

# Calcul du Nombre de Breakpoints entre Génomes: Tour d'Horizon des Résultats Algorithmiques connus

Guillaume Fertin

LINA, UMR 6241, Université de Nantes

# Outline

1 **Comparaison de Génomes**

2 Nombre de Breakpoints

3 Gènes Dupliqués

4 Résultats existants

# Introduction Générale

## Que cherche-t-on à faire ?

- Comparaison de **paires** d'espèces
  - inférence de gènes fonctionnellement liés
  - construction d'arbres phylogéniques
- Pour cela :
  - on compare leurs génomes
  - une valeur est calculée, qui représente une forme de (dis)similarité entre les deux espèces

Le problème peut donc être formulé comme suit

Etant donné deux génomes  $G_1$  et  $G_2$ , et une mesure de (dis)similarité  $M$ , calculer la valeur  $M(G_1, G_2)$

# Introduction Générale

## Que cherche-t-on à faire ?

- Comparaison de **paires** d'espèces
  - inférence de gènes fonctionnellement liés
  - construction d'arbres phylogéniques
- Pour cela :
  - on compare leurs génomes
  - une valeur est calculée, qui représente une forme de (dis)similarité entre les deux espèces

## Le problème peut donc être formulé comme suit

Etant donné deux génomes  $G_1$  et  $G_2$ , et une mesure de (dis)similarité  $M$ , **calculer la valeur  $M(G_1, G_2)$**

# Modélisation du problème

## Génomes

- Génome: séquence ordonnée de gènes
- Gènes: portions d'ADN
- Les gènes seront représentés par des entiers signés
- Signe +/-  $\Rightarrow$  brin d'ADN sur lequel se situe le gène

## Exemple

$$G_1 = +1 + 3 - 4 + 5 + 2 - 6$$

$$G_2 = +1 + 2 - 5 - 3 + 6 - 4$$

# Hypothèses Simplificatrices

## Contenu en Gènes

- Les deux génomes comparés ont le même contenu en gènes
- Si un gène existe dans un seul des deux génomes, il sera supprimé de la séquence
- $\Rightarrow$  insertions/suppressions ne sont pas prises en compte dans ce modèle

# Outline

1 Comparaison de Génomes

**2 Nombre de Breakpoints**

3 Gènes Dupliqués

4 Résultats existants

# Comment comparer deux génomes ?

## Mesures de (Dis)Similarité

- Basées sur la *structure* des génomes
- On calcule une *mesure* qui représente la proximité (ou l'éloignement) de deux génomes
- Mesure étudiée dans cet exposé: **nombre de breakpoints**

# Breakpoints

## Definition

- Soit  $G_1$  et  $G_2$  deux génomes
- On suppose, wlog, que  $G_1 = +1 + 2 + 3 \dots + n$
- Alors il existe un **breakpoint** entre deux gènes  $i$  and  $i + 1$  de  $G_1$ , si dans  $G_2$  on n'a:
  - ni:  $+i + (i + 1)$
  - ni:  $-(i + 1) - i$
- $\Rightarrow$  breakpoint = adjacence entre deux gènes dans  $G_1$ , qui n'a **pas été conservée** dans  $G_2$

# Breakpoints

## Example

- Supposons  $G_1 = +1 + 2 + 3 + 4 + 5 + 6$
- Si  $G_2 = +1 + 2 - 5 - 4 + 3 + 6$
- Alors il existe 3 breakpoints entre  $G_1$  et  $G_2$
- $G_2 = +1 + 2 \bullet -5 - 4 \bullet +3 \bullet +6$

## Remarques

- Cette mesure est *symétrique*:  $B(G_1, G_2) = B(G_2, G_1)$  pour tous génomes  $G_1$  et  $G_2$
- Un breakpoint est l'extrémité d'un événement de réarrangement (inversion, transposition, etc.)
- Historiquement, une des premières mesures proposées/étudiées
- Si aucun gène n'est dupliqué, le calcul de  $B(G_1, G_2)$  est polynomial

# Breakpoints

## Exemple

- Supposons  $G_1 = +1 + 2 + 3 + 4 + 5 + 6$
- Si  $G_2 = +1 + 2 - 5 - 4 + 3 + 6$
- Alors il existe 3 breakpoints entre  $G_1$  et  $G_2$
- $G_2 = +1 + 2 \bullet -5 - 4 \bullet +3 \bullet +6$

## Remarques

- Cette mesure est *symétrique*:  $B(G_1, G_2) = B(G_2, G_1)$  pour tous génomes  $G_1$  et  $G_2$
- Un breakpoint est l'extrémité d'un événement de réarrangement (inversion, transposition, etc.)
- Historiquement, une des premières mesures proposées/étudiées
- Si aucun gène n'est dupliqué, le calcul de  $B(G_1, G_2)$  est polynomial

# Outline

1 Comparaison de Génomes

2 Nombre de Breakpoints

**3 Gènes Dupliqués**

4 Résultats existants

# Duplications

## Les duplications doivent être prises en compte

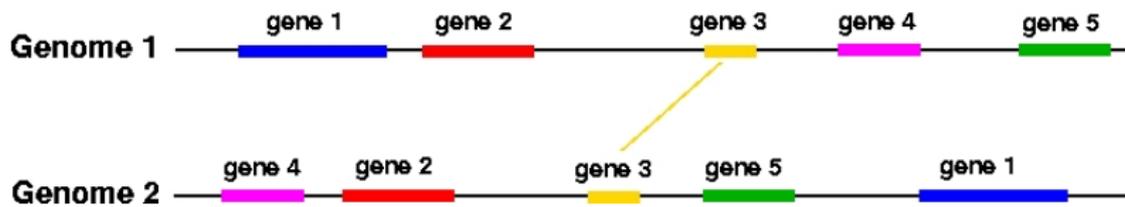
- Calculer  $B(G_1, G_2)$  est polynomial, quand ni  $G_1$  ni  $G_2$  ne contiennent de duplications
- On sait désormais que cette hypothèse est trop restrictive:
  - ~ 15% chez l'humain
  - ~ 16% chez la levure
  - ~ 25% chez Arabidopsis



- Mais comment gérer les duplications ?

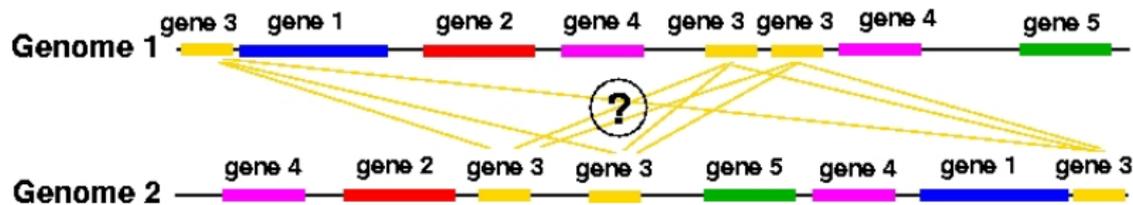
# Premier problème

Sans duplication, pas d'ambiguïté



# Premier problème

Avec duplications, comment faire ?



# Gérer les ambiguïtés

## On cherche à retrouver une *permutation*

- $\Rightarrow$  Etablir un **matching**  $\mathcal{M}$  entre gènes de  $G_1$  et gènes de  $G_2$ , pour chaque famille de gènes
- Possiblement, en supprimant des gènes
- Le but étant de revenir à une permutation  $\Rightarrow$  ambiguïtés inexistantes

## Deux possibilités

- Exemplarisation entre  $G_1$  et  $G_2$
- Matching Maximum entre  $G_1$  et  $G_2$

# Gérer les ambiguïtés

## On cherche à retrouver une *permutation*

- $\Rightarrow$  Etablir un **matching**  $\mathcal{M}$  entre gènes de  $G_1$  et gènes de  $G_2$ , pour chaque famille de gènes
- Possiblement, en supprimant des gènes
- Le but étant de revenir à une permutation  $\Rightarrow$  ambiguïtés inexistantes

## Deux possibilités

- **Exemplarisation** entre  $G_1$  et  $G_2$
- **Matching Maximum** entre  $G_1$  et  $G_2$

# Exemplarisation vs Matching Maximum

## Exemplarisation

Dans le matching  $\mathcal{M}$ , on garde **un seul** gène de chaque famille  
⇒ Gène ancestral

## Matching Maximum

Dans le matching  $\mathcal{M}$ , on garde **le maximum** de gènes de chaque famille  
⇒ On garde le maximum d'informations dans les génomes

# Exemplarisation vs Matching Maximum

## Exemplarisation

Dans le matching  $\mathcal{M}$ , on garde **un seul** gène de chaque famille  
⇒ Gène ancestral

## Matching Maximum

Dans le matching  $\mathcal{M}$ , on garde **le maximum** de gènes de chaque famille  
⇒ On garde le maximum d'informations dans les génomes

# Exemplarisation

## Exemple

$$G_1 = +1 + 2 + 3 - 2 + 5 + 4 + 4 - 3$$

$$G_2 = +3 - 1 + 2 + 1 + 5 - 3 + 2 + 4 + 3$$

## Une exemplarisation possible

$$G_1^E = +1 + 2 + 3 + 5 + 4$$

$$G_2^E = +1 + 5 - 3 + 2 + 4$$

⇒ L'exemplarisation est notée par le triplet  $(G_1^E, G_2^E, \mathcal{M})$

# Exemplarisation

## Exemple

$$G_1 = +1 + 2 + 3 - 2 + 5 + 4 + 4 - 3$$

$$G_2 = +3 - 1 + 2 + 1 + 5 - 3 + 2 + 4 - 3$$

## Une exemplarisation possible

$$G_1^E = +1 + 2 + 3 + 5 + 4$$

$$G_2^E = +1 + 5 - 3 + 2 + 4$$

⇒ L'exemplarisation est notée par le triplet  $(G_1^E, G_2^E, \mathcal{M})$

# Matching Maximum

## Example

$$G_1 = +1 +2 +3 -2 +5 +4 +4 -3$$

$$G_2 = +3 -1 +2 +1 +5 -3 +2 +4 +3$$

## Un matching maximum possible

$$G_1^M = +1 +2 +3 -2 +5 +4 -3$$

$$G_2^M = +3 -1 +2 +5 -3 +2 +4$$

⇒ Le matching maximum est noté par le triplet  $(G_1^M, G_2^M, \mathcal{M})$

# Matching Maximum

## Example

$$G_1 = +1 + 2 + 3 - 2 + 5 + 4 + 4 - 3$$

$$G_2 = +3 - 1 + 2 + 1 + 5 - 3 + 2 + 4 - 3$$

## Un matching maximum possible

$$G_1^M = +1 + 2 + 3 - 2 + 5 + 4 - 3$$

$$G_2^M = +3 - 1 + 2 + 5 - 3 + 2 + 4$$

⇒ Le matching maximum est noté par le triplet  $(G_1^M, G_2^M, \mathcal{M})$

# Question Subsidaire (pour les deux versions)

## Quel matching choisir ?

- Pour une instance  $(G_1, G_2)$  et un modèle de matching donnés, quel est le **meilleur** matching ?
- **Critère retenu**: on recherche le matching qui **minimise** le nombre de breakpoints
- Selon le principe de parcimonie

# Outline

1 Comparaison de Génomes

2 Nombre de Breakpoints

3 Gènes Dupliqués

4 Résultats existants

# Définitions

## Nommons les Problèmes

- EBD: **Exemplar Breakpoint Distance**
- MBD: **Maximum matching Breakpoint Distance**

## Remarques

- Le nom est trompeur: ce **ne sont pas** des distances au sens mathématique !
- Dénomination “historique”

# Définitions

## Terminologie

- $occ(G, g)$ : nombre d'occurrences du gène  $g$  dans le génome  $G$
- $occ(G)$ : maximum des  $occ(G, g)$  sur toutes les familles  $g$  de gènes
- Instance  $(G_1, G_2)$  de type  $(a, b)$ :  $occ(G_1) = a$  et  $occ(G_2) = b$
- Instance  $(G_1, G_2)$  équilibrée: pour tout gène  $g$ ,

$$occ(G_1, g) = occ(G_2, g)$$

# Définitions

## Exemple

$$G_1 = +1 + 2 + 3 - 2 + 5 + 4 + 4 - 3$$

$$G_2 = +3 - 1 + 2 + 1 + 5 - 3 + 2 + 4 + 3$$

- $occ(G_1, 3) = 2$
- $occ(G_2, 3) = 3$
- $(G_1, G_2)$  est une instance de type  $(2, 3)$
- $(G_1, G_2)$  n'est pas une instance équilibrée

## Remarque

- Si  $(G_1, G_2)$  est une instance équilibrée, alors c'est une instance de type  $(a, a)$
- ...mais l'inverse n'est pas vrai

# Définitions

## Exemple

$$G_1 = +1 + 2 + 3 - 2 + 5 + 4 + 4 - 3$$

$$G_2 = +3 - 1 + 2 + 1 + 5 - 3 + 2 + 4 + 3$$

- $occ(G_1, 3) = 2$
- $occ(G_2, 3) = 3$
- $(G_1, G_2)$  est une instance de type  $(2, 3)$
- $(G_1, G_2)$  n'est pas une instance équilibrée

## Remarque

- Si  $(G_1, G_2)$  est une instance équilibrée, alors c'est une instance de type  $(a, a)$
- ...mais l'inverse n'est pas vrai

# Complexité algorithmique du problème EBD

## Theorem (Bryant-2000)

EBD est NP-complet, même pour les instances de type (1,2)

## Theorem (Angibaud et al.-2007)

EBD is APX-dur, même pour les instances de type (1,2)

# Complexité algorithmique du problème EBD

## Theorem (Bryant-2000)

EBD est NP-complet, même pour les instances de type (1,2)

## Theorem (Angibaud et al.-2007)

EBD is APX-dur, même pour les instances de type (1,2)

# Peut-on quand même approcher EBD ?

## Theorem (Chen et al.-2006)

EBD ne peut pas être approché en-deçà d'un ratio **1.36**, même pour les instances de type **(2, 2)**.

## Remarque

Résultat déjà présent (implicitement) dans [Bryant-2000]

# Peut-on quand même approcher EBD ?

## Un nouveau problème: ZEBD

Soit **ZEBD** le problème suivant: existe-t-il une exemplarisation  $(G_1^E, G_2^E, \mathcal{M})$  de  $(G_1, G_2)$  telle que  $B(G_1^E, G_2^E) = 0$  ?

Theorem (Chen et al.-2006)

*ZEBD est NP-complet, même pour les instances de type  $(3, 3)$*

Theorem (Angibaud et al.-2008)

*ZEBD est NP-complet, même pour les instances de type  $(2, k)$ , où  $k$  est non borné*

# Peut-on quand même approcher EBD ?

## Un nouveau problème: ZEBD

Soit **ZEBD** le problème suivant: existe-t-il une exemplarisation  $(G_1^E, G_2^E, \mathcal{M})$  de  $(G_1, G_2)$  telle que  $B(G_1^E, G_2^E) = 0$  ?

## Theorem (Chen et al.-2006)

ZEBD est NP-complet, même pour les instances de type  $(3, 3)$

## Theorem (Angibaud et al.-2008)

ZEBD est NP-complet, même pour les instances de type  $(2, k)$ , où  $k$  est non borné

# Peut-on quand même approcher EBD ?

## Theorem (Chen et al.-2006, Angibaud et al.-2008)

EBD ne peut être approché en-deçà d'*aucun* ratio:

- même pour les instances de type  $(3, 3)$
- même pour les instances de type  $(2, k)$ , où  $k$  est non borné

# EBD: vous n'auriez pas du positif ?

## Heuristiques

- Branch and Bound [Sankoff-1999]
- Divide and Conquer + Branch and Bound [Thach Nguyen et al.-2005]
- **ELCS**: Algorithme glouton basé sur le LCS (Longest Common Subsequence) [Angibaud et al.-2007]

## ELCS: le principe

- 1 Trouver  $S$ , le LCS de  $G_1$  et  $G_2$  (à un renversement total - ordre et signe - près)
- 2 Exemplariser  $S$  arbitrairement: on obtient  $S'$
- 3 Matcher les gènes de  $S'$
- 4 Retirer du reste de  $G_1$  (resp.  $G_2$ ) les gènes de  $S'$
- 5 Itérer le processus jusqu'à avoir matché tous les gènes

# EBD: vous n'auriez pas du positif ?

## Heuristiques

- Branch and Bound [Sankoff-1999]
- Divide and Conquer + Branch and Bound [Thach Nguyen et al.-2005]
- **ELCS**: Algorithme glouton basé sur le LCS (Longest Common Subsequence) [Angibaud et al.-2007]

## ELCS: le principe

- 1 Trouver  $S$ , le LCS de  $G_1$  et  $G_2$  (à un renversement total - ordre et signe - près)
- 2 Exemplariser  $S$  arbitrairement: on obtient  $S'$
- 3 Matcher les gènes de  $S'$
- 4 Retirer du reste de  $G_1$  (resp.  $G_2$ ) les gènes de  $S'$
- 5 Itérer le processus jusqu'à avoir matché tous les gènes

# EBD: vous n'auriez pas du positif ?

## Résultats exacts obtenus par programmation linéaire en $(0, 1)$

- Approche utilisée dans [Angibaud et al.-2007]
- Transformer le problème EBD en un problème de type SAT + fonction objectif
- Utiliser un solveur SAT pour calculer la solution
- Ré-importer la solution dans notre problème
- Donne des résultats exacts... mais pas toujours:
  - **61** résultats obtenus
  - sur les 66 attendus dans notre jeu de données

# EBD: vous n'auriez pas du positif ?

## Heuristique ELCS vs Résultats exacts

- 12 génomes de  $\gamma$ -protéobactéries
- Génomes de taille  $\sim 500$  à  $\sim 5500$  gènes
- 66 comparaisons de génomes deux à deux
- 61 résultats exacts obtenus, et comparés à l'heuristique ELCS

Exemplarisation: Exact vs ELCS		
Pire Cas	Meilleur Cas	Moyenne (61 instances)
96.51%	100%	99.36%

# EBD: vous n'auriez pas du positif ?

## Heuristique ELCS vs Résultats exacts

- 12 génomes de  $\gamma$ -protéobactéries
- Génomes de taille  $\sim 500$  à  $\sim 5500$  gènes
- 66 comparaisons de génomes deux à deux
- 61 résultats exacts obtenus, et comparés à l'heuristique ELCS

Exemplarisation: Exact vs ELCS		
Pire Cas	Meilleur Cas	Moyenne (61 instances)
96.51%	100%	99.36%

# Complexité algorithmique du problème MBD

## Theorem (Bryant-2000, Angibaud et al.-2007)

- MBD est NP-complet, même pour les instances de type  $(1, 2)$
- MBD est APX-dur, même pour les instances de type  $(1, 2)$

## Proof.

Pour toute instance de type  $(1, b)$ ,

exemplarisation = maximum matching

⇒ Instances de type  $(1, b)$ : les résultats pour EBD sont valables pour MBD □

# Complexité algorithmique du problème MBD

## Theorem (Bryant-2000, Angibaud et al.-2007)

- MBD est NP-complet, même pour les instances de type  $(1, 2)$
- MBD est APX-dur, même pour les instances de type  $(1, 2)$

## Proof.

Pour toute instance de type  $(1, b)$ ,

exemplarisation = maximum matching

⇒ Instances de type  $(1, b)$ : les résultats pour EBD sont valables pour MBD □

# Peut-on quand même approcher MBD ?

Contrairement à EBD, je ne connais pas de résultat indiquant que MBD ne peut pas être approché en-deçà d'un ratio  $r$  donné.  
D'ailleurs...

## Un nouveau problème: ZMBD

Soit **ZMBD** le problème suivant: existe-t-il un matching maximum  $(G_1^M, G_2^M, \mathcal{M})$  de  $(G_1, G_2)$  tel que  $B(G_1^M, G_2^M) = 0$  ?

## Theorem (Angibaud et al.-2008)

ZMBD est *polynomial*

⇒ côté approximation, il y a donc de l'espoir pour MBD

# Peut-on quand même approcher MBD ?

Contrairement à EBD, je ne connais pas de résultat indiquant que MBD ne peut pas être approché en-deçà d'un ratio  $r$  donné.  
D'ailleurs...

## Un nouveau problème: ZMBD

Soit **ZMBD** le problème suivant: existe-t-il un matching maximum  $(G_1^M, G_2^M, \mathcal{M})$  de  $(G_1, G_2)$  tel que  $B(G_1^M, G_2^M) = 0$  ?

Theorem (Angibaud et al.-2008)

ZMBD est *polynomial*

⇒ côté approximation, il y a donc de l'espoir pour MBD

# Peut-on quand même approcher MBD ?

Contrairement à EBD, je ne connais pas de résultat indiquant que MBD ne peut pas être approché en-deçà d'un ratio  $r$  donné.  
D'ailleurs...

## Un nouveau problème: ZMBD

Soit **ZMBD** le problème suivant: existe-t-il un matching maximum  $(G_1^M, G_2^M, \mathcal{M})$  de  $(G_1, G_2)$  tel que  $B(G_1^M, G_2^M) = 0$  ?

## Theorem (Angibaud et al.-2008)

ZMBD est *polynomial*

⇒ côté approximation, il y a donc de l'espoir pour MBD

# De l'espoir ?

## Approximation pour MBD: de l'espoir, mais...

- Aucun résultat dans le cas général (comme pour EBD)
- Raison essentielle dans les deux cas: dès qu'on **supprime des gènes**, il est difficile d'assurer que le nombre de breakpoints n'augmente pas de façon déraisonnable
- ⇒ Solution: regarder des instances **équilibrées** en **matching maximum**

# De l'espoir ?

## Approximation pour MBD: de l'espoir, mais...

- Aucun résultat dans le cas général (comme pour EBD)
- Raison essentielle dans les deux cas: dès qu'on **supprime des gènes**, il est difficile d'assurer que le nombre de breakpoints n'augmente pas de façon déraisonnable
- ⇒ Solution: regarder des instances **équilibrées en matching maximum**

# De l'espoir ?

## Approximation pour MBD: de l'espoir, mais...

- Aucun résultat dans le cas général (comme pour EBD)
- Raison essentielle dans les deux cas: dès qu'on **supprime des gènes**, il est difficile d'assurer que le nombre de breakpoints n'augmente pas de façon déraisonnable
- ⇒ Solution: regarder des instances **équilibrées** en **matching maximum**

# MBD pour les instances équilibrées

## Definition

MBD pour les instances équilibrées: problème  $\text{MBD}_{Eq}$

## Theorem (Goldstein et al.-2004, Kolman et al.-2006)

*Il existe des algorithmes d'approximation pour  $\text{MBD}_{Eq}$ :*

- De ratio **1.1037** pour les instances équilibrées de type **(2, 2)**
- De ratio **4** pour les instances équilibrées de type **(3, 3)**
- De ratio  **$O(k)$**  pour les instances équilibrées de type **(k, k)**

# MBD pour les instances équilibrées

## Definition

MBD pour les instances équilibrées: problème  $\text{MBD}_{Eq}$

## Theorem (Goldstein et al.-2004, Kolman et al.-2006)

*Il existe des algorithmes d'approximation pour  $\text{MBD}_{Eq}$ :*

- De ratio  $1.1037$  pour les instances équilibrées de type  $(2, 2)$
- De ratio  $4$  pour les instances équilibrées de type  $(3, 3)$
- De ratio  $O(k)$  pour les instances équilibrées de type  $(k, k)$

# MBD pour les instances équilibrées

## Definition

MBD pour les instances équilibrées: problème  $\text{MBD}_{Eq}$

## Theorem (Goldstein et al.-2004, Kolman et al.-2006)

*Il existe des algorithmes d'approximation pour  $\text{MBD}_{Eq}$ :*

- De ratio  $1.1037$  pour les instances équilibrées de type  $(2, 2)$
- De ratio  $4$  pour les instances équilibrées de type  $(3, 3)$
- De ratio  $O(k)$  pour les instances équilibrées de type  $(k, k)$

# $MBD_{Eq}$ reste un problème difficile

## Theorem (Goldstein et al.-2004)

- $MBD_{Eq}$  est NP-complet, même pour les instances de type (2,2)
- $MBD_{Eq}$  est APX-dur, même pour les instances de type (2,2)

# $MBD_{Eq}$ reste un problème difficile

## Theorem (Goldstein et al.-2004)

- $MBD_{Eq}$  est NP-complet, même pour les instances de type (2, 2)
- $MBD_{Eq}$  est APX-dur, même pour les instances de type (2, 2)

# Retour sur MBD

## Heuristiques

**MLCS**: Algorithme glouton basé sur le LCS (Longest Common Subsequence)

### Heuristique MLCS vs Résultats exacts

- 12 génomes de  $\gamma$ -protéobactéries
- Génomes de taille  $\sim 500$  à  $\sim 5500$  gènes
- 66 comparaisons de génomes deux à deux
- Les 66 résultats exacts ont été obtenus, et comparés à l'heuristique MLCS

Matching Maximum: Exact vs MLCS		
Pire Cas	Meilleur Cas	Moyenne (66 instances)
95.19%	100%	99.00%

# Retour sur MBD

## Heuristiques

**MLCS**: Algorithme glouton basé sur le LCS (Longest Common Subsequence)

## Heuristique MLCS vs Résultats exacts

- 12 génomes de  $\gamma$ -protéobactéries
- Génomes de taille  $\sim 500$  à  $\sim 5500$  gènes
- 66 comparaisons de génomes deux à deux
- Les **66** résultats exacts ont été obtenus, et comparés à l'heuristique MLCS

Matching Maximum: Exact vs MLCS		
Pire Cas	Meilleur Cas	Moyenne (66 instances)
95.19%	100%	99.00%

# Retour sur MBD

## Heuristiques

**MLCS**: Algorithme glouton basé sur le LCS (Longest Common Subsequence)

## Heuristique MLCS vs Résultats exacts

- 12 génomes de  $\gamma$ -protéobactéries
- Génomes de taille  $\sim 500$  à  $\sim 5500$  gènes
- 66 comparaisons de génomes deux à deux
- Les **66** résultats exacts ont été obtenus, et comparés à l'heuristique MLCS

Matching Maximum: Exact vs MLCS		
Pire Cas	Meilleur Cas	Moyenne (66 instances)
95.19%	100%	99.00%

# Et si on comptait les adjacences ?

## Definition (Problèmes EADJ et MADJ)

- $Adj(G_1, G_2)$  = nombre d'adjacences entre  $G_1$  et  $G_2$
- EADJ: Trouver une exemplarisation  $(G_1^E, G_2^E, \mathcal{M})$  qui maximise  $Adj(G_1^E, G_2^E)$
- MADJ: Trouver un matching maximum  $(G_1^M, G_2^M, \mathcal{M})$  qui maximise  $Adj(G_1^M, G_2^M)$

# Et si on comptait les adjacences ?

## Definition (Problèmes EADJ et MADJ)

- $Adj(G_1, G_2)$  = nombre d'adjacences entre  $G_1$  et  $G_2$
- **EADJ**: Trouver une exemplarisation  $(G_1^E, G_2^E, \mathcal{M})$  qui **maximise**  $Adj(G_1^E, G_2^E)$
- **MADJ**: Trouver un matching maximum  $(G_1^M, G_2^M, \mathcal{M})$  qui **maximise**  $Adj(G_1^M, G_2^M)$

# Et si on comptait les adjacences ?

## Definition (Problèmes EADJ et MADJ)

- $Adj(G_1, G_2)$  = nombre d'adjacences entre  $G_1$  et  $G_2$
- **EADJ**: Trouver une exemplarisation  $(G_1^E, G_2^E, \mathcal{M})$  qui **maximise**  $Adj(G_1^E, G_2^E)$
- **MADJ**: Trouver un matching maximum  $(G_1^M, G_2^M, \mathcal{M})$  qui **maximise**  $Adj(G_1^M, G_2^M)$

# Et si on comptait les adjacences ?

## Theorem

- EADJ et EBD sont équivalents
- MADJ et MBD sont équivalents

## Proof.

Soit deux génomes  $(G_1, G_2)$  sans duplication, ayant le même contenu en gènes, avec  $|G_1| = |G_2| = n$ . Alors,

$$B(G_1, G_2) + Adj(G_1, G_2) = n - 1$$



## Remarque

Problèmes équivalents si on veut optimiser, pas si on veut approcher !

# Et si on comptait les adjacences ?

## Theorem

- EADJ et EBD sont équivalents
- MADJ et MBD sont équivalents

## Proof.

Soit deux génomes  $(G_1, G_2)$  sans duplication, ayant le même contenu en gènes, avec  $|G_1| = |G_2| = n$ . Alors,

$$B(G_1, G_2) + Adj(G_1, G_2) = n - 1$$



## Remarque

Problèmes équivalents si on veut optimiser, pas si on veut approcher !

# Et si on comptait les adjacences ?

## Theorem

- EADJ et EBD sont équivalents
- MADJ et MBD sont équivalents

## Proof.

Soit deux génomes  $(G_1, G_2)$  sans duplication, ayant le même contenu en gènes, avec  $|G_1| = |G_2| = n$ . Alors,

$$B(G_1, G_2) + Adj(G_1, G_2) = n - 1$$



## Remarque

Problèmes équivalents si on veut **optimiser**, pas si on veut **approcher** !

# Et si on comptait les adjacences ?

$MADJ_{Eq}$  = MADJ restreint aux instances **équilibrées**

## Theorem (Angibaud et al.-2008)

*Il existe des algorithmes d'approximation pour  $MADJ_{Eq}$ :*

- *De ratio 1.1442 pour les instances équilibrées de type (2, 2)*
- *De ratio 3 pour les instances équilibrées de type (3, 3)*
- *De ratio 4 pour les instances équilibrées de type (k, k)*

# Et si on comptait les adjacences ?

$MADJ_{Eq}$  = MADJ restreint aux instances **équilibrées**

## Theorem (Angibaud et al.-2008)

*Il existe des algorithmes d'approximation pour  $MADJ_{Eq}$ :*

- De ratio **1.1442** pour les instances équilibrées de type **(2, 2)**
- De ratio **3** pour les instances équilibrées de type **(3, 3)**
- De ratio **4** pour les instances équilibrées de type **(k, k)**

# Et si on comptait les adjacences ?

$MADJ_{Eq}$  = MADJ restreint aux instances **équilibrées**

## Theorem (Angibaud et al.-2008)

*Il existe des algorithmes d'approximation pour  $MADJ_{Eq}$ :*

- De ratio **1.1442** pour les instances équilibrées de type **(2, 2)**
- De ratio **3** pour les instances équilibrées de type **(3, 3)**
- De ratio **4** pour les instances équilibrées de type **(k, k)**

# Et si on comptait les adjacences ?

$MADJ_{Eq}$  = MADJ restreint aux instances **équilibrées**

## Theorem (Angibaud et al.-2008)

*Il existe des algorithmes d'approximation pour  $MADJ_{Eq}$ :*

- De ratio **1.1442** pour les instances équilibrées de type **(2, 2)**
- De ratio **3** pour les instances équilibrées de type **(3, 3)**
- De ratio **4** pour les instances équilibrées de type **(k, k)**

# Conclusion

## Résumé du spectacle

- **EBD:**
  - APX-dur dans tous les cas
  - Impossible d'approcher à un quelconque ratio pour les instances de type  $(a, b)$ ,  $a, \geq 3$
  - Existence d'heuristiques efficaces
- **MBD:**
  - APX-dur dans tous les cas
  - Rien de connu en terme d'(in)approximabilité
  - Existence d'heuristiques efficaces
  - Cas particulier des instances **équilibrées**: algorithmes d'approximation existants
- **MADJ<sub>Eq</sub>**: algorithmes d'approximation existants

# Conclusion

## Résumé du spectacle

- **EBD:**
  - APX-dur dans tous les cas
  - Impossible d'approcher à un quelconque ratio pour les instances de type  $(a, b)$ ,  $a, \geq 3$
  - Existence d'heuristiques efficaces
- **MBD:**
  - APX-dur dans tous les cas
  - Rien de connu en terme d'(in)approximabilité
  - Existence d'heuristiques efficaces
  - Cas particulier des instances **équilibrées**: algorithmes d'approximation existants
- **MADJ<sub>Eq</sub>**: algorithmes d'approximation existants

# Conclusion

## Résumé du spectacle

- **EBD**:
  - APX-dur dans tous les cas
  - Impossible d'approcher à un quelconque ratio pour les instances de type  $(a, b)$ ,  $a, \geq 3$
  - Existence d'heuristiques efficaces
- **MBD**:
  - APX-dur dans tous les cas
  - Rien de connu en terme d'(in)approximabilité
  - Existence d'heuristiques efficaces
  - Cas particulier des instances **équilibrées**: algorithmes d'approximation existants
- **MADJ<sub>Eq</sub>**: algorithmes d'approximation existants

# Conclusion

## Problèmes ouverts

- **Approximation de EBD**: que peut-on dire des “petits cas”, par exemple des instances de type  $(2, 3)$  ?
- **Approximation de MBD**: quid du cas général, càd non nécessairement équilibré ?  
⇒ Difficulté liée à la **suppression** des gènes
- Question entêtante à propos de **ZEBD** (savoir si'il existe une exemplarisation à 0 breakpoint): qui de la **complexité des instances de type  $(2, 2)$**  ?

# Conclusion

## Problèmes ouverts

- **Approximation de EBD**: que peut-on dire des “petits cas”, par exemple des instances de type  $(2, 3)$  ?
- **Approximation de MBD**: quid du cas général, càd non nécessairement équilibré ?  
 ⇒ Difficulté liée à la suppression des gènes
- Question entêtante à propos de ZEBD (savoir si'il existe une exemplarisation à 0 breakpoint): qui de la complexité des instances de type  $(2, 2)$  ?

# Conclusion

## Problèmes ouverts

- **Approximation de EBD**: que peut-on dire des “petits cas”, par exemple des instances de type  $(2, 3)$  ?
- **Approximation de MBD**: quid du cas général, càd non nécessairement équilibré ?  
⇒ Difficulté liée à la **suppression** des gènes
- Question entêtante à propos de **ZEBD** (savoir si'il existe une exemplarisation à 0 breakpoint): quid de la **complexité des instances de type  $(2, 2)$**  ?

# Conclusion

## Problèmes ouverts

- **Approximation de EBD**: que peut-on dire des “petits cas”, par exemple des instances de type  $(2, 3)$  ?
- **Approximation de MBD**: quid du cas général, càd non nécessairement équilibré ?  
⇒ Difficulté liée à la **suppression** des gènes
- Question entêtante à propos de **ZEBD** (savoir si'il existe une exemplarisation à 0 breakpoint): qui de la **complexité des instances de type  $(2, 2)$**  ?

# Bibliography



D. Sankoff

Genome Rearrangement with Gene Families  
Bioinformatics, vol. 15, pp. 909–917, 1999



D. Bryant

The Complexity of Calculating Exemplar Distances  
Comparative Genomics, pp. 207–212, 2000



A. Goldstein, P. Kolman, J. Zheng

Minimum Common String Partition Problem: Hardness and Approximations  
In Proc. **ISAAC 2004**, LNCS vol. 3341, pp. 484–495, 2004



C. Thach Nguyen, Y.C. Tai, L. Zhang

Divide-and-Conquer Approach for the Exemplar Breakpoint Distance  
Bioinformatics, vol. 21, pp. 2171–2176, 2006



Z. Chen, B. Fu, B. Zhu

The Approximability of the Exemplar Breakpoint Distance Problem  
In Proc. **AAIM 2006**, LNCS vol. 4041, pp. 291–302, 2006



P. Kolman, T. Waleń

Reversal Distance for Strings with Duplicates: Linear Time Approximation using Hitting Set  
In Proc. **WAOA 2006**, LNCS vol. 4368, pp. 281–291, 2006



S. Angibaud, G. Fertin, I. Rusu, A. Thévenin, S. Viallette

Efficient Tools for Computing the Number of Breakpoints and the Number of Adjacencies between two Genomes with Duplicate Genes  
Journal of Computational Biology, 2007. Submitted.



S. Angibaud, G. Fertin, I. Rusu, A. Thévenin, S. Viallette

# Annexe: Caractéristiques des Genomes étudiés

Caractéristiques principales			
Genome	Nombre de gènes	Nombre de familles de gènes	Pourcentage de duplications
Baphi	564	549	2.66
Ecoli	4183	3423	18.17
Haein	1709	1531	10.42
Paeru	5540	4500	18.77
Pmult	2015	1811	10.12
Salty	4203	3456	17.77
Wglos	653	627	3.98
Xaxon	4192	3634	13.31
Xcamp	4029	3468	13.92
Xfast	2680	2346	12.46
Ypest-CO92	3599	3021	16.06
Ypest-KIM	3879	3236	16.58

**Table:** Caractéristiques principales des 12 génomes de  $\gamma$ -Protéobactérie étudiés