

# Segmentation conjointe de données génomiques en cancérologie

Morgane Pierre-Jean  
Directeur de stage : Pierre Neuvial

Laboratoire Statistique et Génome

15 Novembre 2012

# Sommaire

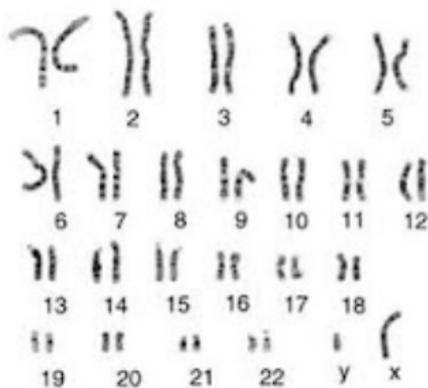
- 1 Contexte et objectifs
- 2 Gain attendu
- 3 Segmentation conjointe
  - Modélisation
  - Évaluation de la méthode
- 4 Conclusion

# Sommaire

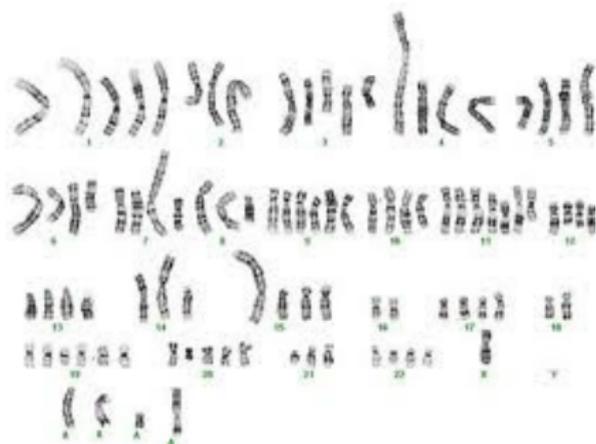
- 1 Contexte et objectifs
- 2 Gain attendu
- 3 Segmentation conjointe
- 4 Conclusion

- Les cellules ont normalement deux copies d'ADN
- Cellules cancéreuses : gains et pertes de fragments d'ADN

- Les cellules ont normalement deux copies d'ADN
- Cellules cancéreuses : gains et pertes de fragments d'ADN



Normal



Tumeur

Caractéristiques de données issues des puces de génotypage ou puces SNP :

- Leur grande dimension
- Leur forte structuration

On peut décrire les signaux obtenus par un couple de vecteurs:

$$(\mathbf{c}, \mathbf{b}) = (c_j, b_j)_{j \in \mathcal{J}}$$

où

- $c_j$  est le nombre de copies total en  $j$
- $b_j$  la proportion d'allèle B en  $j$

## Proportion d'allèle B

Pour SNP  $j$  de la puce à ADN :

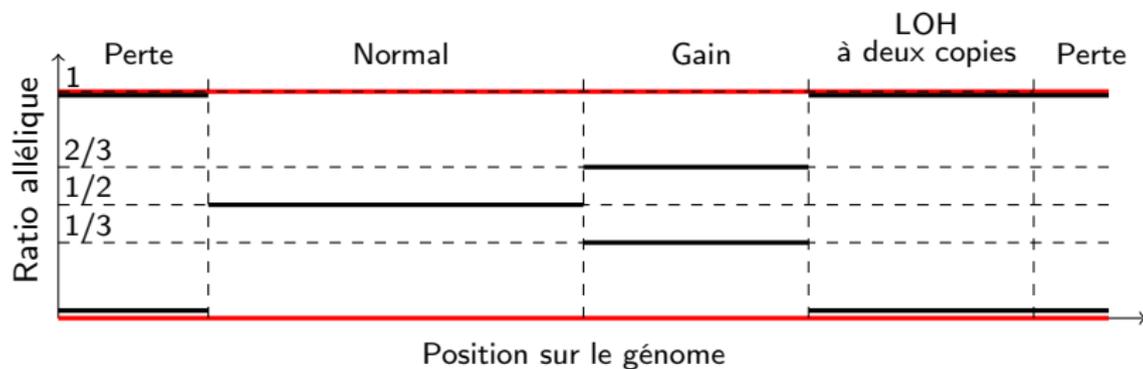
Allèle A : AACG**T**ATCG

Allèle B : AACG**A**ATCG

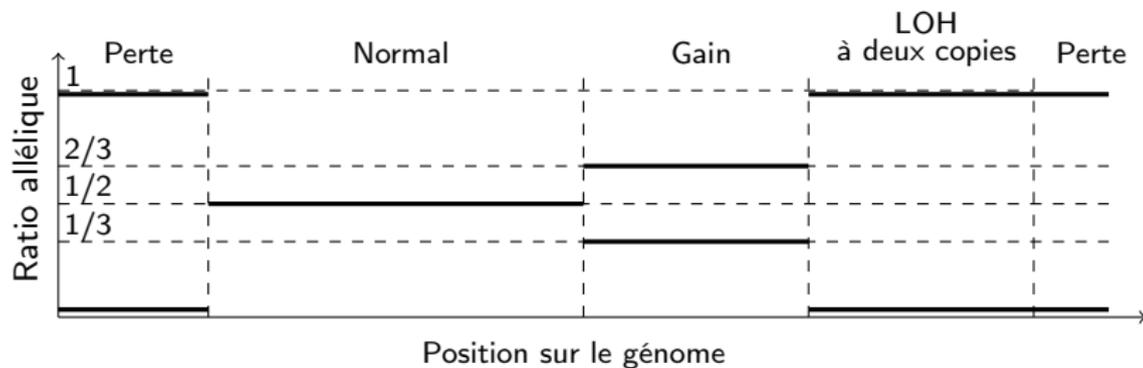
Dans une cellule normale, on a en général deux copies d'ADN si on observe :

- à la fois A et B  $\longrightarrow$  la proportion d'allèle B est égale à  $1/2$
- uniquement A  $\longrightarrow$  la proportion d'allèle B est égale à  $0/2$
- uniquement B  $\longrightarrow$  la proportion d'allèle B est égale à  $2/2$

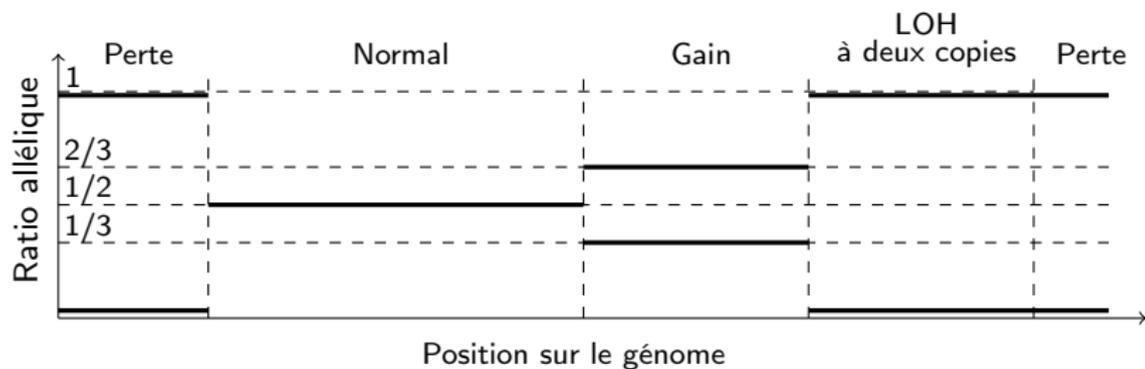
# proportion d'allèle B



# proportion d'allèle B

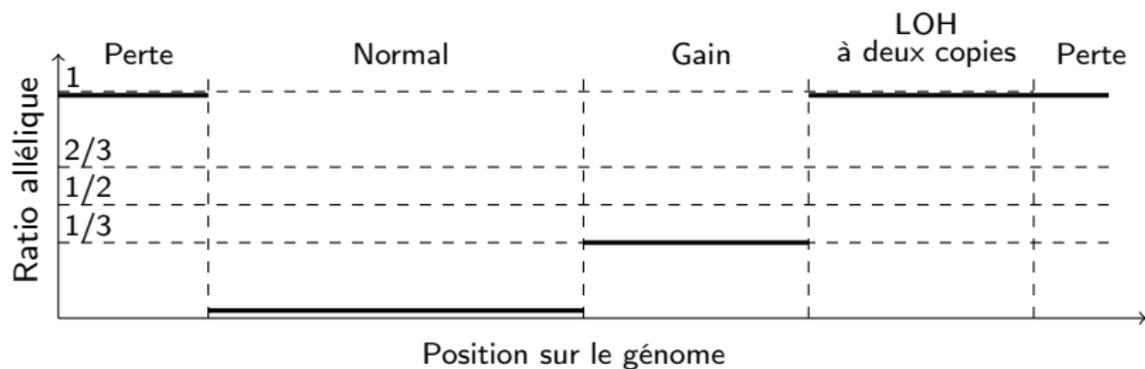


## proportion d'allèle B

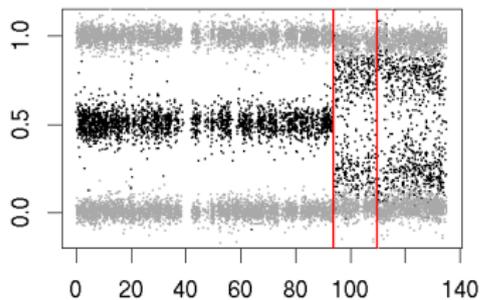
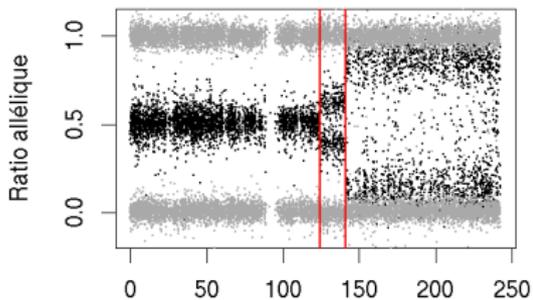
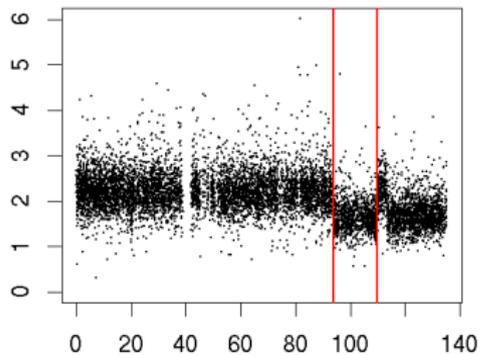
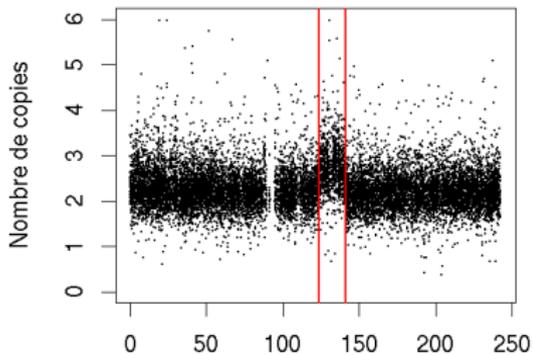


$$2 \times |b_j - 1/2|$$

## proportion d'allèle B



$$2 \times |b_j - 1/2|$$



position sur le chromosome 2 en mégabase

position sur le chromosome 10 en mégabase

Objectif : Caractériser les régions génomiques altérées

Objectif : Caractériser les régions génomiques altérées

Problèmes sur le plan statistique:

- l'identification des points de rupture
- l'étiquetage des régions en termes de gains, de pertes ou d'amplification

Objectif : Caractériser les régions génomiques altérées

Problèmes sur le plan statistique:

- l'identification des points de rupture
- l'étiquetage des régions en termes de gains, de pertes ou d'amplification

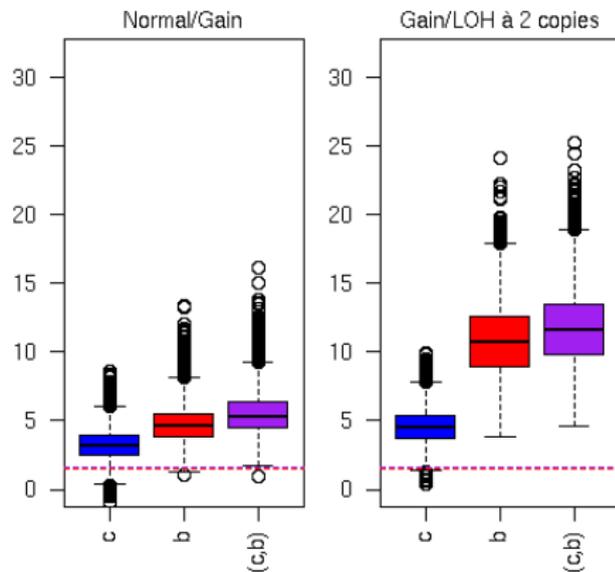
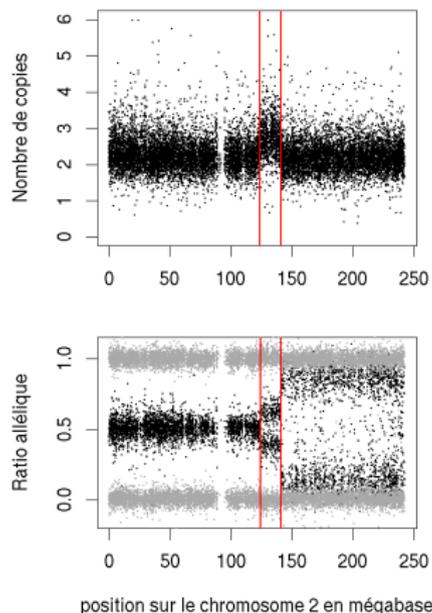
But du stage : mettre en place une méthode de segmentation conjointe des deux dimensions du signal et l'évaluer

# Sommaire

- 1 Contexte et objectifs
- 2 Gain attendu**
- 3 Segmentation conjointe
- 4 Conclusion

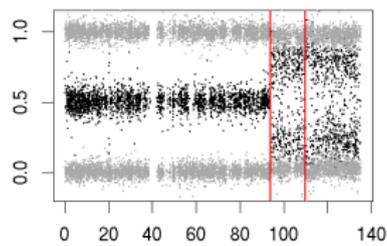
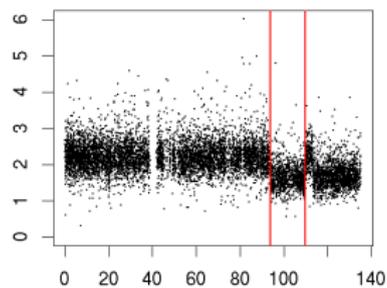
## Distance entre les états du chromosome 2

Normal/Gain et Gain/LOH à deux copies

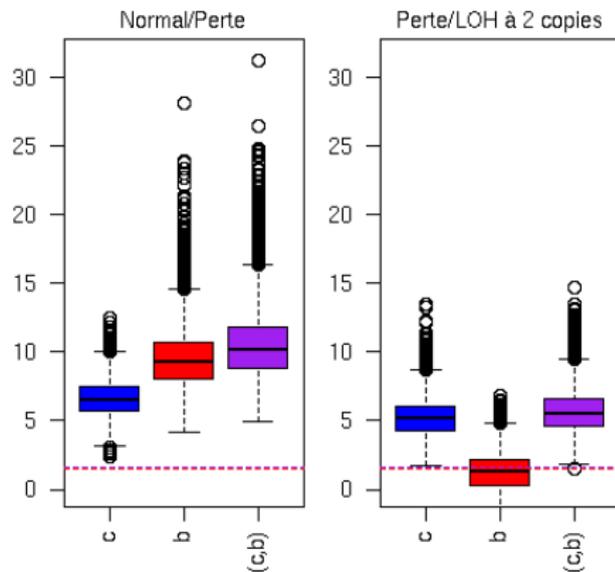


# Distance entre les états du chromosome 10

Normal/Perte et Perte/LOH à deux copies



position sur le chromosome 10 en mégabase



## Bilan

- Selon les ruptures ce n'est pas toujours la même statistique qui est la meilleure
- La statistique conjointe permet de faire au moins aussi bien que la meilleure univariée.
- Il devient intéressant d'utiliser les deux dimensions

# Sommaire

- 1 Contexte et objectifs
- 2 Gain attendu
- 3 Segmentation conjointe**
  - Modélisation
  - Évaluation de la méthode
- 4 Conclusion

## Modélisation du problème

Point de vue statistique : problème de détection de ruptures dans un signal bivarié

- Modélisation naturelle:

$$c_j = \gamma_j + \epsilon_j$$

où  $\forall k \in \{1, K\}, \forall j \in [t_{k-1}, t_k[ \quad \gamma_j = \Gamma_k$

# Modélisation du problème

Point de vue statistique : problème de détection de ruptures dans un signal bivarié

- Modélisation naturelle:

$$c_j = \gamma_j + \epsilon_j$$

où  $\forall k \in \{1, K\}, \forall j \in [t_{k-1}, t_k[ \quad \gamma_j = \Gamma_k$

- Complexité:

À  $K$  fixé, le nombre de positionnements possibles est

$$C_{n-1}^{K-1} = \mathcal{O}(n^{K-1})$$

⇒ **problème combinatoire**

## Méthodes existantes

### Méthodes exactes par programmation dynamique

[Picard et al. (2005)] : complexité en  $\mathcal{O}(Kn^2)$

- Extensible en 2d mais pour des problèmes moins importants

[Rigaill et al.(2010)] : complexité en  $\mathcal{O}(n \log(n))$  en moyenne

- Pire des cas  $\mathcal{O}(Kn^2)$
- Rapide mais non extensible en 2d

## Méthodes existantes

### Méthodes exactes par programmation dynamique

[Picard et al. (2005)] : complexité en  $\mathcal{O}(Kn^2)$

- Extensible en 2d mais pour des problèmes moins importants

[Rigaill et al.(2010)] : complexité en  $\mathcal{O}(n \log(n))$  en moyenne

- Pire des cas  $\mathcal{O}(Kn^2)$
- Rapide mais non extensible en 2d

### Méthodes approchées par relaxation convexe

[Harchaoui and Lévy-Leduc(2008)] : Complexité en  $\mathcal{O}(Kn)$

- Extensible en 2d

[Bleakley and Vert(2011)] : Complexité en  $\mathcal{O}(Kn)$

- Méthodes existantes pour segmenter les signaux bivariés sont sous optimales car elles traitent les deux dimensions:
  - soit indépendamment l'une de l'autre [Rigaill et al.(2010)]
  - soit conditionnellement l'une à l'autre [Olshen et al.(2011)]

- Méthodes existantes pour segmenter les signaux bivariés sont sous optimales car elles traitent les deux dimensions:
  - soit indépendamment l'une de l'autre [Rigaill et al.(2010)]
  - soit conditionnellement l'une à l'autre [Olshen et al.(2011)]
- Difficultés majeures:
  - point de vue algorithmique
  - concilier rigueur statistique, pertinence biologique et temps de calcul

# Modélisation

La méthode de segmentation conjointe développée est basée sur:

- une méthode de relaxation convexe
- une méthode développée pour segmenter plusieurs profils de patients [Vert and Bleakley (2010)]
- le fait que la localisation des points de rupture est la même dans les deux dimensions

- $\mathbf{Y} = (\mathbf{c} \quad \mathbf{b})$  : le nombre de copies d'ADN et le ratio allélique observés.
- $\Gamma = (\Gamma^1 \quad \Gamma^2)$  : le vrai nombre de copies et le vrai ratio allélique
- Objectif :

$$\min_{\Gamma \in \mathbb{R}^{n \times 2}} \|\mathbf{Y} - \Gamma\|_2^2 \text{ sous contrainte } K \text{ ruptures dans le signal}$$

- $\mathbf{Y} = (\mathbf{c} \quad \mathbf{b})$  : le nombre de copies d'ADN et le ratio allélique observés.
- $\Gamma = (\Gamma^1 \quad \Gamma^2)$  : le vrai nombre de copies et le vrai ratio allélique
- Objectif :

$$\min_{\Gamma \in \mathbb{R}^{n \times 2}} \|\mathbf{Y} - \Gamma\|_2^2 \text{ sous contrainte } K \text{ ruptures dans le signal}$$

- Problème de relaxation convexe :

$$\min_{\Gamma \in \mathbb{R}^{n \times 2}} \|\mathbf{Y} - \Gamma\|_2^2 \text{ sous contrainte } \sum_{j=1}^{n-1} \|\Gamma_{j+1} - \Gamma_j\|_2$$

- $\mathbf{Y} = (\mathbf{c} \quad \mathbf{b})$  : le nombre de copies d'ADN et le ratio allélique observés.
- $\Gamma = (\Gamma^1 \quad \Gamma^2)$  : le vrai nombre de copies et le vrai ratio allélique
- Objectif :

$$\min_{\Gamma \in \mathbb{R}^{n \times 2}} \|\mathbf{Y} - \Gamma\|_2^2 \text{ sous contrainte } K \text{ ruptures dans le signal}$$

- Problème de relaxation convexe :

$$\min_{\Gamma \in \mathbb{R}^{n \times 2}} \|\mathbf{Y} - \Gamma\|_2^2 + \lambda \sum_{j=1}^{n-1} \|\Gamma_{j+1} - \Gamma_j\|_2$$

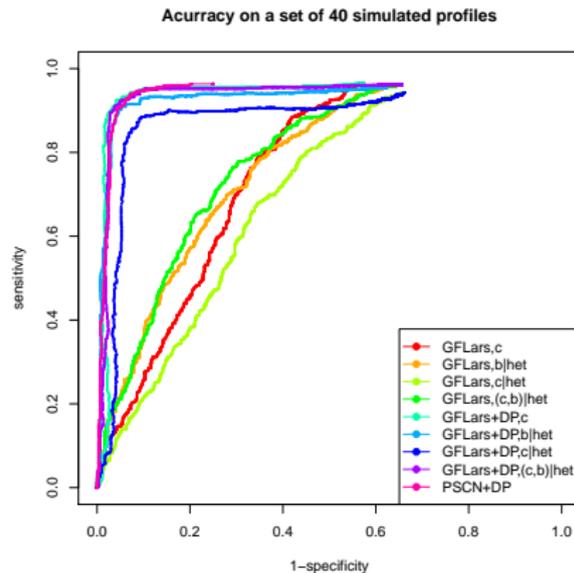
# Sélection des meilleures ruptures par programmation dynamique

- Utilisation d'une méthode **rapide** mais **approchée** pour trouver des ruptures candidates  $\implies$  Méthode Group Lasso
- Utilisation d'une méthode **exacte** mais **lente** pour sélectionner les meilleures ruptures  $\implies$  Programmation dynamique

## Résultats de la segmentation conjointe : simulations

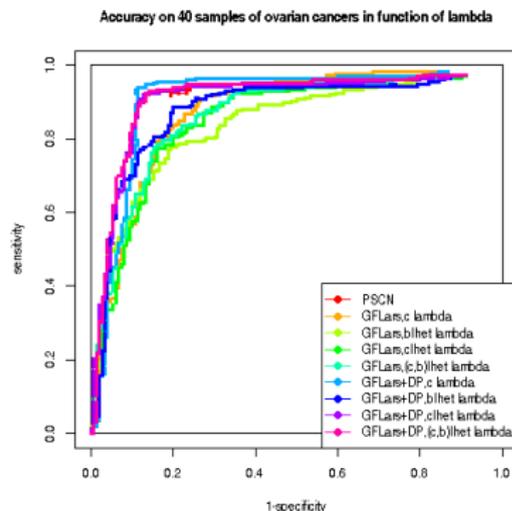
On a simulé 40 profils, et pour un profil

- On simule deux signaux de longueur 20000 à partir de données réelles
- On place 15 ruptures aléatoirement dans le signal
- On simule un état aléatoirement entre deux sauts



# Résultats de la segmentation conjointe : données de cancer de l'ovaire

- On dispose de 40 échantillons tumoraux provenant de 40 patientes différentes
- On réalise les segmentations sur chaque profil indépendamment les uns des autres



# Sommaire

- 1 Contexte et objectifs
- 2 Gain attendu
- 3 Segmentation conjointe
- 4 Conclusion

# Conclusion

## Résultats obtenus

- Modèle pour la segmentation conjointe du nombre de copies d'ADN et le ratio allélique
- Évaluation de l'efficacité de la méthode sur des simulations et des données réelles, comparaison du modèle avec des méthodes existantes
- Implémentation logicielle (développement d'un package R) rapide
- Utilité de la programmation dynamique mise en évidence

## Perspectives

- Amélioration de la méthode
- Segmenter plusieurs chromosomes et aussi plusieurs profils de patients
- Étiquetage des régions

Merci de votre attention



K. Bleakley and J.-P. Vert.

The group fused lasso for multiple change-point detection.  
Technical report, Mines ParisTech, 2011.



H. Bondell and B. Reich.

Simultaneous regression shrinkage, variable selection, and supervised clustering of predictors with OSCAR.  
*Biometrics*, 2008.



Z. Harchaoui and C. Lévy-Leduc.

Catching change-points with lasso.  
*Advances in Neural Information Processing Systems*, 2008.



P. Van Loo, S. H. Nordgard, O.C. Lingjaerd, I. H. Russnes, Hege Gand Rye, and V. N. Kristensen.

Allelic-specific copy number analysis of tumors.  
*Proceedings of the National Academy of Sciences of the United States of America*, 2010.



A. B. Olshen, H. Bengtsson, P. Neuvial, P.T. Spellman, R. A. Olshen, and V. E. Seshan.

Parent-specific copy number in paired tumor-normal studies using circular binary segmentation.  
*Bioinformatics*, 2011.



G. Rigaiil.

Pruned dynamic programming for optimal multiple change-point detection.  
Technical report, <http://arXiv.org/abs/1004.0887>, 2010.



G. Rigaiil, E. Lebarbier, and S. Robin.

Exact posterior distributions and model selection criteria for multiple change point-criteria.  
*Statistics and Computing*, 2012.



J.-P. Vert and K. Bleakley.

Fast detection of multiple change-points shared by many signals using group LARS.  
*Advances in Neural Information Processing Systems*, 2010.

## Tests utilisés

- Choisir une rupture, on prend deux échantillons (avant et après la rupture)
- Tester si les moyennes des deux échantillons sont égales

$$\mathcal{H}_0 : \mu_1 = \mu_2$$

## Tests utilisés

- Choisir une rupture, on prend deux échantillons (avant et après la rupture)
- Tester si les moyennes des deux échantillons sont égales

$$\mathcal{H}_0 : \mu_1 = \mu_2$$

- Statistiques univariées : Approximation de Welch
- Statistique bivariée : Test de Welch James

## Tests utilisés

- Choisir une rupture, on prend deux échantillons (avant et après la rupture)
- Tester si les moyennes des deux échantillons sont égales

$$\mathcal{H}_0 : \mu_1 = \mu_2$$

- Statistiques univariées : Approximation de Welch
- Statistique bivariée : Test de Welch James

$$T_v^2 = \mathbf{y}'\mathbf{S}^{-1}\mathbf{y},$$

où

$$\mathbf{S} = \mathbf{S}_1 + \mathbf{S}_2,$$

$$\mathbf{S}_i = \frac{\mathbf{S}_i^*}{n_i}, \quad i = 1, 2$$

et

$$\mathbf{y} = ((\bar{\mathbf{c}}_1 - \bar{\mathbf{c}}_2) \quad (\bar{\mathbf{b}}_1 - \bar{\mathbf{b}}_2)),$$

Distribution asymptotique de la statistique :  $T_v^2 \sim_{\mathcal{H}_0} \chi^2(2)$

- On obtient des  $p$ -valeurs pour chacun des 3 tests
- On transforme ces  $p$ -valeurs en Z-scores :  $z = \Phi^{-1}(p)$
- On réalise les étapes précédentes 5000 fois
- On obtient ensuite les distributions empiriques des Z-scores

# Modélisation

On veut donc optimiser :

$$\min_{\Gamma \in \mathbb{R}^{n \times 2}} \frac{1}{2} \|\mathbf{Y} - \Gamma\|_2^2 + \lambda \sum_{j=1}^{n-1} \frac{((\Gamma_{j+11} - \Gamma_{j1})^2 + (\Gamma_{j+12} - \Gamma_{j2})^2)^{\frac{1}{2}}}{d_j} \quad (1)$$

## Modélisation

On veut donc optimiser :

$$\min_{\Gamma \in \mathbb{R}^{n \times 2}} \frac{1}{2} \|\mathbf{Y} - \Gamma\|_2^2 + \lambda \sum_{j=1}^{n-1} \frac{((\Gamma_{j+1,1} - \Gamma_{j,1})^2 + (\Gamma_{j+1,2} - \Gamma_{j,2})^2)^{\frac{1}{2}}}{d_j} \quad (1)$$

Reformulation en régression group Lasso :

$$u = \Gamma_{1.} = (\Gamma_{1,1} \quad \Gamma_{1,2}) \in \mathbb{R}^{1 \times 2}$$

$$\beta_j = \frac{(\Gamma_{j+1.} - \Gamma_{j.})}{d_j} = \frac{((\Gamma_{j+1,1} - \Gamma_{j,1}) \quad (\Gamma_{j+1,2} - \Gamma_{j,2}))}{d_j}$$

$\beta_j$ . représente le saut entre la  $j$ -ème et la  $(j+1)$ -ème position.

$$\Gamma = \mathbf{1}_{n,1} u + \mathbf{X} \beta. \quad (2)$$

L'équation peut se réécrire de la façon suivante :

$$\min_{\beta \in \mathbb{R}^{(n-1) \times 2}} \frac{1}{2} \|\mathbf{Y} - \mathbf{X} \beta - \mathbf{1}_{n,1} u\|_2^2 + \lambda \sum_{j=1}^{n-1} (\beta_{j,1}^2 + \beta_{j,2}^2)^{\frac{1}{2}} \quad (3)$$

# Modélisation

On veut donc optimiser :

$$\min_{\Gamma \in \mathbb{R}^{n \times 2}} \frac{1}{2} \|\mathbf{Y} - \Gamma\|_2^2 + \lambda \sum_{j=1}^{n-1} \frac{((\Gamma_{j+1,1} - \Gamma_{j,1})^2 + (\Gamma_{j+1,2} - \Gamma_{j,2})^2)^{\frac{1}{2}}}{d_j} \quad (1)$$

Reformulation en régression group Lasso :

$$u = \Gamma_{1, \cdot} = (\Gamma_{1,1} \quad \Gamma_{1,2}) \in \mathbb{R}^{1 \times 2}$$

$$\beta_j = \frac{(\Gamma_{j+1, \cdot} - \Gamma_{j, \cdot})}{d_j} = \frac{((\Gamma_{j+1,1} - \Gamma_{j,1}) \quad (\Gamma_{j+1,2} - \Gamma_{j,2}))}{d_j}$$

$\beta_j$  représente le saut entre la  $j$ -ème et la  $(j+1)$ -ème position.

$$\Gamma = \mathbf{1}_{n,1} u + \mathbf{X} \beta. \quad (2)$$

L'équation peut se réécrire de la façon suivante :

$$\min_{\beta \in \mathbb{R}^{(n-1) \times 2}} \frac{1}{2} \|\bar{\mathbf{Y}} - \bar{\mathbf{X}} \beta\|_2^2 + \lambda \sum_{j=1}^{n-1} \|\beta_{j, \cdot}\|_2 \quad (3)$$

## Algorithme group LARS

### Initialisation

- $k = 1$
- $\beta^{[0]} = 0$
- $r^{[0]} = \mathbf{Y}$  est le résidu

On cherche la variable la plus corrélée avec  $\mathbf{Y}$

$$\mathcal{A}_1 = \arg \max_j \|\mathbf{X}'_j \mathbf{Y}\|_2^2$$

# Algorithme group LARS

Pour  $k$  allant de 1 à  $K$

A chaque étape  $k$

- On calcule la direction  $w$  qui est une matrice de dimension  $(n - 1) \times 2$  tel que :

$$w_{\mathcal{A}_k}^{\xi} = 0, \text{ et } w_{\mathcal{A}_k} = (X'_{\mathcal{A}_k} X_{\mathcal{A}_k})^{-1} X'_{\mathcal{A}_k} r^{[k-1]}$$

où  $X_{\mathcal{A}_k}$  est la matrice composée des colonnes de  $\mathbf{X}$  correspondant aux indices de  $\mathcal{A}_k$ .

# Algorithme group LARS

Pour  $k$  allant de 1 à  $K$

A chaque étape  $k$

- On calcule la direction  $w$  qui est une matrice de dimension  $(n-1) \times 2$  tel que :

$$w_{\mathcal{A}_k^c} = 0, \text{ et } w_{\mathcal{A}_k} = (X'_{\mathcal{A}_k} X_{\mathcal{A}_k})^{-1} X'_{\mathcal{A}_k} r^{[k-1]}$$

où  $X_{\mathcal{A}_k}$  est la matrice composée des colonnes de  $\mathbf{X}$  correspondant aux indices de  $\mathcal{A}_k$ .

- Pour chaque  $j$  qui n'est pas dans le groupes des indices actifs, on résout l'équation suivante pour  $\gamma_j \in [0, 1]$  tel que :

$$\|X'_j(r^{[k-1]} - \gamma_j \mathbf{X}w)\|_2^2 = \|X'_j(r^{[k-1]} - \gamma_j \mathbf{X}w)\|_2^2 \quad (4)$$

# Algorithme group LARS

Pour  $k$  allant de 1 à  $K$

A chaque étape  $k$

- On calcule la direction  $w$  qui est une matrice de dimension  $(n-1) \times 2$  tel que :

$$w_{\mathcal{A}_k^c} = 0, \text{ et } w_{\mathcal{A}_k} = (X'_{\mathcal{A}_k} X_{\mathcal{A}_k})^{-1} X'_{\mathcal{A}_k} r^{[k-1]}$$

où  $X_{\mathcal{A}_k}$  est la matrice composée des colonnes de  $\mathbf{X}$  correspondant aux indices de  $\mathcal{A}_k$ .

- Pour chaque  $j$  qui n'est pas dans le groupes des indices actifs, on résout l'équation suivante pour  $\gamma_j \in [0, 1]$  tel que :

$$\|X'_j(r^{[k-1]} - \gamma_j \mathbf{X}w)\|_2^2 = \|X'_j(r^{[k-1]} - \gamma_j \mathbf{X}w)\|_2^2 \quad (4)$$

- On pose ensuite  $\min_{j \notin \mathcal{A}_k} \gamma_j = \gamma_{j^*}$ , et on met à jour les indices actifs  $\mathcal{A}_{k+1} = \mathcal{A}_k \cup \{j^*\}$

# Algorithme group LARS

Pour  $k$  allant de 1 à  $K$

A chaque étape  $k$

- On calcule la direction  $w$  qui est une matrice de dimension  $(n-1) \times 2$  tel que :

$$w_{\mathcal{A}_k^c} = 0, \text{ et } w_{\mathcal{A}_k} = (X'_{\mathcal{A}_k} X_{\mathcal{A}_k})^{-1} X'_{\mathcal{A}_k} r^{[k-1]}$$

où  $X_{\mathcal{A}_k}$  est la matrice composée des colonnes de  $\mathbf{X}$  correspondant aux indices de  $\mathcal{A}_k$ .

- Pour chaque  $j$  qui n'est pas dans le groupes des indices actifs, on résout l'équation suivante pour  $\gamma_j \in [0, 1]$  tel que :

$$\|X'_j(r^{[k-1]} - \gamma_j \mathbf{X}w)\|_2^2 = \|X'_j(r^{[k-1]} - \gamma_j \mathbf{X}w)\|_2^2 \quad (4)$$

- On pose ensuite  $\min_{j \notin \mathcal{A}_k} \gamma_j = \gamma_{j^*}$ , et on met à jour les indices actifs  $\mathcal{A}_{k+1} = \mathcal{A}_k \cup \{j^*\}$
- On met également à jour  $\beta^{[k]} = \beta^{[k-1]} + \gamma_{j^*} w$  et  $r^{[k]} = \mathbf{Y} - \mathbf{X}\beta^{[k]}$