

Segmentation/Classification de processus.

Application à l'analyse des données de microarrays CGH.

Franck PICARD

UMR INAPG/ENGREF/INRA MIA 518

Sous la direction de J-J. Daudin

16 Novembre 2005

Organisation de la présentation

1. Présentation du contexte biologique.
2. Application des méthodes de segmentation aux données CGH.
3. Développement d'un nouveau modèle de segmentation/classification.
4. Comparaison avec d'autres méthodes.
5. Perspectives.

Organisation de la présentation

1. **Présentation du contexte biologique :**

- délétion/amplification de séquences d'ADN et microarrays CGH,
- domaines d'applications,
- nature du signal étudié,
- interprétation d'un profil CGH.

2. Application des méthodes de segmentation aux données CGH.

3. Développement d'un nouveau modèle de segmentation/classification.

4. Comparaison avec d'autres méthodes.

5. Perspectives.

Présentation de la technologie des microarrays CGH

► Réarrangements chromosomiques de grande taille et pathologies humaines :

→ outil d'étude : **caryotype**,


→ résolution ~ chromosome ~ 100Mb.

► Délétion/amplification de séquences d'ADN :


→ CGH : Comparative Genomic Hybridization,

→ **microarrays CGH** : 1997,

→ dernière génération de puces : résolution ~ 100kb.



Présentation simplifiée des données de microarrays CGH



Applications des CGH en génétique humaine

► **Génétique des cancers :**

- recherche de régions *hotspots* sur le génome associées aux cancers,
- portraits moléculaires des tumeurs.

► Nouvelles perspectives pour l'étude du **polymorphisme humain** :


- variations du nombre de copies de séquences d'ADN de grande taille,
- comparaison de génomes humains/primates.

⇒ Besoin de nouveaux outils statistiques.

Nature du signal étudié

- ▶ Le phénomène biologique étudié est discret :
 - **comptage** de copies de séquences d'ADN.
- ▶ Le nombre de copies possible est inconnu.
- ▶ Différentes sources de variabilité :
 - variabilité **technique** (ex : saturation),
 - variabilité **biologique** (ex : hétérogénéité des tissus).
- ▶ Le nombre de copies est quantifié par fluorescence :
 - le signal étudié est **continu**.


Interprétation d'un profil CGH



Un point sur le graphique représente

$$\log_2 \left\{ \frac{\text{signal à la position } t \text{ dans le génome test}}{\text{signal à la position } t \text{ dans le génome référence}} \right\}$$

Interprétation d'un profil CGH



Une succession de **"segments"** :

zones du génome où le signal est homogène en moyenne.

Organisation de la présentation

1. Présentation du contexte biologique.
2. **Application des méthodes de segmentation aux données CGH :**
 - présentation des modèles de segmentation,
 - estimation des paramètres et sélection de modèle,
 - applications aux CGH.
3. Développement d'un nouveau modèle de segmentation/classification.
4. Comparaison avec d'autres méthodes.
5. Perspectives.

Détection de ruptures dans un signal gaussien

- $Y = \{Y_1, \dots, Y_n\}$ un processus gaussien, Y_t indépendantes.
- On suppose que les paramètres de la loi des Y sont affectés par $K - 1$ changements abrupts à des instants inconnus $T = \{t_1, \dots, t_{K-1}\}$.

- Ces instants de ruptures définissent une partition des données en K segments :

$$I_k = \{t, t \in]t_{k-1}, t_k]\}, \quad Y^k = \{Y_t, t \in I_k\}.$$

- On suppose que les paramètres sont constants entre deux ruptures :

$$\forall t \in I_k, \quad \mathbb{E}(Y_t) = \mu_k, \quad \mathbb{V}(Y_t) = \sigma_k^2.$$

- Les paramètres de ce modèle sont :

$$\rightarrow T = \{t_1, \dots, t_{K-1}\},$$

$$\rightarrow \Theta = (\theta_1, \dots, \theta_K), \quad \theta_k = (\mu_k, \sigma_k^2).$$

Estimation des paramètres et sélection de modèle

- ▶ Log-vraisemblance du modèle :

$$\log \mathcal{L}_K(T, \Theta) = \sum_{k=1}^K \log f(y^k; \theta_k) = \sum_{k=1}^K \sum_{t \in I_k} \log f(y_t; \theta_k).$$

- ▶ Estimation des paramètres à K fixé par maximum de vraisemblance :

→ optimisation par programmation dynamique (complexité algorithmique $\mathcal{O}(n^2)$),

→ optimum global.

- ▶ Sélection de modèle : choix de K .


→ Vraisemblance pénalisée : $\hat{K} = \underset{K \geq 1}{\operatorname{Argmax}} \left(\log \hat{\mathcal{L}}_K - \beta \times \operatorname{pen}(K) \right)$.

→ **Objectif** : établir un compromis entre bon ajustement du modèle aux données et un nombre raisonnable de paramètres à estimer.


Application des méthodes de segmentation aux données de microarrays CGH

- Quels sont les paramètres du modèle affectés par des changements abrupts ?

→ Modélisation de la variance.



Variances hétérogènes




Variance homogène

Application des méthodes de segmentation aux données de microarrays CGH

► Quelle méthode pour sélectionner le nombre de segments ?

→ Méthode adaptative proposée par Lavielle (2005).



Application des méthodes de segmentation aux données de microarrays CGH

- ▶ Quels sont les paramètres du modèle affectés par des changements abrupts ?

→ Moyenne à variance constante.

- ▶ Quel algorithme d'optimisation de la vraisemblance ?

→ Programmation dynamique (optimum global).

- ▶ Quelle méthode pour sélectionner le nombre de segments ?

→ Méthode adaptative proposée par Lavielle (2005).


⇒ Publication dans BMC Bioinformatics (Fev 2005)

⇒ Citation dans Lai et. al (2005)

Organisation de la présentation


1. Présentation du contexte biologique.
2. Application des méthodes de segmentation aux données CGH.
3. **Développement d'un nouveau modèle de segmentation/classification :**
 - présentation du modèle,
 - construction d'un algorithme d'estimation,
 - construction d'une heuristique de sélection de modèle.
4. Comparaison avec d'autres méthodes.
5. Perspectives.

Attentes des biologistes et nécessité d'un nouveau modèle



Segmentation: structure spatiale du signal

$$\theta_k = (\mu_k, \sigma_k^2)$$



Segmentation/Classification

$$\theta_p = (m_p, s_p^2)$$

Modèle de segmentation/classification

- On suppose qu'il existe une **deuxième structure sous-jacente** des segments en P populations de poids π_1, \dots, π_P .
- On introduit des variables cachées, Z_p^k indicatrices de la population d'appartenance **du segment k** .

- Ces variables sont supposées indépendantes de loi multinomiale :

$$(Z_1^k, \dots, Z_P^k) \sim \mathcal{M}(1; \pi_1, \dots, \pi_P).$$

- Conditionnellement aux variables cachées, on connaît la loi des Y :

$$Y^k | Z_p^k = 1 \sim \mathcal{N}_{n_k}(\mathbb{1}_{n_k} m_p, s_p^2 I_{n_k}).$$

- Les paramètres de ce modèle sont :

$$\rightarrow T = \{t_1, \dots, t_{K-1}\},$$

$$\rightarrow \Theta = \{\pi_1, \dots, \pi_P; \theta_1, \dots, \theta_P\}, \text{ avec } \theta_p = (m_p, s_p^2).$$

Définition des unités statistiques du modèle

- On observe n données $\{Y_t\}$ structurées en K segments.
- Les K segments sont structurés en P groupes :
 - les unités statistiques du modèle de mélange sont des segments de différentes tailles,
 - les unités statistiques du mélange changent avec les paramètres de segmentation et le nombre de segments.
- Les données complètes de ce modèle s'écrivent :

$$X^k = (Y_{t_{k-1}+1}, \dots, Y_{t_k}, Z^k).$$

Algorithme hybride d'optimisation de la vraisemblance

► Estimation alternée des paramètres à K et P fixés

1. À T fixé, l'algorithme **EM** optimise la vraisemblance en Θ :

$$\hat{\Theta}^{(\ell+1)} = \underset{\Theta}{\operatorname{Argmax}} \left\{ \log \mathcal{L}_{KP} \left(\Theta, T^{(\ell)} \right) \right\} .$$

2. À Θ fixé, la **programmation dynamique** optimise la vraisemblance en T :

$$\hat{T}^{(\ell+1)} = \underset{T}{\operatorname{Argmax}} \left\{ \log \mathcal{L}_{KP} \left(\hat{\Theta}^{(\ell+1)}, T \right) \right\} .$$

► Une suite croissante de vraisemblances :


$$\log \mathcal{L}_{KP}(\hat{\Theta}^{(\ell+1)}; \hat{T}^{(\ell+1)}) \geq \log \mathcal{L}_{KP}(\hat{\Theta}^{(\ell)}; \hat{T}^{(\ell)}) .$$

Initialisation de l'algorithme

- ▶ Algorithme itératif : nécessité d'une double initialisation :
 - $\Theta^{(0)}$ les paramètres du mélange,
 - $T^{(0)}$ les coordonnées des ruptures.
- ▶ Proposition d'une méthode hiérarchique pour initialiser EM.
- ▶ Étude de sensibilité à l'étape d'initialisation :
 - l'algorithme est sensible à la méthode d'initialisation,
 - il n'existe pas de meilleure méthode (multicritères),
 - choix de la méthode hiérarchique.
- ▶ Proposition d'une méthode pour éviter les maxima locaux.

Sélection de modèle

- ▶ Nouveau problème :
 - choix simultané de P et K .
- ▶ Méthode :
 - vraisemblance pénalisée.
- ▶ Paramètres de différentes natures :
 - Θ paramètres continus,
 - T paramètres discrets.



⇒ Les méthodes classiques de pénalisation ne peuvent pas être appliquées dans ce cadre.

Propriété du modèle

► Modèles emboîtés :

$$\begin{cases} \mathcal{M}(K, P) \not\subset \mathcal{M}(K + 1, P), \\ \mathcal{M}(K, P) \subset \mathcal{M}(K, P + 1). \end{cases}$$

► Propriété du modèle : $\mathcal{M}(P) = \bigcup_{K \geq 1} \mathcal{M}(K, P)$,

$$\mathcal{M}(P) \subset \mathcal{M}(P + 1).$$

⇒ Choisir P dans un premier temps et choisir K ensuite.

Méthode heuristique de sélection de modèle

1. Construction d'une suite croissante de vraisemblances :

$$\log \tilde{\mathcal{L}}_1 \dots \leq \log \tilde{\mathcal{L}}_P \leq \dots \leq \log \tilde{\mathcal{L}}_{P_{max}},$$

$$\log \tilde{\mathcal{L}}_P = \max_K \left\{ \log \mathcal{L}_{KP}(\hat{T}; \hat{\psi}) \right\}.$$


2. Choix du nombre de groupes :

$$\hat{P} = \operatorname{argmax}_P \left\{ \log \tilde{\mathcal{L}}_P - \beta \operatorname{pen}(P) \right\}.$$



3. Choix du nombre de segments :

$$\hat{K}_{\hat{P}} = \operatorname{argmax}_K \left\{ \log \mathcal{L}_{K\hat{P}}(\hat{T}; \hat{\psi}) - \frac{1}{2} \log(n) \times K \right\}.$$

Étude de performances par simulations



- Facteurs de variation :
 - taille des segments,
 - distance entre groupes.




Conclusion sur le modèle de segmentation/classification

- ▶ Présentation d'un nouveau modèle dans le cas gaussien généralisable à d'autres distributions :
 - étude du cas discret avec applications aux séquences d'ADN.
- ▶ Développement d'un algorithme hybride :
 - étude de sensibilité à l'étape d'initialisation,
 - méthode heuristique pour les maxima locaux.
- ▶ Proposition d'une heuristique de sélection de modèle :
 - méthode séquentielle,
 - analyse de performances par simulations.


Organisation de la présentation

1. Présentation du contexte biologique.
2. Application des méthodes de segmentation aux données CGH.
3. Développement d'un nouveau modèle de segmentation/classification.
4. **Comparaison avec d'autres méthodes :**
 - segmentation,
 - Chaînes de Markov cachées (HMM).
5. Perspectives.

Segmentation vs segmentation/classification



Segmentation



Segmentation/classification

Comparaison avec les Chaînes de Markov cachées (HMM)

► Modèle à structure cachée :

→ on suppose qu'il existe une séquence de variables cachées $\{Z_t\}$ telle que

$$Y_t | Z_t = p \sim \mathcal{N}(m_p, s_p^2).$$

→ Dépendance spatiale des $\{Z_t\}$ modélisée à l'aide d'une chaîne de Markov :

$$\Pr\{Z_t = \ell | Z_{t-1} = p\} = \phi(p, \ell).$$


→ Les HMMs modélisent implicitement la taille des "segments" (loi géométrique).

► Comparaison avec le modèle de segmentation/classification :


→ la structure spatiale est modélisée grâce au modèle de segmentation,

→ les ruptures sont des paramètres qui sont estimés.

HMMs vs segmentation/classification



HMM



segmentation/classification

► **Analyse des données CGH :**

- prendre en compte l'ensemble des chromosomes dans la procédure de segmentation,
- analyser les profils CGH de plusieurs patients simultanément,
- segmentation sur données dépendantes (nouvelles génération de puces).

► **Méthodes de segmentation :**

- intervalles de confiance pour les paramètres des ruptures.

► **Segmentation/classification :**

- développer un critère théorique pour la sélection de modèle,
- approche bayésienne (modèles hiérarchiques).