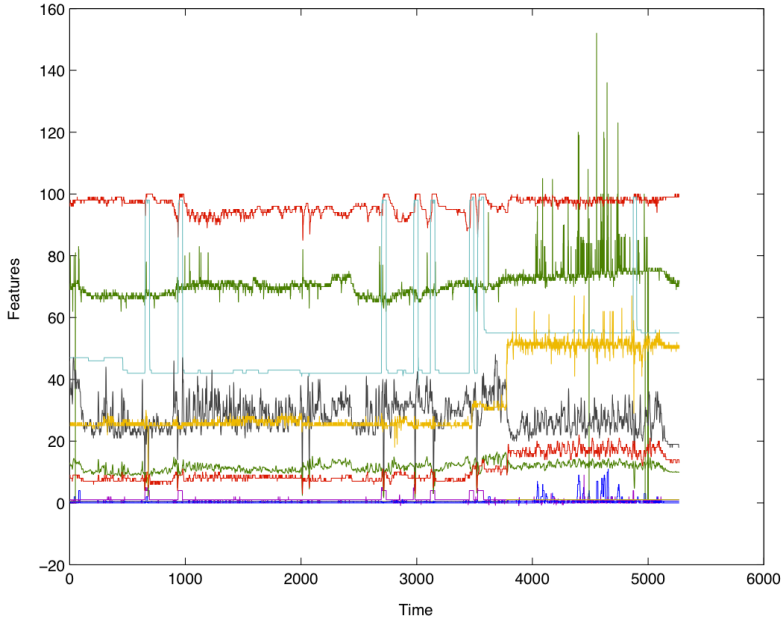

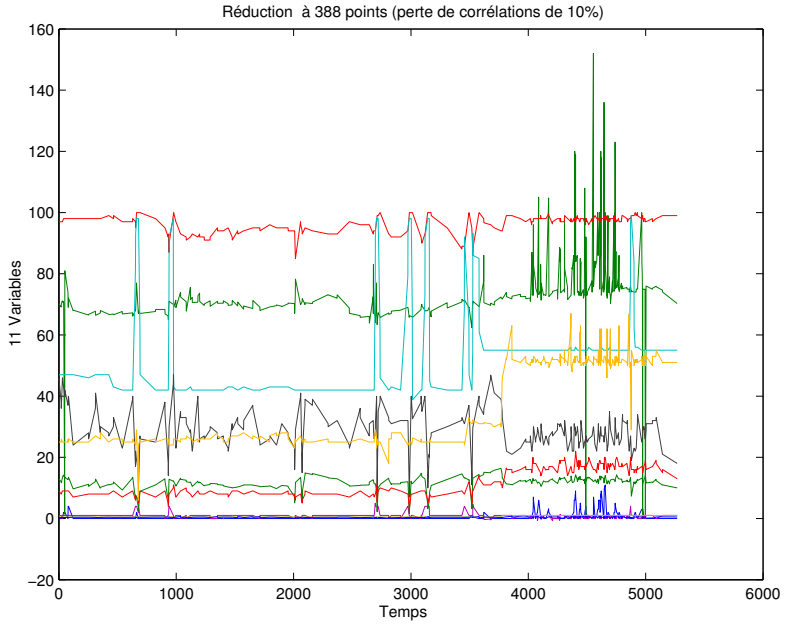

Deuxième partie

Apprentissage d'appariements discriminants

Problème et objectif

- **Problème & objectif**
  - Classification de séries multivariées complexes
  - Différentes dynamiques au sein des classes, faibles différences entre les classes
  - **Objectif** : Classification fondée sur les caractéristiques dynamiques discriminantes
- **Limites des approches existantes**
  - Hypothèse de dynamiques globales similaires dans les classes
- **Contribution**
  - Apprentissage d'appariements discriminants (révélant les caractéristiques communes dans les classes et différentielles entre les classes)
  - Dériver une métrique pour la classification de séries

Problème et objectif

- **Problème & objectif**
  - Classification de séries multivariées complexes
  - Différentes dynamiques au sein des classes, faibles différences entre les classes
  - **Objectif** : Classification fondée sur les caractéristiques dynamiques discriminantes
- **Limites des approches existantes**
  - Hypothèse de dynamiques globales similaires dans les classes
- **Contribution**
  - Apprentissage d'appariements discriminants (révélant les caractéristiques communes dans les classes et différentielles entre les classes)
  - Dériver une métrique pour la classification de séries

Problème et objectif

- **Problème & objectif**
  - Classification de séries multivariées complexes
  - Différentes dynamiques au sein des classes, faibles différences entre les classes

Courbes de consommations électriques journalières

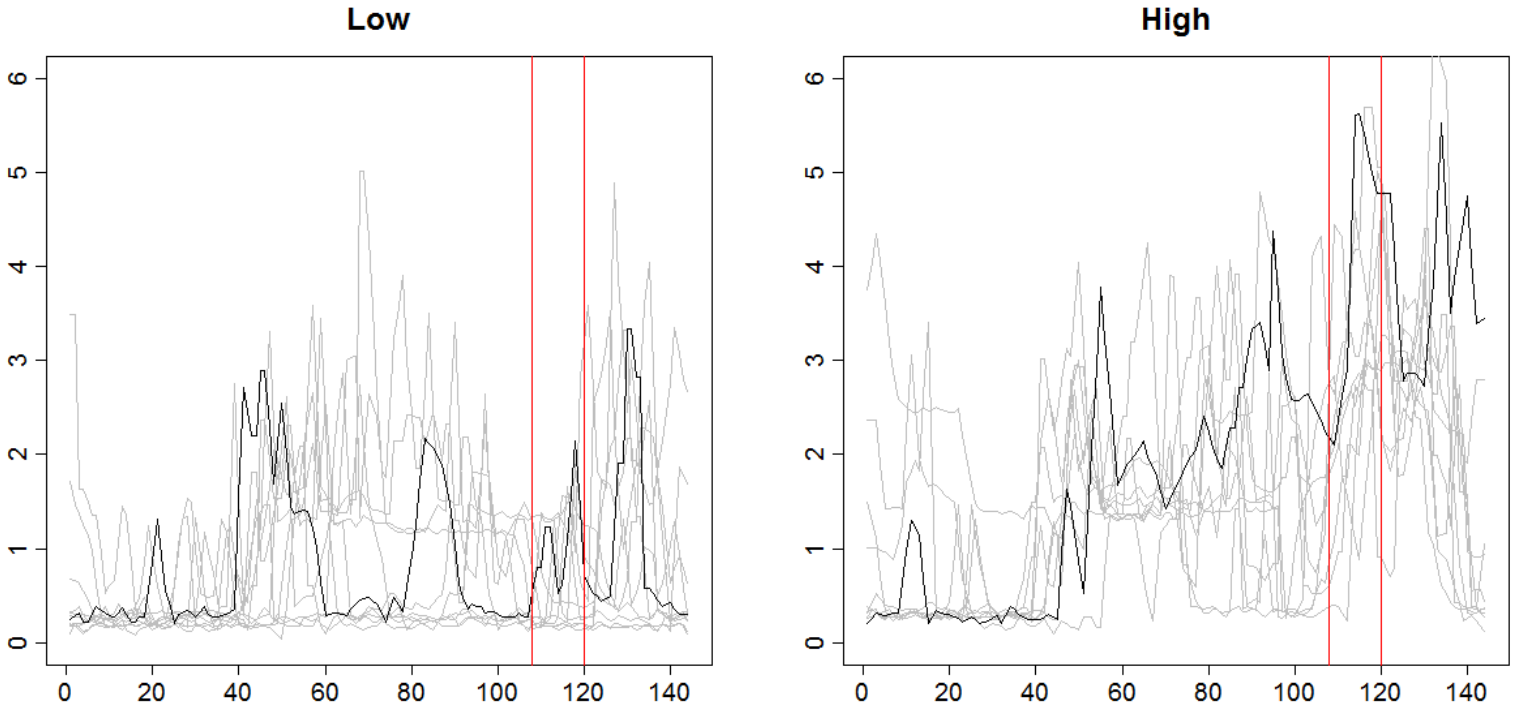

  - **Objectif** : Classification fondée sur les caractéristiques dynamiques discriminantes

- Limites des approches existantes

Problème et objectif

- **Problème & objectif**
  - Classification de séries multivariées complexes
  - Différentes dynamiques au sein des classes, faibles différences entre les classes
  - **Objectif** : Classification fondée sur les caractéristiques dynamiques discriminantes
- **Limites des approches existantes**
  - Hypothèse de dynamiques globales similaires dans les classes
- **Contribution**
  - Apprentissage d'appariements discriminants (révélant les caractéristiques communes dans les classes et différentielles entre les classes)
  - Dériver une métrique pour la classification de séries

Problème et objectif

- **Problème & objectif**
  - Classification de séries multivariées complexes
  - Différentes dynamiques au sein des classes, faibles différences entre les classes
  - **Objectif** : Classification fondée sur les caractéristiques dynamiques discriminantes
- **Limites des approches existantes**
  - Hypothèse de dynamiques globales similaires dans les classes
- **Contribution**
  - Apprentissage d'appariements discriminants (révélant les caractéristiques communes dans les classes et différentielles entre les classes)
  - Dériver une métrique pour la classification de séries

Problème et objectif

- **Problème & objectif**
  - Classification de séries multivariées complexes
  - Différentes dynamiques au sein des classes, faibles différences entre les classes
  - **Objectif** : Classification fondée sur les caractéristiques dynamiques discriminantes
- **Limites des approches existantes**
  - Hypothèse de dynamiques globales similaires dans les classes
- **Contribution**
  - Apprentissage d'appariements discriminants (révélant les caractéristiques communes dans les classes et différentielles entre les classes)
  - Dériver une métrique pour la classification de séries

Stratégies classiques d'alignement des séries

- Alignement des observations de mêmes instants (alignement euclidien)

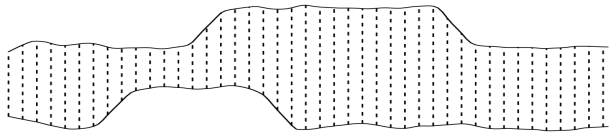

- Alignement tenant compte de délais, Dynamic Time Warping DTW (Sankoff & Kruskal 1983, Kruskal & Liberman 1983).
- Alignement sous contraintes globales/locales (Sakoe-Chiba 1975, Itakura 1971, Rabiner 1978)

Stratégies classiques d'alignement des séries

- Alignement des observations de mêmes instants (alignement euclidien)

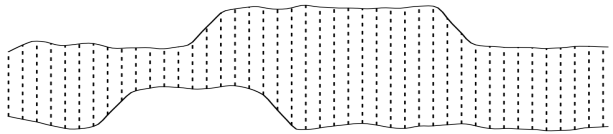

- Alignement tenant compte de délais, Dynamic Time Warping DTW (Sankoff & Kruskal 1983, Kruskal & Liberman 1983).

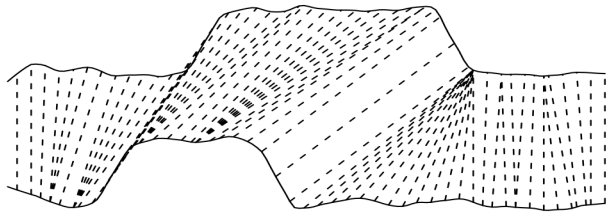

- Alignement sous contraintes globales/locales (Sakoe-Chiba 1975, Itakura 1971, Rabiner 1978)

Stratégies classiques d'alignement des séries

- Alignement des observations de mêmes instants (alignement euclidien)

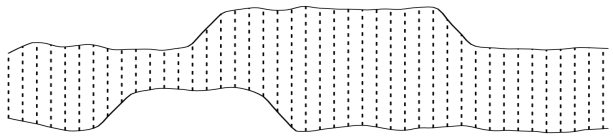

- Alignement tenant compte de délais, Dynamic Time Warping DTW (Sankoff & Kruskal 1983, Kruskal & Liberman 1983).

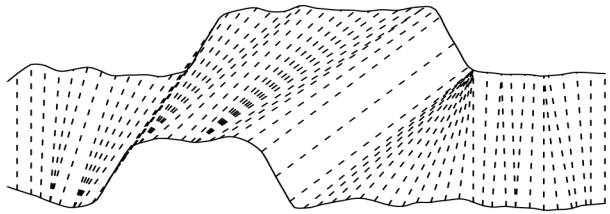

- Alignement sous contraintes globales/locales (Sakoe-Chiba 1975, Itakura 1971, Rabiner 1978)

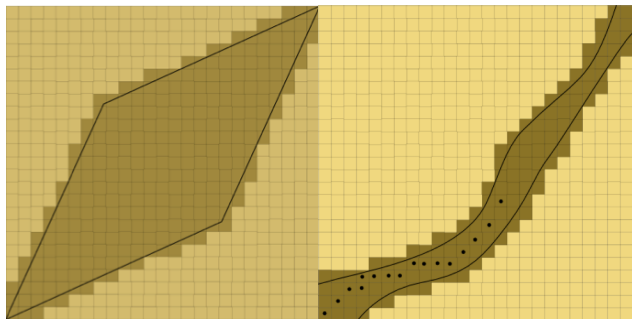

Alignements classiques

Limite : hypothèse de dynamiques globales similaires dans les classes

- Approches pair-à-pair
  - Limitées au couple de séries à aligner
  - Ne rend pas compte des dynamiques de l'ensemble des séries
  - Dissociées des processus d'analyse des séries
- Contraintes temporelles rigides
  - Croisements non permis

Propositions plus récentes

- Apprentissage de contraintes d'alignement de la DTW en vue d'un k-NN à vase marge
  Yu et al. 2011, Jeong et al. 2011
- Modèle probabiliste assurant conjointement les processus de classification non supervisée des séries et leur alignements Ramsay et al. 1998, Gaffney et al. 2005
- Modèle bayésien hiérarchique pour l'identification de faibles différences entre classes
  Listegarten et al. 2007

Alignements classiques

Limite : hypothèse de dynamiques globales similaires dans les classes

- Approches pair-à-pair
  - Limitées au couple de séries à aligner
  - Ne rend pas compte des dynamiques de l'ensemble des séries
  - Dissociées des processus d'analyse des séries
- Contraintes temporelles rigides
  - Croisements non permis

Propositions plus récentes

- Apprentissage de contraintes d'alignement de la DTW en vue d'un k-NN à vase marge
  Yu et al. 2011, Jeong et al. 2011
- Modèle probabiliste assurant conjointement les processus de classification non supervisée des séries et leur alignements Ramsay et al. 1998, Gaffney et al. 2005
- Modèle bayésien hiérarchique pour l'identification de faibles différences entre classes
  Listegarten et al. 2007

Alignements classiques

Limite : hypothèse de dynamiques globales similaires dans les classes

- Approches pair-à-pair
  - Limitées au couple de séries à aligner
  - Ne rend pas compte des dynamiques de l'ensemble des séries
  - Dissociées des processus d'analyse des séries
- Contraintes temporelles rigides
  - Croisements non permis

Propositions plus récentes

- Apprentissage de contraintes d'alignement de la DTW en vue d'un k-NN à vase marge Yu et al. 2011, Jeong et al. 2011
- Modèle probabiliste assurant conjointement les processus de classification non supervisée des séries et leur alignements Ramsay et al. 1998, Gaffney et al. 2005
- Modèle bayésien hiérarchique pour l'identification de faibles différences entre classes Listegarten et al. 2007

Discrimination de séries temporelles

Objectif

- Discrimination de classes de séries complexes (dynamiques différentes au sein des classes, faibles différences entre les classes)

Approche

- Élargir la stratégie d'alignement à un appariement moins contraints temporellement
- Appariement multiples : mettre en regard l'ensemble des dynamiques des séries
- Révéler des caractéristiques communes dans les classes et différentielles entre les classes

Discrimination de séries temporelles

Objectif

- Discrimination de classes de séries complexes (dynamiques différentes au sein des classes, faibles différences entre les classes)

Approche

- Élargir la stratégie d'alignement à un appariement moins contraints temporellement
- Appariement multiples : mettre en regard l'ensemble des dynamiques des séries
- Révéler des caractéristiques communes dans les classes et différentielles entre les classes

Discrimination de séries temporelles

Objectif

- Discrimination de classes de séries complexes (dynamiques différentes au sein des classes, faibles différences entre les classes)

Approche

- Élargir la stratégie d'alignement à un appariement moins contraints temporellement
- Appariement multiples : mettre en regard l'ensemble des dynamiques des séries
- Révéler des caractéristiques communes dans les classes et différentielles entre les classes

Discrimination de séries temporelles

Objectif

- Discrimination de classes de séries complexes (dynamiques différentes au sein des classes, faibles différences entre les classes)

Approche

- Élargir la stratégie d'alignement à un appariement moins contraints temporellement
- Appariement multiples : mettre en regard l'ensemble des dynamiques des séries
- Révéler des caractéristiques communes dans les classes et différentielles entre les classes

Contribution

Idée

- A tout appariement entre des séries correspond une variabilité intra et inter classe définie par les observations liées à l'intérieur des classes et entre les classes
- Révéler les caractéristiques communes au sein des classes par la minimisation de la variance intra classe
- Révéler les attributs différentiels par la maximisation de la variance inter classe

Comment ?

- Étendre les concepts de variance/covariance à un ensemble, ainsi qu'à une partition de séries
- Pénaliser (renforcer) les liens en fonction de leur contribution à la variance intra et inter classes

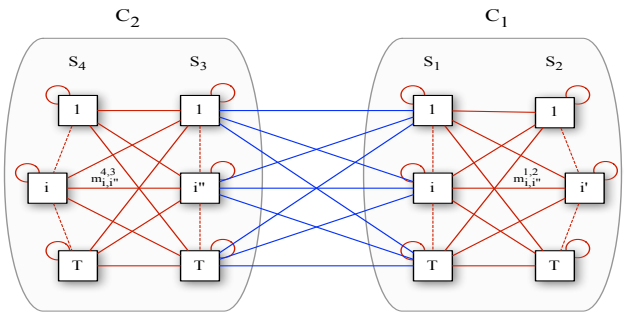

Contribution

Idée

- A tout appariement entre des séries correspond une variabilité intra et inter classe définie par les observations liées à l'intérieur des classes et entre les classes
- Révéler les caractéristiques communes au sein des classes par la minimisation de la variance intra classe
- Révéler les attributs différentiels par la maximisation de la variance inter classe

Comment ?

- Étendre les concepts de variance/covariance à un ensemble, ainsi qu'à une partition de séries
- Pénaliser (renforcer) les liens en fonction de leur contribution à la variance intra et inter classes

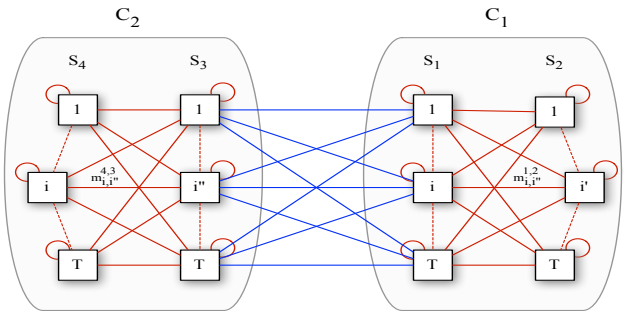

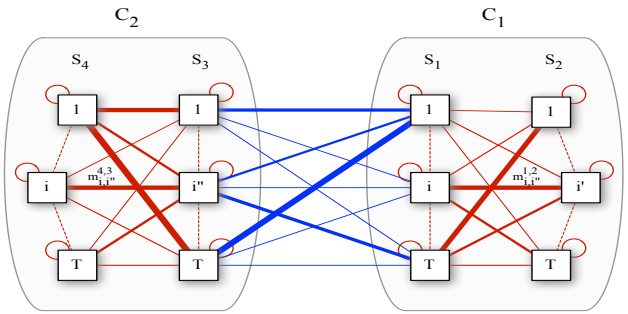

Variance/Covariance induite par des séries temporelles

$S_1, ..., S_n$ séries multivariées, S_l décrit l'observation de p variables à T instants
$X_{n.T \times p}(x_{ij}^l)$: matrice de description des séries $S_1, ..., S_n$ par p variables
x_{ij}^l : la valeur de la variable j prise à l'instant i de S_l

Appariement *a* priori des séries

- Pour tout appariement *a* priori des séries $S_1, ..., S_n$ (exp. DTW)
- On associe $M_{(n,n)}(M_{ll'})$ une matrice d'adjacence par blocs $M_{ll'}(m_{ii'}^{ll'})$ liant les observations i de S_l et et i' de S_l'
- $m_{ii'}^{ll'} = 1$ si i et i' entre S_l et S_l' sont alignées, 0 sinon

Variance/covariance totale associée à l'ensemble des séries

$$V_M(X) = X^t(I - M')^t P(I - M')X$$

Variance/covariance intra et inter classes de séries

$$V_{M_{Intra}}(X) = X^t(I - M_{Intra})^t P(I - M_{Intra})X$$
$$V_{M_{Inter}}(X) = X^t(I - M_{Inter})^t P(I - M_{Inter})X$$

- M_{Intra} : $m_{ii'}^{ll'} = 1$ si i et i' sont des observations de séries de même classe, 0 sinon.
- M_{Inter} : $m_{ii'}^{ll'} = 1$ si i et i' sont des observations de séries de classes différentes, 0 sinon.

Variance/Covariance induite par des séries temporelles

$S_1, ..., S_n$ séries multivariées, S_l décrit l'observation de p variables à T instants
$X_{n.T \times p}(x_{ij}^l)$: matrice de description des séries $S_1, ..., S_n$ par p variables
x_{ij}^l : la valeur de la variable j prise à l'instant i de S_l

Appariement *a* priori des séries

- Pour tout appariement *a* priori des séries $S_1, ..., S_n$ (exp. DTW)
- On associe $M_{(n,n)}(M_{ll'})$ une matrice d'adjacence par blocs $M_{ll'}(m_{ii'}^{ll'})$ liant les observations i de S_l et et i' de S_l'
- $m_{ii'}^{ll'} = 1$ si i et i' entre S_l et S_l' sont alignées, 0 sinon

Variance/covariance totale associée à l'ensemble des séries

$$V_M(X) = X^t(I - M')^t P(I - M')X$$

Variance/covariance intra et inter classes de séries

$$V_{M_{Intra}}(X) = X^t(I - M_{Intra})^t P(I - M_{Intra})X$$
$$V_{M_{Inter}}(X) = X^t(I - M_{Inter})^t P(I - M_{Inter})X$$

- M_{Intra} : $m_{ii'}^{ll'} = 1$ si i et i' sont des observations de séries de même classe, 0 sinon.
- M_{Inter} : $m_{ii'}^{ll'} = 1$ si i et i' sont des observations de séries de classes différentes, 0 sinon.

Variance/Covariance induite par des séries temporelles

$S_1, ..., S_n$ séries multivariées, S_l décrit l'observation de p variables à T instants
$X_{n.T \times p}(x_{ij}^l)$: matrice de description des séries $S_1, ..., S_n$ par p variables
x_{ij}^l : la valeur de la variable j prise à l'instant i de S_l

Appariement *a* priori des séries

- Pour tout appariement *a* priori des séries $S_1, ..., S_n$ (exp. DTW)
- On associe $M_{(n,n)}(M_{ll'})$ une matrice d'adjacence par blocs $M_{ll'}(m_{ii'}^{ll'})$ liant les observations i de S_l et et i' de S_l'
- $m_{ii'}^{ll'} = 1$ si i et i' entre S_l et S_l' sont alignées, 0 sinon

Variance/covariance totale associée à l'ensemble des séries

$$V_M(X) = X^t(I - M')^t P(I - M')X$$

Variance/covariance intra et inter classes de séries

$$V_{M_{Intra}}(X) = X^t(I - M_{Intra})^t P(I - M_{Intra})X$$
$$V_{M_{Inter}}(X) = X^t(I - M_{Inter})^t P(I - M_{Inter})X$$

- M_{Intra} : $m_{ii'}^{ll'} = 1$ si i et i' sont des observations de séries de même classe, 0 sinon.
- M_{Inter} : $m_{ii'}^{ll'} = 1$ si i et i' sont des observations de séries de classes différentes, 0 sinon.

Variance/Covariance induite par des séries temporelles

$S_1, ..., S_n$ séries multivariées, S_l décrit l'observation de p variables à T instants
$X_{n.T \times p}(x_{ij}^l)$: matrice de description des séries $S_1, ..., S_n$ par p variables
x_{ij}^l : la valeur de la variable j prise à l'instant i de S_l

Appariement *a* priori des séries

- Pour tout appariement *a* priori des séries $S_1, ..., S_n$ (exp. DTW)
- On associe $M_{(n,n)}(M_{ll'})$ une matrice d'adjacence par blocs $M_{ll'}(m_{ii'}^{ll'})$ liant les observations i de S_l et et i' de S_l'
- $m_{ii'}^{ll'} = 1$ si i et i' entre S_l et S_l' sont alignées, 0 sinon

Variance/covariance totale associée à l'ensemble des séries

$$V_M(X) = X^t(I - M')^t P(I - M')X$$

Variance/covariance intra et inter classes de séries

$$V_{M_{Intra}}(X) = X^t(I - M_{Intra})^t P(I - M_{Intra})X$$
$$V_{M_{Inter}}(X) = X^t(I - M_{Inter})^t P(I - M_{Inter})X$$

- M_{Intra} : $m_{ii'}^{ll'} = 1$ si i et i' sont des observations de séries de même classe, 0 sinon.
- M_{Inter} : $m_{ii'}^{ll'} = 1$ si i et i' sont des observations de séries de classes différentes, 0 sinon.

Objectif

Rechercher les appariements M_{Intra} et M_{Inter} par :
minimisation de $V_{M_{Intra}}$ et maximisation $V_{M_{Inter}}$

$$M^{ll'}_{Intra} = \begin{cases} \mathbf{I} & \text{si } l = l' \\ \neq \mathbf{0} & \text{si } y_l = y_{l'} \text{ and } l \neq l' \\ \mathbf{0} & \text{si } y_l \neq y_{l'} \end{cases} \qquad M^{ll'}_{Inter} = \begin{cases} \mathbf{I} & \text{if } l = l' \\ \mathbf{0} & \text{if } y_l = y_{l'} \text{ and } l \neq l' \\ \neq \mathbf{0} & \text{if } y_l \neq y_{l'} \end{cases}$$

$\mathbf{I}$ et $\mathbf{0}$ les matrices identités et nulles
y_l la classe de S_l

Deux phases consécutives :

1. Apprentissage des appariements intra classes (M^*_{Intra})
   - Initialisation M^0_{Intra} non contrainte
2. Apprentissage des appariements inter classes (M^*)
   - Initialisation de M^0_{Inter} à partir de M^*_{Intra}
     (affiner M^*_{Intra} pour révéler les liens à la fois communs et différentiels)

Objectif

Rechercher les appariements M_{Intra} et M_{Inter} par :
minimisation de $V_{M_{Intra}}$ et maximisation $V_{M_{Inter}}$

$$M^{ll'}_{Intra} = \begin{cases} \mathbf{I} & \text{si } l = l' \\ \neq \mathbf{0} & \text{si } y_l = y_{l'} \text{ and } l \neq l' \\ \mathbf{0} & \text{si } y_l \neq y_{l'} \end{cases}$$

$$M^{ll'}_{Inter} = \begin{cases} \mathbf{I} & \text{if } l = l' \\ \mathbf{0} & \text{if } y_l = y_{l'} \text{ and } l \neq l' \\ \neq \mathbf{0} & \text{if } y_l \neq y_{l'} \end{cases}$$

$\mathbf{I}$ et $\mathbf{0}$ les matrices identités et nulles
y_l la classe de S_l

Deux phases consécutives :

1. Apprentissage des appariements intra classes (M^*_{Intra})
   - Initialisation M^0_{Intra} non contrainte
2. Apprentissage des appariements inter classes (M^*)
   - Initialisation de M^0_{Inter} à partir de M^*_{Intra}
     (affiner M^*_{Intra} pour révéler les liens à la fois communs et différentiels)

Objectif

Rechercher les appariements M_{Intra} et M_{Inter} par :
minimisation de $V_{M_{Intra}}$ et maximisation $V_{M_{Inter}}$

$$M^{ll'}_{Intra} = \begin{cases} \mathbf{I} & \text{si } l = l' \\ \neq \mathbf{0} & \text{si } y_l = y_{l'} \text{ and } l \neq l' \\ \mathbf{0} & \text{si } y_l \neq y_{l'} \end{cases} \qquad M^{ll'}_{Inter} = \begin{cases} \mathbf{I} & \text{if } l = l' \\ \mathbf{0} & \text{if } y_l = y_{l'} \text{ and } l \neq l' \\ \neq \mathbf{0} & \text{if } y_l \neq y_{l'} \end{cases}$$

$\mathbf{I}$ et $\mathbf{0}$ les matrices identités et nulles
y_l la classe de S_l

Deux phases consécutives :

1. Apprentissage des appariements intra classes (M^*_{Intra})
   - Initialisation M^0_{Intra} non contrainte
2. Apprentissage des appariements inter classes (M^*)
   - Initialisation de M^0_{Inter} à partir de M^*_{Intra}
     (affiner M^*_{Intra} pour révéler les liens à la fois communs et différentiels)

Objectif

Rechercher les appariements M_{Intra} et M_{Inter} par :
minimisation de $V_{M_{Intra}}$ et maximisation $V_{M_{Inter}}$

$$M^{ll'}_{Intra} = \begin{cases} \mathbf{I} & \text{si } l = l' \\ \neq \mathbf{0} & \text{si } y_l = y_{l'} \text{ and } l \neq l' \\ \mathbf{0} & \text{si } y_l \neq y_{l'} \end{cases} \qquad M^{ll'}_{Inter} = \begin{cases} \mathbf{I} & \text{if } l = l' \\ \mathbf{0} & \text{if } y_l = y_{l'} \text{ and } l \neq l' \\ \neq \mathbf{0} & \text{if } y_l \neq y_{l'} \end{cases}$$

$\mathbf{I}$ et $\mathbf{0}$ les matrices identités et nulles
y_l la classe de S_l

Deux phases consécutives :

1. Apprentissage des appariements intra classes (M^*_{Intra})
   - Initialisation M^0_{Intra} non contrainte
2. Apprentissage des appariements inter classes (M^*)
   - Initialisation de M^0_{Inter} à partir de M^*_{Intra}
     (affiner M^*_{Intra} pour révéler les liens à la fois communs et différentiels)

Objectif

Rechercher les appariements M_{Intra} et M_{Inter} par :
minimisation de $V_{M_{Intra}}$ et maximisation $V_{M_{Inter}}$

$$M^{ll'}_{Intra} = \begin{cases} \mathbf{I} & \text{si } l = l' \\ \neq \mathbf{0} & \text{si } y_l = y_{l'} \text{ and } l \neq l' \\ \mathbf{0} & \text{si } y_l \neq y_{l'} \end{cases} \qquad M^{ll'}_{Inter} = \begin{cases} \mathbf{I} & \text{if } l = l' \\ \mathbf{0} & \text{if } y_l = y_{l'} \text{ and } l \neq l' \\ \neq \mathbf{0} & \text{if } y_l \neq y_{l'} \end{cases}$$

$\mathbf{I}$ et $\mathbf{0}$ les matrices identités et nulles
y_l la classe de S_l

Deux phases consécutives :

1. Apprentissage des appariements intra classes (M^*_{Intra})
   - Initialisation M^0_{Intra} non contrainte
2. Apprentissage des appariements inter classes (M^*)
   - Initialisation de M^0_{Inter} à partir de M^*_{Intra}
     (affiner M^*_{Intra} pour révéler les liens à la fois communs et différentiels)

Apprentissage des appariements intra classes

$S_{l_1} = (x_1^{l_1}, ..., x_T^{l_1})$, $S_{l_2} = (x_1^{l_2}, ..., x_T^{l_2})$, de même classe C_k ($|C_k| = n_k$)

$M \backslash (i, i', l, l')$: M après suppression du lien (i, i') entre S_l et $S_{l'}$ ($m_{ii'}^{ll'} = 0$)

Principe de l'algorithme

1. Initialiser M_{Intra} par un couplage complet :

$$\forall\, i, i' \in \{1, ...T\} \text{ et } S_l,\ S_{l'} \text{ de même classe } m_{ii'}^{ll'} = 1$$

2. Mesurer la contribution $C_{i_1 i_2}^{l_1 l_2}$ de chaque lien i_1, i_2 entre S_{l_1} et S_{l_2} à la variance $V_{M_{Intra}}$

$$C_{i_1 i_2}^{l_1 l_2} = V_{M_{Intra}} - V_{M_{Intra} \backslash (i_1, i_2, l_1, l_2)}$$

3. Pénaliser les liens (i_1, i_2) $(m_{i_1 i_2}^{l_1 l_2} = 0)$ de contributions $C_{i_1 i_2}^{l_1 l_2} > 0$

4. Réitérer les étapes 2 et 3 jusqu'à stabilisation de la variance intra

Apprentissage des appariements intra classes

$S_{l_1} = (x_1^{l_1}, ..., x_T^{l_1})$, $S_{l_2} = (x_1^{l_2}, ..., x_T^{l_2})$, de même classe C_k ($|C_k| = n_k$)

$M \backslash (i, i', l, l')$: M après suppression du lien (i, i') entre S_l et $S_{l'}$ ($m_{ii'}^{ll'} = 0$)

Principe de l'algorithme

1. Initialiser M_{Intra} par un couplage complet :

$$\forall\, i, i' \in \{1, ...T\} \text{ et } S_l,\ S_{l'} \text{ de même classe } m_{ii'}^{ll'} = 1$$

2. Mesurer la contribution $C_{i_1 i_2}^{l_1 l_2}$ de chaque lien i_1, i_2 entre S_{l_1} et S_{l_2} à la variance $V_{M\,Intra}$

$$C_{i_1 i_2}^{l_1 l_2} \quad = \quad V_{M_{Intra}} - V_{M_{Intra} \backslash (i_1, i_2, l_1, l_2)}$$

3. Pénaliser les liens (i_1, i_2) ($m_{i_1 i_2}^{l_1 l_2} = 0$) de contributions $C_{i_1 i_2}^{l_1 l_2} > 0$

4. Réitérer les étapes 2 et 3 jusqu'à stabilisation de la variance intra

Apprentissage des appariements intra classes

$S_{l_1} = (x_1^{l_1}, ..., x_T^{l_1})$, $S_{l_2} = (x_1^{l_2}, ..., x_T^{l_2})$, de même classe C_k $(|C_k| = n_k)$

$M \backslash (i, i', l, l')$: M après suppression du lien (i, i') entre S_l et $S_{l'}$ $(m_{ii'}^{ll'} = 0)$

Principe de l'algorithme

1. Initialiser M_{Intra} par un couplage complet :

$$\forall\, i, i' \in \{1, ...T\} \text{ et } S_l,\ S_{l'} \text{ de même classe } m_{ii'}^{ll'} = 1$$

2. Mesurer la contribution $C_{i_1 i_2}^{l_1 l_2}$ de chaque lien i_1, i_2 entre S_{l_1} et S_{l_2} à la variance $V_{M\,Intra}$

$$C_{i_1 i_2}^{l_1 l_2} \quad = \quad V_{M_{Intra}} - V_{M_{Intra} \backslash (i_1, i_2, l_1, l_2)}$$

3. Pénaliser les liens (i_1, i_2) $(m_{i_1 i_2}^{l_1 l_2} = 0)$ de contributions $C_{i_1 i_2}^{l_1 l_2} > 0$

4. Réitérer les étapes 2 et 3 jusqu'à stabilisation de la variance intra

Apprentissage des appariements intra classes

$S_{l_1} = (x_1^{l_1}, ..., x_T^{l_1})$, $S_{l_2} = (x_1^{l_2}, ..., x_T^{l_2})$, de même classe C_k $(|C_k| = n_k)$

$M \backslash (i, i', l, l')$: M après suppression du lien (i, i') entre S_l et $S_{l'}$ $(m_{ii'}^{ll'} = 0)$

Principe de l'algorithme

1. Initialiser M_{Intra} par un couplage complet :

$$\forall\, i, i' \in \{1, ...T\} \text{ et } S_l,\ S_{l'} \text{ de même classe } m_{ii'}^{ll'} = 1$$

2. Mesurer la contribution $C_{i_1 i_2}^{l_1 l_2}$ de chaque lien i_1, i_2 entre S_{l_1} et S_{l_2} à la variance $V_{M\,Intra}$

$$C_{i_1 i_2}^{l_1 l_2} \quad = \quad V_{M_{Intra}} - V_{M_{Intra} \backslash (i_1, i_2, l_1, l_2)}$$

3. Pénaliser les liens (i_1, i_2) $(m_{i_1 i_2}^{l_1 l_2} = 0)$ de contributions $C_{i_1 i_2}^{l_1 l_2} > 0$

4. Réitérer les étapes 2 et 3 jusqu'à stabilisation de la variance intra

Conditions de non dégénérescence & convergence

$\forall k \in \{1, ..., K\},\ \forall (l, l') \in C_k,\ \forall (i, i') \in [1, T]^2$

Contraintes liées à la définition de la variance

1- $m_{ii}^{ll} > 0$

2- M_{Intra} normée en ligne : $\sum_{l'=1}^{n_k} \sum_{i'=1}^{T} m_{ii'}^{ll'} = 1$

Contrainte de non dégénérescence de la variance

3- Toute obs. i de S_l doit être connectée à au moins une obs. de $S_{l'}$: $\sum_{i'=1}^{T} m_{ii'}^{ll'} > 0$

Contrainte de convergence de la minimisation de la variance

4- La suppression d'un lien (i, i') influence le poids des voisins de i et i' (ligne i et i') : suppression par itération d'au plus un lien par ligne (max des contributions $C_{i_1 i_2}^{l_1 l_2} > 0$)

Conditions de non dégénérescence & convergence

$\forall k \in \{1, ..., K\},\ \forall (l, l') \in C_k,\ \forall (i, i') \in [1, T]^2$

Contraintes liées à la définition de la variance

1- $m_{ii}^{ll} > 0$

2- M_{Intra} normée en ligne : $\sum_{l'=1}^{n_k} \sum_{i'=1}^{T} m_{ii'}^{ll'} = 1$

Contrainte de non dégénérescence de la variance

3- Toute obs. i de S_l doit être connectée à au moins une obs. de $S_{l'}$: $\sum_{i'=1}^{T} m_{ii'}^{ll'} > 0$

Contrainte de convergence de la minimisation de la variance

4- La suppression d'un lien (i, i') influence le poids des voisins de i et i' (ligne i et i') : suppression par itération d'au plus un lien par ligne (max des contributions $C_{i_1 i_2}^{l_1 l_2} > 0$)

Conditions de non dégénérescence & convergence

$\forall k \in \{1, ..., K\},\ \forall (l, l') \in C_k,\ \forall (i, i') \in [1, T]^2$

Contraintes liées à la définition de la variance

1- $m_{ii}^{ll} > 0$

2- M_{Intra} normée en ligne : $\sum_{l'=1}^{n_k} \sum_{i'=1}^{T} m_{ii'}^{ll'} = 1$

Contrainte de non dégénérescence de la variance

3- Toute obs. i de S_l doit être connectée à au moins une obs. de $S_{l'}$: $\sum_{i'=1}^{T} m_{ii'}^{ll'} > 0$

Contrainte de convergence de la minimisation de la variance

4- La suppression d'un lien (i, i') influence le poids des voisins de i et i' (ligne i et i') : suppression par itération d'au plus un lien par ligne (max des contributions $C_{i_1 i_2}^{l_1 l_2} > 0$)

Complexité

- Par classe et par itération :

$$O(\sum_{k=1}^{K} n_k^3 T^3)$$

- Parallélisation de l'apprentissage de M_{Intra} et M_{Inter} par classe et par ligne

Algorithme: apprentissage de M_{Intra}

M = complete intra-class matching [1]
repeat
  $LinkRemoved = false$
  for all (l, l') *with* $y_l = y_{l'}$ and $l \neq l'$ **do**
    for all $(i, i') \in [1, T] \times [1, T]$ **do**
      $C_{ii'}^{ll'}$ evaluation [2]
    end for
  end for
  for all $(i, l) \in [1, T] \times [1, n]$ **do**
    $Link = argmax_{i',l'}(C_{ii'}^{ll'})$ (C.3-4) [3]
    if $Link \neq \emptyset$ **then**
      Remove $Link$ $(m_{i,i'}^{l,l'} = 0)$ and
      Update weights (C.1-2)
      $LinkRemoved = true$
    end if
  end for
until $\neg LinkRemoved$ [4]
$return(M_{Intra} = M)$

Applications : courbes de consommations électriques

Georges Hébrail (EDF Clamart)

- Mesures annuelles de la consommation électrique au sein d'un foyer individuel
- Courbes de consommations électriques journalières (échantillonnage / 10mn)

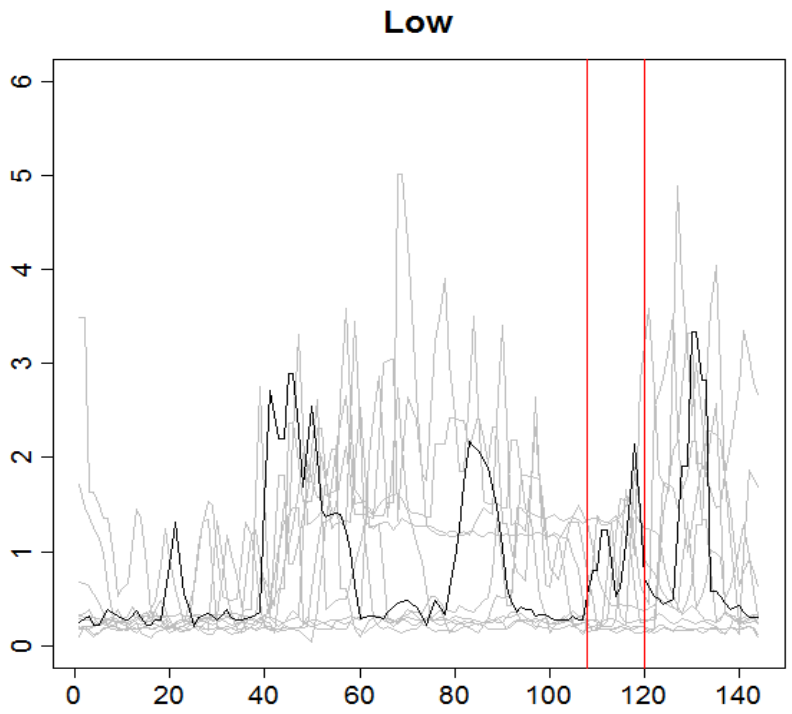

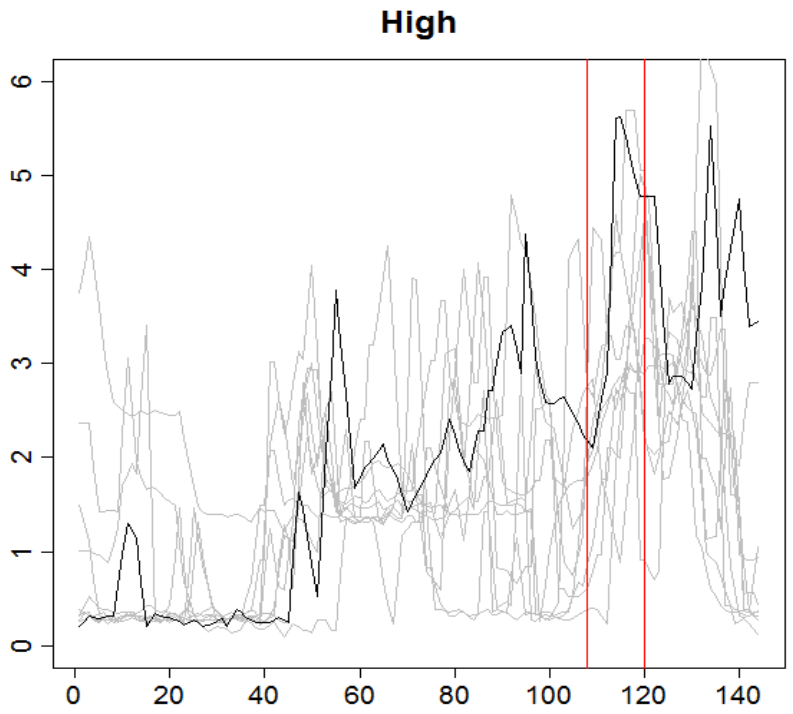

Objectif : prédiction précoces de la consommation électrique entre 18h-20h

Applications : courbes de consommations électriques

Georges Hébrail (EDF Clamart)

Appariements discriminant appris (CONSLEVEL)

M^*_{Intra} (Low)

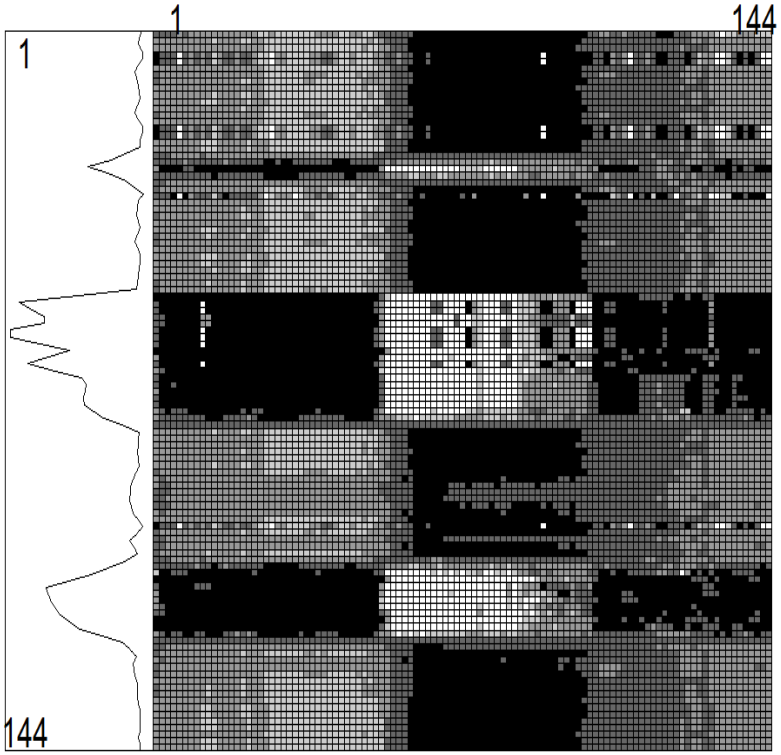

M^*_{Inter} (Low vs. High)

Applications : courbes de consommations électriques

Georges Hébrail (EDF Clamart)

Appariements discriminant appris (CONSLEVEL)

M^*_{Intra} (Low)

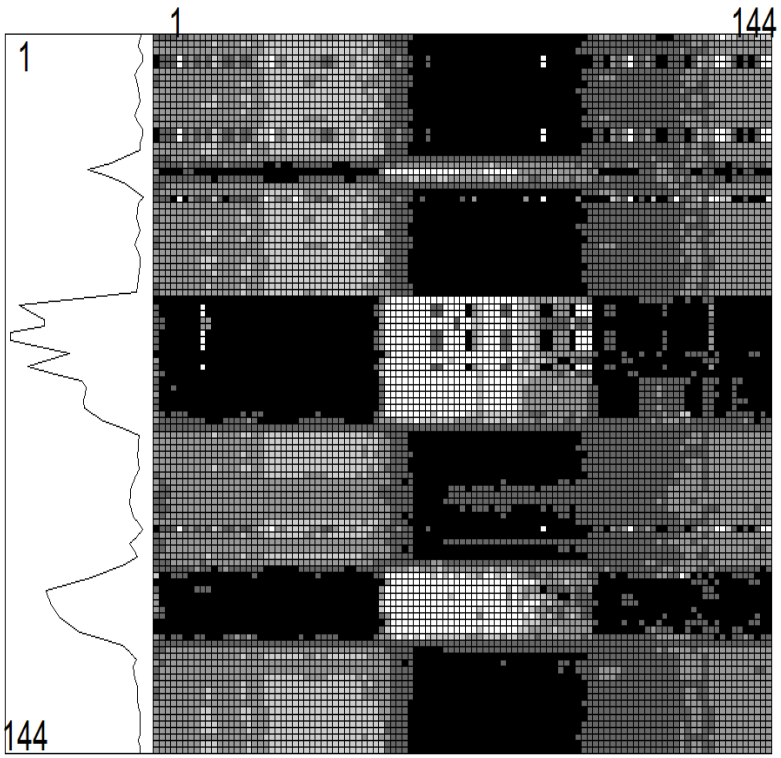

M^*_{Inter} (Low vs. High)

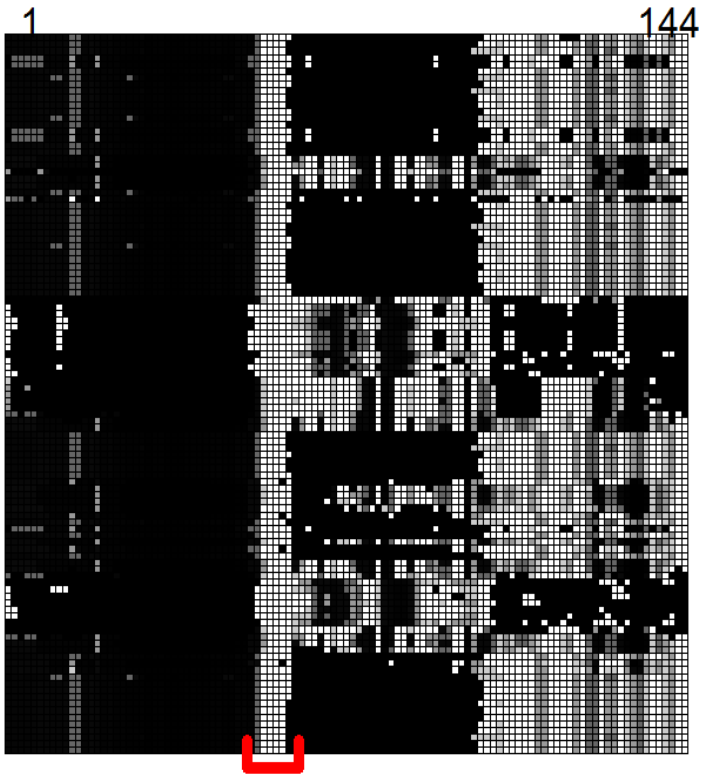

Applications : courbes de consommations électriques

- D fondée sur les alignements discriminants

Table 2: k-Nearest Neighbor classification error rates

	k	D	DE	DTW
BME	1	**0.032**	0.165	0.130
	3	0.034	0.208	0.132
	5	0.062	0.234	0.136
	7	0.079	0.297	0.191
UMD	1	**0.055**	0.173	0.121
	3	0.111	0.333	0.177
	5	0.173	0.343	0.225
	7	0.222	0.378	0.274
CONSLEVEL	1	**0.056**	0.306	**0.289**
	3	**0.044**	0.267	**0.261**
	5	**0.028**	0.233	**0.239**
	7	**0.017**	0.233	**0.233**
CONSSEASON	1	**0.094**	0.239	0.283
	3	0.128	0.228	0.311
	5	0.205	0.200	0.300
	7	0.111	0.222	0.306
TRAJ	1	0.014	**0.012**	0.019
	3	0.018	0.017	0.022
	5	0.022	0.021	0.028
	7	0.019	0.021	0.026

- Distribution des courbes de consommations (CONSLEVEL)

Applications : courbes de consommations électriques

- Distribution des courbes de consommations (CONSLEVEL)

- *D* fondée sur les alignements discriminants

Table 2: k-Nearest Neighbor classification error rates

	k	D	DE	DTW
BME	1	**0.032**	0.165	0.130
	3	0.034	0.208	0.132
	5	0.062	0.234	0.136
	7	0.079	0.297	0.191
UMD	1	**0.055**	0.173	0.121
	3	0.111	0.333	0.177
	5	0.173	0.343	0.225
	7	0.222	0.378	0.274
CONSLEVEL	1	**0.056**	0.306	**0.289**
	3	**0.044**	0.267	**0.261**
	5	**0.028**	0.233	**0.239**
	7	**0.017**	0.233	**0.233**
CONSSEASON	1	**0.094**	0.239	0.283
	3	0.128	0.228	0.311
	5	0.205	0.200	0.300
	7	0.111	0.222	0.306
TRAJ	1	0.014	**0.012**	0.019
	3	0.018	0.017	0.022
	5	0.022	0.021	0.028
	7	0.019	0.021	0.026

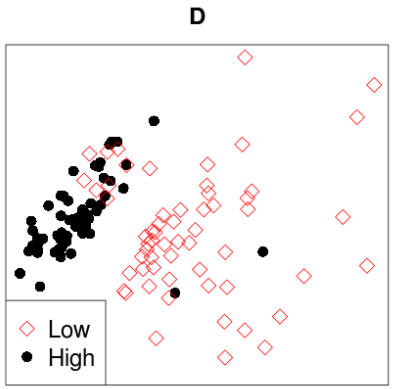

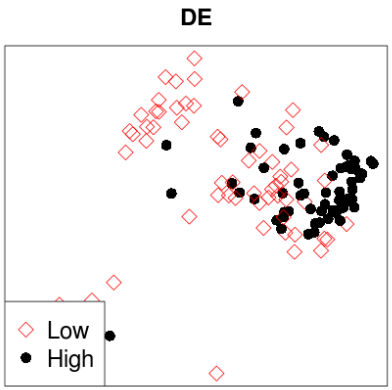

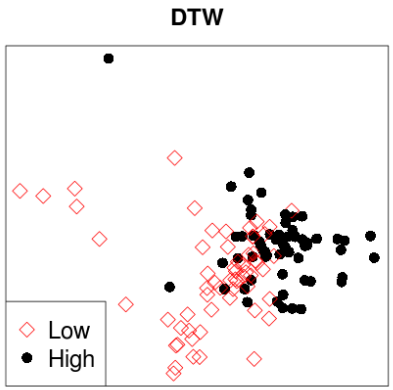

Troisième partie

Intégration de la "forme" des séries

Problème et objectif

- **Problème & objectif**
  - Classification des séries sur la base de la "forme"
  - **Objectif** : Métrique intégrant la composante "forme" des séries
- **Limites des approches existantes**
  - Comparaison des valeurs des séries (ignore le voisinage temporel)
- **Contributions**
  - Définition d'une métrique capturant la forme des séries
  - Métriques adaptatives alliant les composantes formes et valeurs.
  - Extension des arbres de classification à des séries

Problème et objectif

- **Problème & objectif**
  - Classification des séries sur la base de la "forme"

Profils d'expression de gènes

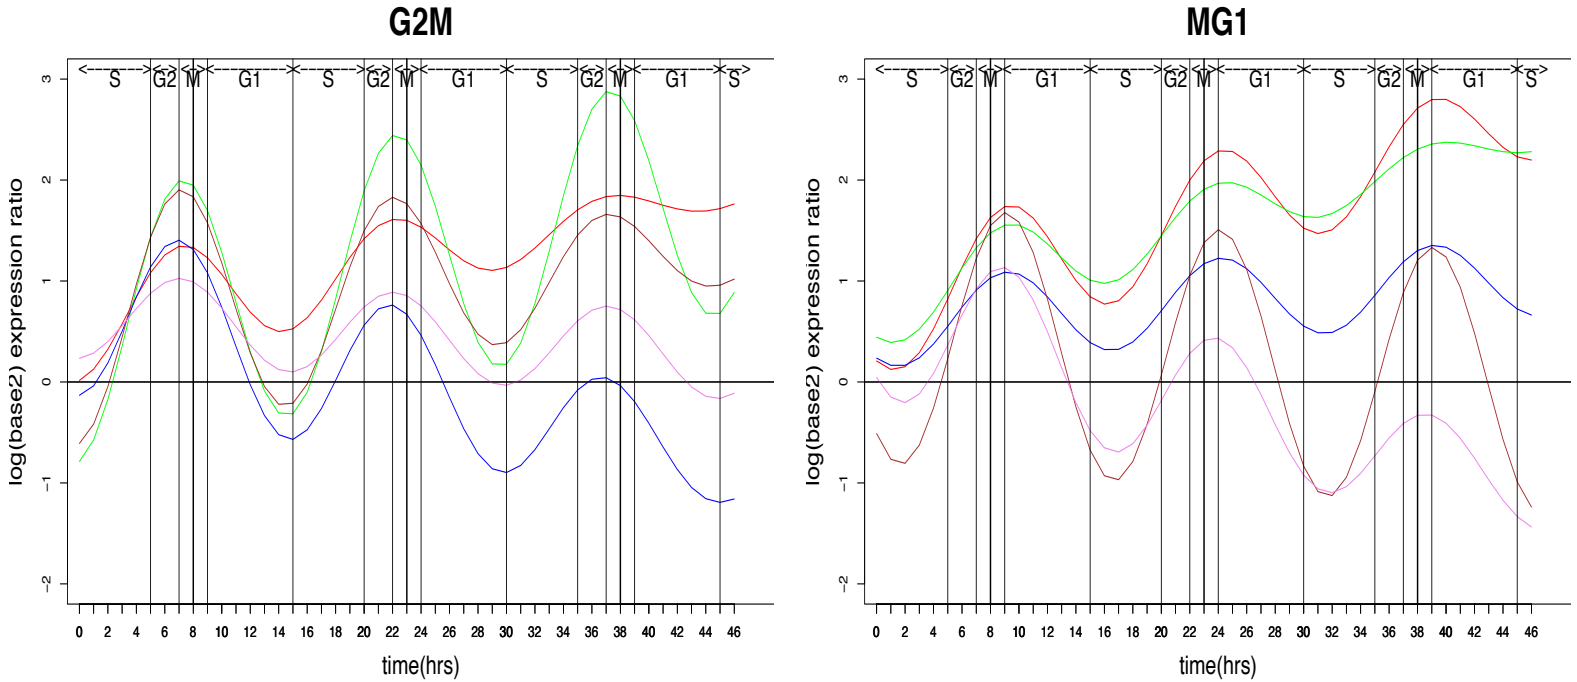

  - **Objectif** : Métrique intégrant la composante "forme" des séries

- Limites des approches existantes

Problème et objectif

- **Problème & objectif**
  - Classification des séries sur la base de la "forme"
  - **Objectif** : Métrique intégrant la composante "forme" des séries
- **Limites des approches existantes**
  - Comparaison des valeurs des séries (ignore le voisinage temporel)
- **Contributions**
  - Définition d'une métrique capturant la forme des séries
  - Métriques adaptatives alliant les composantes formes et valeurs.
  - Extension des arbres de classification à des séries

Problème et objectif

- **Problème & objectif**
  - Classification des séries sur la base de la "forme"
  - **Objectif** : Métrique intégrant la composante "forme" des séries
- **Limites des approches existantes**
  - Comparaison des valeurs des séries (ignore le voisinage temporel)
- **Contributions**
  - Définition d'une métrique capturant la forme des séries
  - Métriques adaptatives alliant les composantes formes et valeurs.
  - Extension des arbres de classification à des séries

Problème et objectif

- **Problème & objectif**
  - Classification des séries sur la base de la "forme"
  - **Objectif** : Métrique intégrant la composante "forme" des séries
- **Limites des approches existantes**
  - Comparaison des valeurs des séries (ignore le voisinage temporel)
- **Contributions**
  - Définition d'une métrique capturant la forme des séries
  - Métriques adaptatives alliant les composantes formes et valeurs.
  - Extension des arbres de classification à des séries

Comparaison de la forme des séries

Quelques travaux

- Coefficient de Kendall, distance qualitative pour la comparaison des accroissements Todorovski et al. 2002, Son et Baek 2008
- Coefficient de Spearman pour la comparaison des rangs des observations Balasubramanian et al 2004
- Coefficient de corrélation de Pearson, autocorrélations Abraham et al. 2010, Cabestaing et al. 2007, Rydell et al. 2008, Gaidon et al. 2011

Limites principales

- Coefficient de corrélation de Pearson
  - Implique tous les couples i, i' (présume de l'indépendance des observations)
  - Surestime la similarité entre formes
- Autocorrélation
  - Invariant pour des dynamiques opposées
  - Autocorrélations proches $\not\Rightarrow$ dynamiques similaires !

Comparaison de la forme des séries

Quelques travaux

- Coefficient de Kendall, distance qualitative pour la comparaison des accroissements Todorovski et al. 2002, Son et Baek 2008
- Coefficient de Spearman pour la comparaison des rangs des observations Balasubramanian et al 2004
- Coefficient de corrélation de Pearson, autocorrélations Abraham et al. 2010, Cabestaing et al. 2007, Rydell et al. 2008, Gaidon et al. 2011

Limites principales

- Coefficient de corrélation de Pearson
  - Implique tous les couples i, i' (présume de l'indépendance des observations)
  - Surestime la similarité entre formes
- Autocorrélation
  - Invariant pour des dynamiques opposées
  - Autocorrélations proches $\not\Rightarrow$ dynamiques similaires !

Comparaison de la forme des séries

Quelques travaux

- Coefficient de Kendall, distance qualitative pour la comparaison des accroissements Todorovski et al. 2002, Son et Baek 2008
- Coefficient de Spearman pour la comparaison des rangs des observations Balasubramanian et al 2004
- Coefficient de corrélation de Pearson, autocorrélations Abraham et al. 2010, Cabestaing et al. 2007, Rydell et al. 2008, Gaidon et al. 2011

Limites principales

- Coefficient de corrélation de Pearson
  - Implique tous les couples i, i' (présume de l'indépendance des observations)
  - Surestime la similarité entre formes
- Autocorrélation
  - Invariant pour des dynamiques opposées
  - Autocorrélations proches $\not\Rightarrow$ dynamiques similaires !

Comparaison de la forme des séries

Quelques travaux

- Coefficient de Kendall, distance qualitative pour la comparaison des accroissements Todorovski et al. 2002, Son et Baek 2008
- Coefficient de Spearman pour la comparaison des rangs des observations Balasubramanian et al 2004
- Coefficient de corrélation de Pearson, autocorrélations Abraham et al. 2010, Cabestaing et al. 2007, Rydell et al. 2008, Gaidon et al. 2011

Limites principales

- Coefficient de corrélation de Pearson
  - Implique tous les couples i, i' (présume de l'indépendance des observations)
  - Surestime la similarité entre formes
- Autocorrélation
  - Invariant pour des dynamiques opposées
  - Autocorrélations proches $\not\Rightarrow$ dynamiques similaires !

Comparaison de la forme des séries

Quelques travaux

- Coefficient de Kendall, distance qualitative pour la comparaison des accroissements Todorovski et al. 2002, Son et Baek 2008
- Coefficient de Spearman pour la comparaison des rangs des observations Balasubramanian et al 2004
- Coefficient de corrélation de Pearson, autocorrélations Abraham et al. 2010, Cabestaing et al. 2007, Rydell et al. 2008, Gaidon et al. 2011

Limites principales

- Coefficient de corrélation de Pearson
  - Implique tous les couples i, i' (présume de l'indépendance des observations)
  - Surestime la similarité entre formes
- Autocorrélation
  - Invariant pour des dynamiques opposées
  - Autocorrélations proches $\not\Rightarrow$ dynamiques similaires !

Contribution

Coefficient de corrélation temporelle $Cort(x, y)$ d'ordre r

$$Cort(x,y) = \frac{\sum_{i,i'} m_{ii'}(x_i - x_{i'})(y_i - y_{i'})}{\sqrt{\sum_{i,i'} m_{ii'}(x_i - x_{i'})^2}\sqrt{\sum_{i,i'} m_{ii'}(y_i - y_{i'})^2}} = \frac{Cov_M}{\sqrt{Var_M}}$$

$M(m_{ii'})$: $m_{ii'} = 1$ si $|i' - i| \leq r$, 0 sinon (dépendance temporelle de voisinage r)

Force et faiblesse

+ Dynamiques similaires $\Leftrightarrow$ Coefficient de corrélation temporelle fort
- Sensible aux bruits, pris en compte pour fixer r

Analyses fondées sur *Cort*

- Analyse de données d'expression de gènes (Thèse : A. Diallo, F. Giroud)
- Définition de métriques adaptatives alliant formes et valeurs des séries (P. Nagabhushan)
- Extension des arbres de classification à des séries (C. Amblard)

Contribution

Coefficient de corrélation temporelle $Cort(x, y)$ d'ordre r

$$Cort(x,y) = \frac{\sum_{i,i'} m_{ii'}(x_i - x_{i'})(y_i - y_{i'})}{\sqrt{\sum_{i,i'} m_{ii'}(x_i - x_{i'})^2}\sqrt{\sum_{i,i'} m_{ii'}(y_i - y_{i'})^2}} = \frac{Cov_M}{\sqrt{Var_M}}$$

$M(m_{ii'})$: $m_{ii'} = 1$ si $|i' - i| \leq r$, 0 sinon (dépendance temporelle de voisinage r)

Force et faiblesse

+ Dynamiques similaires $\Leftrightarrow$ Coefficient de corrélation temporelle fort
- Sensible aux bruits, pris en compte pour fixer r

Analyses fondées sur *Cort*

- Analyse de données d'expression de gènes (Thèse : A. Diallo, F. Giroud)
- Définition de métriques adaptatives alliant formes et valeurs des séries (P. Nagabhushan)
- Extension des arbres de classification à des séries (C. Amblard)

Contribution

Coefficient de corrélation temporelle $Cort(x, y)$ **d'ordre** r

$$Cort(x,y) = \frac{\sum_{i,i'} m_{ii'}(x_i - x_{i'})(y_i - y_{i'})}{\sqrt{\sum_{i,i'} m_{ii'}(x_i - x_{i'})^2}\sqrt{\sum_{i,i'} m_{ii'}(y_i - y_{i'})^2}} = \frac{Cov_M}{\sqrt{Var_M}}$$

$M(m_{ii'})$: $m_{ii'} = 1$ si $|i' - i| \leq r$, 0 sinon (dépendance temporelle de voisinage r)

Force et faiblesse

+ Dynamiques similaires $\Leftrightarrow$ Coefficient de corrélation temporelle fort
- Sensible aux bruits, pris en compte pour fixer r

Analyses fondées sur *Cort*

- Analyse de données d'expression de gènes (Thèse : A. Diallo, F. Giroud)
- Définition de métriques adaptatives alliant formes et valeurs des séries (P. Nagabhushan)
- Extension des arbres de classification à des séries (C. Amblard)

Classification par arbre de séries ("Digits")

Nouveau critère de coupure

- Métrique alliant les composantes forme et valeurs des séries
- Métrique adaptative adapter le compromis forme/valeurs aux propriétés dynamiques des séries
- Localisation de sous-séquences discriminantes
- Interprétabilité de l'arbre induit

Classification par arbre de séries ("Digits")

Nouveau critère de coupure

- Métrique alliant les composantes forme et valeurs des séries
- Métrique adaptative adapter le compromis forme/valeurs aux propriétés dynamiques des séries
- Localisation de sous-séquences discriminantes
- Interprétabilité de l'arbre induit

Classification par arbre de séries ("Digits")

Nouveau critère de coupure

- Métrique alliant les composantes forme et valeurs des séries
- Métrique adaptative adapter le compromis forme/valeurs aux propriétés dynamiques des séries
- Localisation de sous-séquences discriminantes
- Interprétabilité de l'arbre induit

Classification par arbre de séries ("Digits")

Nouveau critère de coupure

- Métrique alliant les composantes forme et valeurs des séries
- Métrique adaptative adapter le compromis forme/valeurs aux propriétés dynamiques des séries
- Localisation de sous-séquences discriminantes
- Interprétabilité de l'arbre induit

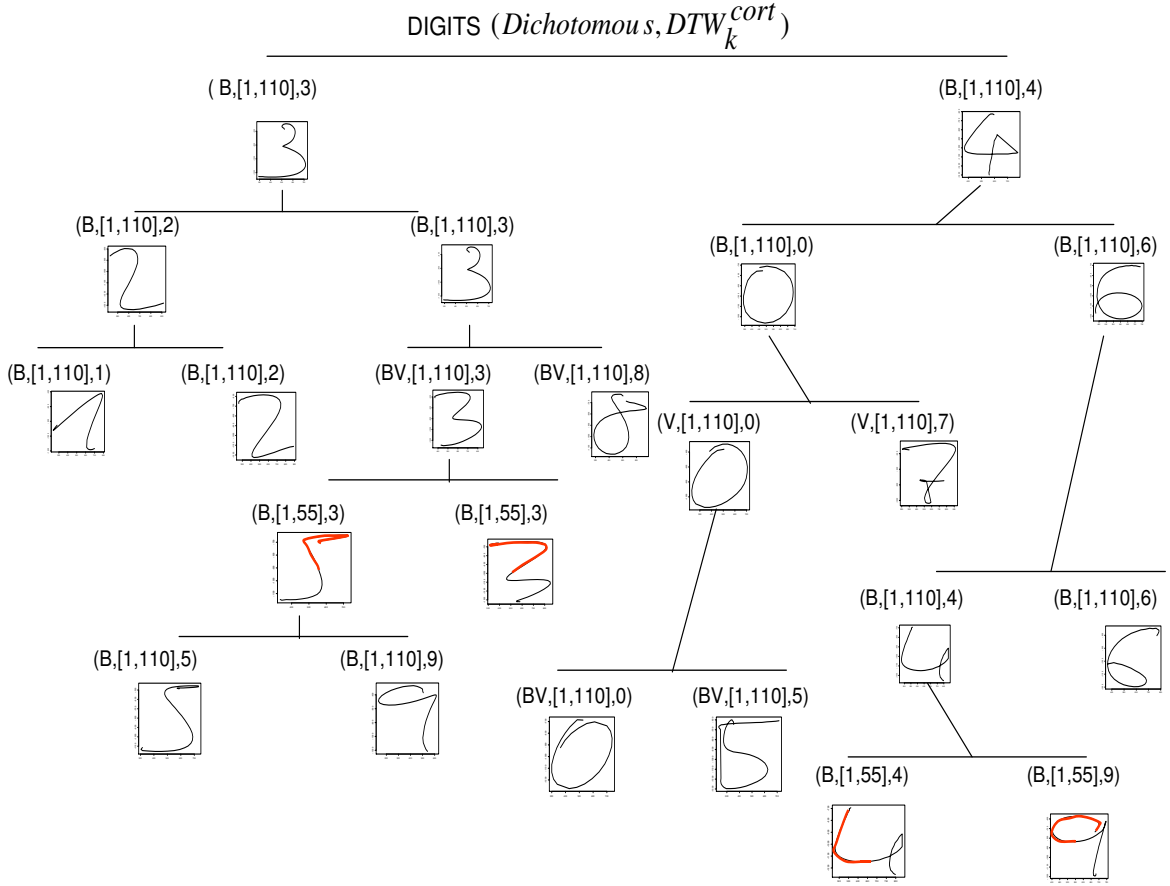

Conclusion

- **Analyse de longues séries multivariées**
  - Segmentation : nouvelles approches de segmentation de séries multivariées préservant les corrélations
- **Classification de séries de structures complexes**
  - Appariements discriminants : nouvelle stratégie d'appariement révélant les caractéristiques discriminants des classes de séries
- **Classification des séries intégrant la composante "Forme"**
  - Forme des séries : a) une mesure de similarité fondée sur la forme des séries, b) métriques adaptatives alliant les composantes forme et valeurs et c) nouveau critère de coupure étendant les arbres de classification à des séries temporelles

Conclusion

- **Analyse de longues séries multivariées**
  - Segmentation : nouvelles approches de segmentation de séries multivariées préservant les corrélations
- **Classification de séries de structures complexes**
  - Appariements discriminants : nouvelle stratégie d'appariement révélant les caractéristiques discriminants des classes de séries
- **Classification des séries intégrant la composante "Forme"**
  - Forme des séries : a) une mesure de similarité fondée sur la forme des séries, b) métriques adaptatives alliant les composantes forme et valeurs et c) nouveau critère de coupure étendant les arbres de classification à des séries temporelles

Conclusion

- **Analyse de longues séries multivariées**
  - Segmentation : nouvelles approches de segmentation de séries multivariées préservant les corrélations
- **Classification de séries de structures complexes**
  - Appariements discriminants : nouvelle stratégie d'appariement révélant les caractéristiques discriminants des classes de séries
- **Classification des séries intégrant la composante "Forme"**
  - Forme des séries : a) une mesure de similarité fondée sur la forme des séries, b) métriques adaptatives alliant les composantes forme et valeurs et c) nouveau critère de coupure étendant les arbres de classification à des séries temporelles

Publications

Cinq revues majeures

- Advanced Data Analysis and Classification (2007)
- Computational Statistics and Data Analysis (2009)
- Pattern Recognition Letters (2010)
- Statistical Analysis and Data Mining (2011)
- Pattern Recognition (2012)

Publications (36 publications)

- 5 revues internationales, 2 revues nationales avec comité de lecture, 4 chapitres de livres, 9 conférences internationales avec publication des actes, 6 conférences internationales à publications courtes, 10 conférences nationales avec publication des actes, 3 thèses co-encadrées

Perspectives

À très brèves échéances

- Pallier la surparamétrisation des appariements
  - Régularisation des blocs $M_{ll'}$
  - Initialisation par bloc diagonaux entre segments saillants (DIALIGN, Brudno et al. 2003)

Analyse de la dépendance temporelle

- Classification non supervisée par apprentissage d'appariements (définition de prototypes)
- Étude de noyaux dédiés aux séries (analyse des séries par des méthodes à noyaux)

Analyse de la dépendance liée à des structures plus générales

- Analyse de structures impliquant différents types de dépendances (par décomposition de matrices non négatives)
- Analyse de graphes évolutifs, de structures spatio-temporelles

Perspectives

À très brèves échéances

- Pallier la surparamétrisation des appariements
  - Régularisation des blocs $M_{ll'}$
  - Initialisation par bloc diagonaux entre segments saillants (DIALIGN, Brudno et al. 2003)

Analyse de la dépendance temporelle

- Classification non supervisée par apprentissage d'appariements (définition de prototypes)
- Étude de noyaux dédiés aux séries (analyse des séries par des méthodes à noyaux)

Analyse de la dépendance liée à des structures plus générales

- Analyse de structures impliquant différents types de dépendances (par décomposition de matrices non négatives)
- Analyse de graphes évolutifs, de structures spatio-temporelles

Perspectives

À très brèves échéances

- Pallier la surparamétrisation des appariements
  - Régularisation des blocs $M_{ll'}$
  - Initialisation par bloc diagonaux entre segments saillants (DIALIGN, Brudno et al. 2003)

Analyse de la dépendance temporelle

- Classification non supervisée par apprentissage d'appariements (définition de prototypes)
- Étude de noyaux dédiés aux séries (analyse des séries par des méthodes à noyaux)

Analyse de la dépendance liée à des structures plus générales

- Analyse de structures impliquant différents types de dépendances (par décomposition de matrices non négatives)
- Analyse de graphes évolutifs, de structures spatio-temporelles

Projets en cours

Analyse de la dépendance temporelle

- Biologie
  - ANR DYNOTEP (SVSE6) avec le CEA (début 2013, 25%)
    - Exploration de profils d'abondance de peptides pour l'analyse de la dynamique de cellules endocytaires
- Réseaux de capteurs
  - Schneider : Innovation pour l'Efficacité Energétique
    - Étude de méthodes d'apprentissage adaptées au réseaux de capteurs
    - Thèse : Cao-Tri Do (Cifre, debut : janvier 2013), Co-Dir M. Rambaut

Analyse de la dépendance liée à des structures plus générales

- Réseaux sociaux
  - BestOfMedia
    - Détection et prédiction de thèmes émergents dans les médias sociaux
    - Thèse : F. Kawala (Cifre, début : sep 2011), Dir. E. Gaussier
  - Namayan Farda Company
    - Prédiction de liens dans des réseaux évolutifs
    - Thèse : S. Souheily (début : mars 2013), Co-Dir. E. Gaussier
- Spatio/temporel
  - Apprentissage et recommandation d'itinéraires partagés à partir de trajectories GPS (spatio-temporel), H. Martin

Projets en cours

Analyse de la dépendance temporelle

- Biologie
  - ANR DYNOTEP (SVSE6) avec le CEA (début 2013, 25%)
    - Exploration de profils d'abondance de peptides pour l'analyse de la dynamique de cellules endocytaires
- Réseaux de capteurs
  - Schneider : Innovation pour l'Efficacité Energétique
    - Étude de méthodes d'apprentissage adaptées au réseaux de capteurs
    - Thèse : Cao-Tri Do (Cifre, debut : janvier 2013), Co-Dir M. Rambaut

Analyse de la dépendance liée à des structures plus générales

- Réseaux sociaux
  - BestOfMedia
    - Détection et prédiction de thèmes émergents dans les médias sociaux
    - Thèse : F. Kawala (Cifre, début : sep 2011), Dir. E. Gaussier
  - Namayan Farda Company
    - Prédiction de liens dans des réseaux évolutifs
    - Thèse : S. Souheily (début : mars 2013), Co-Dir. E. Gaussier
- Spatio/temporel
  - Apprentissage et recommandation d'itinéraires partagés à partir de trajectories GPS (spatio-temporel), H. Martin

Projets en cours

Analyse de la dépendance temporelle

- Biologie
  - ANR DYNOTEP (SVSE6) avec le CEA (début 2013, 25%)
    - Exploration de profils d'abondance de peptides pour l'analyse de la dynamique de cellules endocytaires
- Réseaux de capteurs
  - Schneider : Innovation pour l'Efficacité Energétique
    - Étude de méthodes d'apprentissage adaptées au réseaux de capteurs
    - Thèse : Cao-Tri Do (Cifre, debut : janvier 2013), Co-Dir M. Rambaut

Analyse de la dépendance liée à des structures plus générales

- Réseaux sociaux
  - BestOfMedia
    - Détection et prédiction de thèmes émergents dans les médias sociaux
    - Thèse : F. Kawala (Cifre, début : sep 2011), Dir. E. Gaussier
  - Namayan Farda Company
    - Prédiction de liens dans des réseaux évolutifs
    - Thèse : S. Souheily (début : mars 2013), Co-Dir. E. Gaussier
- Spatio/temporel
  - Apprentissage et recommandation d'itinéraires partagés à partir de trajectories GPS (spatio-temporel), H. Martin

Projets en cours

Analyse de la dépendance temporelle

- Biologie
  - ANR DYNOTEP (SVSE6) avec le CEA (début 2013, 25%)
    - Exploration de profils d'abondance de peptides pour l'analyse de la dynamique de cellules endocytaires
- Réseaux de capteurs
  - Schneider : Innovation pour l'Efficacité Energétique
    - Étude de méthodes d'apprentissage adaptées au réseaux de capteurs
    - Thèse : Cao-Tri Do (Cifre, debut : janvier 2013), Co-Dir M. Rambaut

Analyse de la dépendance liée à des structures plus générales

- Réseaux sociaux
  - BestOfMedia
    - Détection et prédiction de thèmes émergents dans les médias sociaux
    - Thèse : F. Kawala (Cifre, début : sep 2011), Dir. E. Gaussier
  - Namayan Farda Company
    - Prédiction de liens dans des réseaux évolutifs
    - Thèse : S. Souheily (début : mars 2013), Co-Dir. E. Gaussier
- Spatio/temporel
  - Apprentissage et recommandation d'itinéraires partagés à partir de trajectories GPS (spatio-temporel), H. Martin

Projets en cours

Analyse de la dépendance temporelle

- Biologie
  - ANR DYNOTEP (SVSE6) avec le CEA (début 2013, 25%)
    - Exploration de profils d'abondance de peptides pour l'analyse de la dynamique de cellules endocytaires
- Réseaux de capteurs
  - Schneider : Innovation pour l'Efficacité Energétique
    - Étude de méthodes d'apprentissage adaptées au réseaux de capteurs
    - Thèse : Cao-Tri Do (Cifre, debut : janvier 2013), Co-Dir M. Rambaut

Analyse de la dépendance liée à des structures plus générales

- Réseaux sociaux
  - BestOfMedia
    - Détection et prédiction de thèmes émergents dans les médias sociaux
    - Thèse : F. Kawala (Cifre, début : sep 2011), Dir. E. Gaussier
  - Namayan Farda Company
    - Prédiction de liens dans des réseaux évolutifs
    - Thèse : S. Souheily (début : mars 2013), Co-Dir. E. Gaussier
- Spatio/temporel
  - Apprentissage et recommandation d'itinéraires partagés à partir de trajectories GPS (spatio-temporel), H. Martin

Merci !

Considérations calculatoires

- Le calcul des contributions $C_{i_1 i_2}^{l_1 l_2}$

$$
\begin{aligned}
C_{i_1 i_2}^{l_1 l_2} &= V_{M^{Intra}} - V_{M^{Intra} \setminus (i_1, i_2, l_1, l_2)} \\
&= \frac{1}{nT}(x_{i_1}^{l_1} - \sum_{l'=1}^{n_k} \sum_{i'=1}^{T} m_{i_1 i'}^{l_1 l'} x_{i'}^{l'})^2 - \frac{1}{nT}(x_{i_1}^{l_1} - \sum_{l'=1}^{n_k} \sum_{i'=1}^{T} \frac{m_{i_1 i'}^{l_1 l'}}{1 - m_{i_1 i_2}^{l_1 l_2}} x_{i'}^{l'})^2 \quad (1)
\end{aligned}
$$

$C_{i_1 i_2}^{l_1 l_2}$ se réduit à la différence entre deux valeurs centrées, impliquant les seules lignes i_1, et i_2 de M^{Intra}

- Couplage initial par blocs diagonaux entre segments saillants (DIALIGN, Brudno et al. 2003)

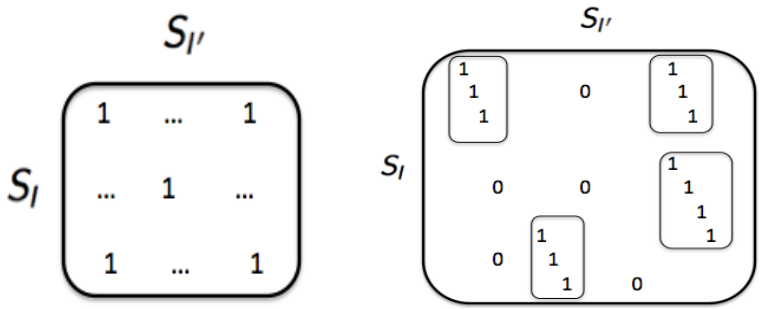

Complexité

- Nb de liens évalués :

$$\approx O(\sum_{k=1}^{K} l_k n_k^2 T^2)$$

Au pire, $l_k = (n_k - 1)(T - 1)$

$$\approx O(\sum_{k=1}^{K} n_k^3 T^3)$$

- Parallélisation de l'apprentissage de M_{Intra} et M_{Inter} par classe et par ligne

Algorithme: apprentissage de M_{Intra}

M = complete intra-class matching [1]
repeat
  $LinkRemoved = false$
  for all (l, l') *with* $y_l = y_{l'}$ and $l \neq l'$ **do**
    for all $(i, i') \in [1, T] \times [1, T]$ **do**
      $C_{ii'}^{ll'}$ evaluation [2]
    end for
  end for
  for all $(i, l) \in [1, T] \times [1, n]$ **do**
    $Link = argmax_{i',l'}(C_{ii'}^{ll'})$ [3]
    if $Link \neq \emptyset$ **then**
      Remove $Link$ $(m_{i,i'}^{l,l'} = 0)$ and
      Update weights
      $LinkRemoved = true$
    end if
  end for
until $\neg LinkRemoved$
$return(M_{Intra} = M)$ [4]

2. Comparaison classique des séries

$\mathbf{x} = (x_1, ..., x_n)$, $\mathbf{y} = (y_1, ..., y_m)$ éléments de $X = \Re^d$

$$\begin{aligned} DTS(\mathbf{x}, \mathbf{y}) &= min_{\pi \in A(n,m)} D_{\mathbf{x},\mathbf{y}}(\pi) \\ D_{\mathbf{x},\mathbf{y}}(\pi) &= sum_{i=1}^{|\pi|} \varphi(x_{\pi_1(i)}, y_{\pi_2(i)}) \end{aligned}$$

$A(n, m)$: l'ensemble des alignements $\pi(\mathbf{x}, \mathbf{y})$

$(\pi_1(i), \pi_2(i))$: i^{eme} couple d'observations alignées

$\varphi(x_{\pi_1(i)}, y_{\pi_2(i)}) = \|x_{\pi_1(i)} - y_{\pi_2(i)}\|^2$, ignore le voisinage temporel des valeurs

Comparaison de la forme des séries : autocorrélation

Mesures fondées sur les autocorrélations (Chatfield 2009)

$$\mathbf{x} = (x_1, ..., x_n), \mathbf{y} = (y_1, ..., y_n)$$

$$\rho_\tau(x) = \frac{\sum_{i=1}^{T-\tau}(x_i - \bar{x})(x_{i+\tau} - \bar{x})}{\sum_{i=1}^{T}(x_i - \bar{x})^2}$$

Faiblesse

- Coefficient d'autocorrélations ρ_τ proches $\not\Rightarrow$ dynamiques similaires !

$$\tilde{x} = (\rho_1(x), ..., \rho_K(x)) \quad \tilde{y} = (\rho_1(y), ..., \rho_K(y))$$

$$D(x, y) = \varphi(\tilde{x}, \tilde{y})$$

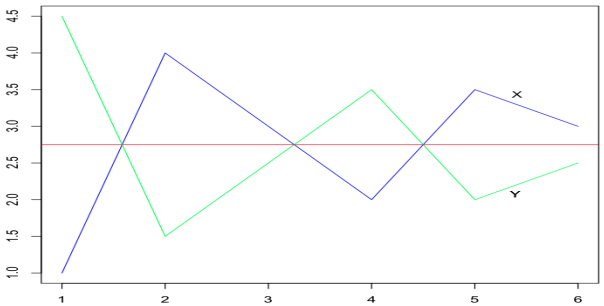

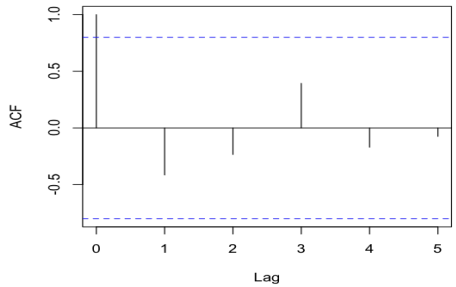

$$\tilde{x} = \tilde{y} = (1.000, -0.415, -0.234, 0.394, -0.170, -0.074)$$

Comparaison de la forme des séries : corrélations & autocorrélation

Coefficient de corrélations de Pearson

$$\mathbf{x} = (x_1, ..., x_n),\ \mathbf{y} = (y_1, ..., y_n)$$

$$Cor(x, y) = \frac{\sum_{i,i'}(x_i - x_{i'})(y_i - y_{i'})}{\sqrt{\sum_{i,i'}(x_i - x_{i'})^2}\sqrt{\sum_{i,i'}(y_i - y_{i'})^2}}$$

Faiblesses

- Implique tous les couples i, i' (présume les obs. indépendantes)
- Surestime la similarité entre formes

Segmentation

Caractéristiques des approches standards

- Recherche de points changements de caractéristiques (moyenne, variance), ne rend pas compte de la dépendance temporelle des observations,

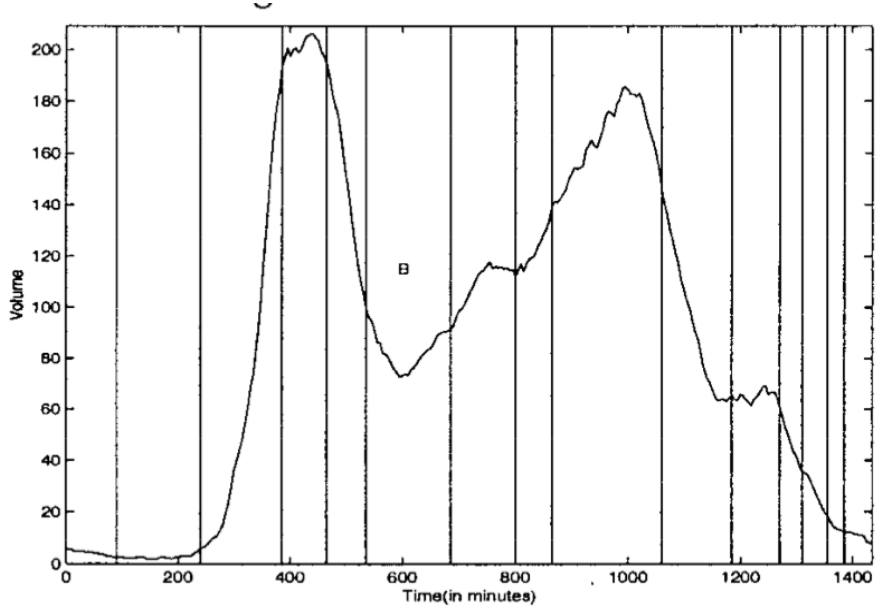

Change points detection by likelihood estimate Guralnik et al. 99

[20, 33, 34, 39, 43, 1, 12, 6, 13, 8, 5, 2, 10, 4, 9, 7, 3, 14, 18, 17, 16, 15, 22, 19, 36, 23, 25, 30, 28, 27, 26, 29, 24, 11, 21, 32, 35, 31, 38, 37, 41, 40, 42]

P. Cazes, A. Chouakria, E. Diday, and Y. Schektman.
Extension de l'analyse en composantes principales à des données intervalles.
Revue de statistiques appliquées, XLV(3):5–24, 1997.

A. Chouakria.
Extension de l'analyse en composantes principales à des données de type intervalle. Thèse,Paris IX Dauphine.
PhD thesis, Paris IX Dauphine, INRIA-Rocquencourt, 1998.

A. Chouakria, P. Cazes, and E. Diday.
Analysis of Symbolic Data Exploratory Methods for Extracting Statistical Information from Complex Data, chapter Symbolic Principal component Analysis, pages 200–212.
Springer-Verlag. Berlin, bock, h.h. and diday, e. edition, 2000.

A. Chouakria, E. Diday, and P. Cazes.
Extension de l'analyse factorielle des correspondances multiples à des données de type intervalle et de type ensemble.

In *Société Francophone de Classification (SFC'95)*, Namur, 1995.

A. Chouakria, E. Diday, and P. Cazes.
Extension of the principal component analysis to interval data.
In *New Techniques and Technologies for Statistics*, Bonn, 1995.

A. Chouakria, E. Diday, and P. Cazes.
Généralisation, en vue d'une acm du découpage en classes d'effectifs égaux à des variables de type intervalle.
Technical report, Association de la Statistique et de ses Utilisateurs (ASU'97), Carcassonne, 1997.

A. Chouakria, E. Diday, and P. Cazes.
Advances in Data Science and Classification, chapter Vertices Principal Components Analysis with an Improved Factorial Representation, pages 397–402.
ISBN: 3-540-6441-8. Springer Verlag, a. rizzi, and m. vichi, and h.h. bock edition, 1998.

A. Chouakria, E. Diday, and P. Cazes.

An improved factorial representation of symbolic objects.
In *Knowledge Extraction from Statistical Data (KESDA'98)*, Luxembourg, 1998.

A. Chouakria, R. Verde, E. Diday, and P. Cazes.
Généralisation de l'analyse factorielle des correspondances multiples à des objets symboliques.
In *Société Francophone de Classification (SFC'96)*, Vannes, 1996.

A. Chouakria-Douzal.
Réduction de dimension par extraction des tendances locales composant une séquence temporelle multivariée.
Technical Report RR-IMAG 1053-I, UJF/CNRS/TIMC, 2002.

A. Chouakria-Douzal.
Compression technique preserving correlations of a multivariate temporal sequence.
In M. R. Berthold, H-J. Lenz, E. Bradley, R. Kruse, and C. Borgelt, editors, *Advances in Intelligent Data Analysis*, volume V, pages 566–577. Springer, 2003.

A. Chouakria Douzal.
On the distance measure between time series.
In *International Association for Statistical Computing (IASC'05)*, Cyprus, 2005.

A. Chouakria-Douzal and P. Nagabhushan.
Improved fréchet distance for time series.
In *Data Science and Classification*, Studies in Classification, Data Analysis, and Knowledge Organization, pages 13–20. 2006.

J. Demongeot, B. Beaucamps, T. Chaperon, A. Douzal-Chouakria, T. Faraut, M. Simonet, and A. Simonet.
Estimating joint probabilities in the context of probabilistic management of querying and integrity in a knowledge database.
In F. Matús and M. Studeny, editors, *Conditional Independence Structures and Graphical Models*, pages 21–23, Field Institute, Toronto, 1999.

A. Diallo, A. Douzal-Chouakria, and F. Giroud.

Classification adaptative de séries temporelles : application à l'identification des gènes exprimés au cours du cycle cellulaire.
Revue des Nouvelles Technologies de l'Information, 11:487–498, 2008.

A. Diallo, A. Douzal-Chouakria, and F. Giroud.
Comparaisons et évaluation de métriques pour la classification de profils d'expression de gènes.
In *Société Francophone de Classification*, number 65-68, Grenoble, 2009.

A. Diallo, A. Douzal-Chouakria, and F. Giroud.
Which distance for the identification and the differentiation of cell-cycle expressed genes?
In *Advances in Intelligent Data Analysis VIII*, volume 5772 of *Lecture Notes in Computer Science*, pages 273–284, 2009.

A. Diallo, A. Douzal-Chouakria, and F. Giroud.
Un modèle génératif pour la comparaison de métriques en classification de profils d 'expression de gènes.

In *Conférence d'Apprentissage automatique*, pages 135–150. Edition Publibook., 2011.

A. Douzal-Chouakria.
Réduction de la dimension de séries temporelles multidimensionnelles par extraction des tendances locales.
In *Extraction et Gestion des Connaissances, Atelier Fouille de données temporelles*, Lille, 2006.

A. Douzal-Chouakria.
Contributions à l'analyse de données temporelles.
PhD thesis, Université Joseph Fourier - Grenoble 1, Novembre 2012.

A. Douzal-Chouakria and C. Amblard.
Classification trees for time series.
Pattern Recognition, 45(3):1076–1091, 2012.

A. Douzal-Chouakria, L. Billard, and E. Diday.
Principal component analysis for interval-valued observations.
Statistical Analysis and Data Mining. Wiley, 4(2):229–246, 2011.

A. Douzal-Chouakria, A. Diallo, and F. Giroud.
Adaptive dissimilarity index for genes expression profiles classification.
In *Integrative Post Genomics Conference*, Lyon, 2006.

A. Douzal-Chouakria, A. Diallo, and F. Giroud.
Adaptive clustering for time series.
In *Statistics for Data Mining, Learning and Knowledge Extraction*, 2007.

A. Douzal-Chouakria, A. Diallo, and F. Giroud.
Adaptive clustering for time series: application for identifying cell cycle expressed genes.
In *IASC'07, International Association for Statistical Computing, Statistics for Data Mining, Learning and Knowledge Extraction*, Aveiro, Portugal, 2007.

A. Douzal-Chouakria, A. Diallo, and F. Giroud.
Adaptive dissimilarity index for Gene Expression Profiles Classification, volume 13, pages 483–494.
Brito, P. and Bertrand, P. and Cucumel, G. and De Carvalho, F., 2007.

A. Douzal-Chouakria, A. Diallo, and F. Giroud.
Adaptive clustering for time series: application for identifying cell cycle expressed genes.
Computational Statistics and Data Analysis, 53(4):1414–1426, 2009.

A. Douzal-Chouakria, A. Diallo, and F. Giroud.
A random-periods model for the comparison of a metrics efficiency to classify cell-cycle expressed genes.
Pattern Recognition Letters, 31:1601–1617, 2010.

A. Douzal-Chouakria, N. Hammami, and C. Garbay.
Local factorial analysis of time series.
In *56th Session of the International Statistical Institute*, 2007.

A. Douzal-Chouakria and P.N. Nagabhushan.
Adaptive dissimilarity index for measuring time series proximity.
Advances in Data Analysis and Classification Journal., 1(1):5–21, 2007.

C. Frambourg, A. Douzal-Chouakria, and J. Demongeot.

Moran and geary indices for multivariate time series exploratory analysis.
In *Société Francophone de Classification*, pages 177–180, Grenoble, 2009.

C. Frambourg, A. Douzal-Chouakria, and E. Gaussier.
Learning temporal matchings for time series discrimination.
Soumission à Machine Learning, 2012.

C. Frambourg, A. Douzal-Chouakria, and E. Gaussier.
Learning multiple temporal matching for time series classification.
In Arno Siebes Stephen Swift Allan Tucker, Frank Höppner, editor, *Advances in Intelligent Data Analysis XII*, number 198-200, page 12. Springer, 2013.

C. Frambourg, A. Douzal-Chouakria, and E. Gaussier.
New temporal matching strategies for time series discrimination.
In *European Conference on Data Analysis*, Luxembourg, 2013.

C. Frambourg, A. Douzal-Chouakria, E. Gaussier, and J. Demongeot.

Apprentissage de couplages pour la discrimination de séries temporelles.
In *Conférence d'Apprentissage automatique*, pages 151–166. Edition Publibook, 2011.

C. Frambourg, A. Douzal-Chouakria, Eric Gaussier, and Jacques Demongeot.
Learning time series dissimilarities.
In *Joint Conference of the German Classification Society (GfKl'11)*, Frankfurt, 2011.

F. Giroud, A. Diallo, and A. Douzal-Chouakria.
Identification of cell cycle expressed genes: a new approach for molecular dynamic network analysis.
In *Workshop Towards Systems Biology*, Grenoble, 2007.

F. Giroud, A. Diallo, and A. Douzal-Chouakria.
A new approach for molecular dynamic network analysis.
In *Réaumur Meeting*, Grenoble, 2007.

F. Kawala, E. Gaussier, A. Douzal-Chouakria, and Diemert E.

Prédire l'amplitude des « buzz » dans les médias sociaux.
In *Modèles et l'Analyse des Réseaux : Approches Mathématiques et Informatiques MARAMI'2013*, page 12, (2013).

R.P. Kumar, P. Nagabhushan, and A. Chouakria-Douzal.
Wavesim and adaptive wavesim transform for subsequence time-series clustering.
In *9th IEEE International Conference on Information Technology*, pages 197 –202, dec. 2006.

B. Leroy, A. Chouakria, I. Herlin, and E. Diday.
Approche géométrique et classification pour la reconnaissance de visage.
In *Reconnaissance des Formes et Intelligence Artificielle (RFIA'96)*, pages 548–557, Rennes, 1996.

G. Rizk, A. Douzal-Chouakria, and C. Amblard.
Temporal decision trees.
In *56th Session of the International Statistical Institute*, Lisboa, Portugal, 2007.

Adaptive split test for multivariate time series classification trees.
Douzal-chouakria, a. and amblard, c.
In *Conférence Francophone sur l'Apprentissage Automatique*, 2012.