

# ALGORITHMES DE CONSTRUCTION ET CORRECTION **D'ARBRES DE GÈNES** PAR LA **RÉCONCILIATION**

---

Manuel Lafond, Université de Montréal

# Le plan

## **Introduction**

**Arbres de gènes, arbres d'espèces  
Réconciliation**


## **Résolution de polytomies**

## **Correction par relations d'orthologie**


## **Validation de relations d'orthologie et paralogie**

## **Superarbres de gènes et réconciliation**

# Arbre d'espèces



# Arbre d'espèces



# Arbre de gènes



## Prenons par exemple le gène RPGR :

*Retinitis pigmentosa GTPase regulator*

Participe à la coloration des yeux.

Quelle est l'**histoire** du RPGR ?


Presque tous les vertébrés ont ce gène. Certaines espèces ont même 2+ copies.

Qu'est-ce qui s'est passé?


Un gène peut être :

- **Transmis** à des espèces descendantes par **spéciation**
- **Dupliqué**
- **Perdu**

# Arbre de gènes




# Arbre de gènes




# Arbre de gènes

Duplication = le gène créé une copie dans le génome de son espèce




# Arbre de gènes


**Speciation = le gène est envoyé dans les 2 espèces descendantes**




# Arbre de gènes




# Arbre de gènes




# Arbre de gènes




# Arbre de gènes




# Arbre de gènes




# Arbre de gènes




# Arbre de gènes




# Arbre de gènes




# Arbre de gènes



# Arbre de gènes



# Arbre de gènes



# Inférence d'arbres de gènes

**Ce qu'on a en réalité:**

O1  
AGTTG

M1  
ACGTT

R1  
AGGTT

R1' G2  
AGGTT CGGAT

O2  
CCGAT

H2  
CGGAT

# Inférence d'arbres de gènes

O1  
AGTTG

M1  
ACGTT


R1  
AGGTT

R1'  
AGGTT


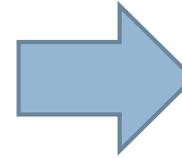
G2  
CGGAT

O2  
CCGAT

H2  
CGGAT



Algorithme de reconstruction phylogénétique (e.g. maximum parcimonie, maximum vraisemblance, inférence Bayésienne)




# Mauvaise différentiation des séquences

g1  
CCCCC


g2  
CCCCC

g3  
CCCCC

g4  
CCCCC




Algorithme de  
reconstruction  
phylogénétique  
(e.g. maximum  
parcimonie, maximum  
vraisemblance,  
inférence Bayésienne)



???

# Mauvaise différentiation des séquences




# Mauvaise différentiation des séquences

g1  
AAAA



g2  
CCCC

g3  
GGGG

g4  
TTTT



Algorithme de reconstruction phylogénétique (e.g. maximum parcimonie, maximum vraisemblance, inférence Bayésienne)



# Mauvaise différentiation des séquences

g1  
AAAA

g2  
CCCC


g3  
GGGG

g4  
TTTT



g5  
TTTT

g6  
AAAA

g7  
AAAA



Algorithme de reconstruction phylogénétique  
(e.g. maximum parcimonie, maximum vraisemblance, inférence Bayésienne)




# Branches mal supportées

g1  
ACGT


g2  
CGTA

g3  
CGGT


g4  
TGCG



Algorithme de reconstruction phylogénétique (e.g. maximum parcimonie, maximum vraisemblance, inférence Bayésienne)



Revient dans peu d'arbres bootstrap (e.g. <70%)




# Branches mal supportées

g1  
ACGT




g2  
CGTA

g3  
CGGT


g4  
TGCG



Algorithme de reconstruction phylogénétique (e.g. maximum parcimonie, maximum vraisemblance, inférence Bayésienne)



# Paramétrisation des algorithmes




# Arbres multiples

g1  
ACGT





g2  
CGTA

g3  
CGGT

g4  
TGCG



Algorithme de reconstruction phylogénétique  
(e.g. maximum parcimonie, maximum vraisemblance, inférence Bayésienne)



# Quelques problèmes

- Arbres partiellement résolus
  - ▣ Les arbres contiennent des **polytomies** (des nœuds non-binaires)
- Topologies erronés
- Plusieurs arbres
  - ▣ Candidats multiples
  - ▣ Petits sous-arbres à combiner


# Quelques problèmes

- La quasi-totalité des méthodes de reconstruction phylogénétique sont génériques (i.e. non-spécifiques aux arbres de gènes) et ont souvent été développées pour la reconstruction d'**arbres d'espèces**.

# Quelques problèmes

- La quasi-totalité des méthodes de reconstruction phylogénétique sont génériques (i.e. non-spécifiques aux arbres de gènes) et ont souvent été développées pour la reconstruction d'**arbres d'espèces**.
- On veut utiliser les propriétés spécifiques aux gènes pour corriger les arbres de gènes.
  - ▣ Arbre d'espèces
  - ▣ Réconciliation

# Pipeline de correction d'arbres



# Articles présentés

## [An optimal reconciliation algorithm for gene trees with polytomies](#)

M Lafond, KM Swenson, N El-Mabrouk

International Workshop on Algorithms in Bioinformatics, 2012

## [Gene tree correction guided by orthology](#)

M Lafond, M Semeria, KM Swenson, E Tannier, N El-Mabrouk

BMC bioinformatics (2013)

## [Orthology and paralogy constraints: satisfiability and consistency](#)

M Lafond, N El-Mabrouk

BMC genomics 15 (2014)


## [Reconstructing a SuperGeneTree minimizing reconciliation](#)

M Lafond, A Ouangraoua, N El-Mabrouk


BMC bioinformatics 16 (2015)

# Réconciliation

S





G



# Réconciliation



- 1) Mapping gène-espèce (Ica mapping)

S





# Réconciliation

- 1) Mapping gène-espèce (lca mapping)
- 2) Trouver les duplications
  - ▣ Nœuds qui ont le même mapping que leur enfant





# Réconciliation

- 1) Mapping gène-espèce (lca mapping)
- 2) Trouver les duplications
  - Nœuds qui ont le même mapping que leur enfant
- 3) Trouver les pertes
  - Compléter les branches avec les espèces manquantes



# Réconciliation

- Coût d'une réconciliation:
  - ▣ Typiquement, # de duplications + # de pertes
  - ▣ Parfois, # de duplications seulement



# Méthodes de construction/correction

- Construction "de novo"
  - ▣ SYNERGY (2007), Prime-GSR (2009), GIGA (2010), SPIMAP (2011), PHYLD OG (2013)
- Construction par amalgamation
  - ▣ AngST (2011), TERA (2014)
- Correction par résolution de polytomies
  - ▣ NOTUNG (2006), Chang & Eulenstein (2006), Zheng & Zhang (2014)
- Correction par exploration du voisinage
  - ▣ NOTUNG (2000), Eulenstein (2012), TreeFix (2012)
- À l'exception de PHYLD OG, toutes ces méthodes nécessitent un arbre d'espèces en entrée, et appliquent une forme de réconciliation.



# Résolution de polytomies


[An optimal reconciliation algorithm for gene trees with polytomies](#)

M Lafond, KM Swenson, N El-Mabrouk

International Workshop on Algorithms in Bioinformatics, 2012


# Résolution de polytomies

- **Entrée**: une arbre d'espèces  $S$  binaire, et un arbre de gènes  $G$  non-binaire
- **Sortie**: une "binarisation" de  $G$  qui minimise le coût de réconciliation avec  $S$




# Résolution de polytomies

- Chaque polytomie peut être résolue indépendamment (*Chang & Eulenstein, 2006*)
  - ▣ Algorithme  $O(|G||S|^2)$  par polytomie




# Résolution de polytomies

- Chaque polytomie peut être résolue indépendamment (*Chang & Eulenstein, 2006*)
  - ▣ Algorithme  $O(|G||S|^2)$  par polytomie




# Résolution de polytomies

- Chaque polytomie peut être résolue indépendamment (*Chang & Eulenstein, 2006*)
  - ▣ Algorithme  $O(|G||S|^2)$  par polytomie





# Résolution de polytomies

- Chaque polytomie peut être résolue indépendamment (*Chang & Eulenstein, 2006*)
  - ▣ Algorithme  $O(|G||S|^2)$  par polytomie



# Le vrai problème

- On réduit le problème à la résolution d'une seule polytomie.





# Travaux antérieurs

- Notung (2006)
  - ▣  $O(|S||G|^3)$  pour résoudre tout un arbre. Supporte coût différents dup et pertes.
- Chang & Eulenstein (2006)
  - ▣  $O(|S||P|^2)$  par polytomie  $P$ ,  $O(|S||G|^2)$  pour tout un arbre  $G$
- **Lafond, Swenson & El-Mabrouk (2012)**
  - ▣  $O(|S| + |P|)$  par polytomie  $P$ ,  $O(|S||G|)$  pour tout l'arbre
- Zhang & Zheng (2014)
  - ▣  $O(|S| + |G|)$  pour résoudre tout un arbre  $G$
- Lafond, Noutahi & El-Mabrouk (2016)
  - ▣  $O(|S| + |G|)$  pour tout l'arbre  $G$ ,  $O(|G|^2)$  avec coûts différents dup et pertes.



# Programmation dynamique

- On réduit le problème à la résolution d'une seule polytomie.
- Algorithme en temps  $O(|S|)$  par programmation dynamique.



# Programmation dynamique

- Pour une espèce  $s$  et un entier  $k$ :
- $M(s, k)$ : si on se restreint aux gènes des descendant de  $s$ , quel est le coût minimum pour avoir une forêt de  $k$  arbres tous enracinés en un gène de  $s$ .





# Programmation dynamique

- Pour une espèce  $s$  et un entier  $k$ :
- $M(s, k)$ : si on se restreint aux gènes des descendant de  $s$ , quel est le coût minimum pour avoir une forêt de  $k$  arbres tous enracinés en un gène de  $s$ .
  - ▣ Chaque gène retenu devient un sous-arbre
  - ▣ On peut connecter deux feuilles/sous-arbres
  - ▣ On doit utiliser tous les gènes dans notre restriction
  - ▣ On peut insérer des pertes, ce qui crée de nouveaux sous-arbres

# Programmation dynamique

- Exemple:  $M(b, 2) = 0$





Restriction à b  
(et ses descendants)




Forêt de 2 arbres

# Programmation dynamique

- Exemple:  $M(b, 1) = 1$





Restriction à **b** (et ses descendants)




# Programmation dynamique

□ Exemple:  $M(b, 3) = 1$





Restriction à b (et ses descendants)



Forêt de 3 arbres (dont 1 perte)



# Programmation dynamique

- En général, pour une feuille  $s$  présente  $\#(s)$  fois dans la polytomie,
- $M(s, k) = |k - \#(s)|$






# Programmation dynamique

□  $M(e, 1) = ?$






# Programmation dynamique

□  $M(e, 1) = 1$






# Programmation dynamique

□  $M(e, 2) = ?$






# Programmation dynamique

□  $M(e, 2) = ?$



# Programmation dynamique



□  $M(e, 2) = 1$




# Récurrance

□  $M(e, 2) = \min($

$M(a, 2) + M(b, 2),$




$M(e, 2 - 1) + 1,$



$M(e, 2 + 1) + 1$




)



La table M peut être remplie en temps  $O(|S||G|)$

# Cas final

- $M(g, 1) =$  si on se restreint à tous les gènes, coût min. pour avoir un seul arbre
- (i.e. coût min. d'une solution)




# Calcul de la table M

<b>k =</b>	<b>1</b>	<b>2</b>	<b>3</b>	<b>4</b>	<b>5</b>	<b>6</b>
M(a, k)	3	2	1	0	1	2
M(b, k)	1	0	1	2	3	4
M(c, k)	0	1	2	3	4	5
M(d, k)	1	2	3	4	5	6
M(e, k)	3	2	2	2	3	4
M(f, k)	1	2	3	4	5	6
M(g, k)	4	4	5	6	7	8

# Calcul de la table M

- Les valeurs des rangées ne sont pas aléatoires.


<b>k =</b>	<b>1</b>	<b>2</b>	<b>3</b>	<b>4</b>	<b>5</b>	<b>6</b>
M(a, k)	3	2	1	0	1	2
M(b, k)	1	0	1	2	3	4
M(c, k)	0	1	2	3	4	5
M(d, k)	1	2	3	4	5	6
M(e, k)	3	2	2	2	3	4
M(f, k)	1	2	3	4	5	6
M(g, k)	4	4	5	6	7	8



# Calcul de la table M

- Les valeurs des rangées ne sont pas aléatoires.


<b>k =</b>	<b>1</b>	<b>2</b>	<b>3</b>	<b>4</b>	<b>5</b>	<b>6</b>
M(a, k)	3	2	1	0	1	2
M(b, k)	1	0	1	2	3	4
M(c, k)	0	1	2	3	4	5
M(d, k)	1	2	3	4	5	6
M(e, k)	3	2	2	2	3	4
M(f, k)	1	2	3	4	5	6
M(g, k)	4	4	5	6	7	8



# Calcul de la table M


- Les valeurs des rangées ne sont pas aléatoires.

<b>k =</b>	<b>1</b>	<b>2</b>	<b>3</b>	<b>4</b>	<b>5</b>	<b>6</b>
M(a, k)	3	2	1	0	1	2
M(b, k)	1	0	1	2	3	4
M(c, k)	0	1	2	3	4	5
M(d, k)	1	2	3	4	5	6
M(e, k)	3	2	2	2	3	4
M(f, k)	1	2	3	4	5	6
M(g, k)	4	4	5	6	7	8



# Calcul de la table M


- Chaque rangée peut être représentée par une "fonction de coupe", qui est entièrement décrite par seulement 3 =  $O(1)$  valeurs.



# Calcul de la table M

- Les valeurs des rangées ne sont pas aléatoires.

<b>k =</b>	<b>1</b>	<b>2</b>	<b>3</b>	<b>4</b>	<b>5</b>	<b>6</b>
M(a, k)	3	2	1	0	1	2
M(b, k)	1	0	1	2	3	4
M(c, k)	0	1	2	3	4	5
M(d, k)	1	2	3	4	5	6
M(e, k)	3	2	2	2	3	4
M(f, k)	1	2	3	4	5	6
M(g, k)	4	4	5	6	7	8



Chaque rangée peut être remplie (i.e. représentée par ses 3 valeurs) en temps  $O(1)$

$\Rightarrow$  La table M peut être remplie en temps  $O(|S|)$

# Extensions de l'algorithme

- Plusieurs solutions possibles:
  - ▣ Choisir selon un critère Neighbor-Joining
  - ▣ Sortir toutes les solutions possibles

E. Noutahi, M. Semeria, **M. Lafond**, J. Seguin, B. Boussau, L. Guéguen, N. El-Mabrouk, E. Tannier, "Efficient gene tree correction guided by species and synteny evolution". PLOS ONE (à paraître)

- Coût différents entre pertes et duplications
  - ▣ De plus, coût pouvant varier selon l'espèce

**M. Lafond**, E. Noutahi, N. El-Mabrouk, "Efficient Non-Binary Gene Tree Resolution with Weighted Reconciliation Cost". CPM 2016



# Correction d'arbres par relations d'orthologie

[Gene tree correction guided by orthology](#)

M Lafond, M Semeria, KM Swenson, E Tannier, N El-Mabrouk  
BMC bioinformatics (2013)


# Orthologues et paralogues

Deux gènes sont:

**Orthologues** si leur dernier ancêtre commun a subi une **spéciation**


**Paralogues** si leur dernier ancêtre commun a subi une **duplication**

# Orthologues et paralogues




# Orthologues et paralogues

O1 et M1 sont orthologues  
(lca est une spéciation)



# Orthologues et paralogues

O1 et G2 sont paralogues  
(lca est une duplication)



# Pourquoi les relations?

Les relations d'orthologie/paralogie sont liées aux fonctions des gènes.

Certaines bases de données **d'annotation fonctionnelle** supposent que les orthologues effectuent des fonctions similaires


(e.g. COG, eggNOG)

**Quest For Orthologs consortium**: "a joint effort to benchmark, improve and standardize orthology predictions through collaboration, the use of shared reference datasets, and evaluation of emerging new methods".

# Inférence de relations




## Clustering de gènes en groupes d'orthologues:

- ▣ Si  $g_1$  and  $g_2$  sont "**assez similaires**" en terme de séquences,  $g_1$  and  $g_2$  sont dits "orthologues candidats".
- ▣ Faire une graphe  $G$  des orthologues candidats.
- ▣ Partitionner  $G$  en clusters, i.e. composantes fortement connexes
  - Sinon, trop de faux-positifs
- ▣ OrthoMCL, InParanoid, proteinortho, ...



# Graphe de relations

Sequences  
et autres...



Orthologues = (a,b) (a, c) (c, d)

Paralogues = (a, d) (b, c) (b, d)





Orthologues



Paralogues


# Relations et arbres de gènes

Arbre de gènes => relations





# Relations et arbres de gènes

Relations => Arbre de gènes (??)





# Correction par orthologie

Sequences  
et autres...




$a_1$  et  $b_1$  sont  
orthologues




# Correction par orthologie

- **Entrée**: une arbre d'espèces  $S$  binaire, et un arbre de gènes  $G$  binaire, et des relations d'orthologie  $R$  à satisfaire.
- **Sortie**: un arbre  $G'$  qui satisfait  $R$  en "s'éloignant le moins possible" de  $G$ .




# Correction par orthologie

- Note: il existe toujours une solution – on met tous les gènes de la même espèce ensemble.



# Correction par orthologie

- Note: il existe toujours une solution – on met tous les gènes de la même espèce ensemble.
- Mais on voudrait ne pas trop changer G.



# Préservation des clades


- On va préserver un maximum de clades de  $G$ .
- À chaque nœud  $x$  correspond un clade, dénoté  $\text{clade}(x)$ , qui est l'ensemble des feuilles descendantes de  $x$ .

$$\text{clade}(w) = \{a_2, b_1\}$$

$$\text{clade}(x) = \{c_1, d_1\}$$

$$\text{clade}(y) = \{a_1, a_2, b_1\}$$

$$\text{clade}(z) = \{a_1, a_2, b_1, c_1, d_1\}$$



# Préservation des clades


- On va préserver un maximum de clades de  $G$ .
- À chaque nœud  $x$  correspond un clade, dénoté  $\text{clade}(x)$ , qui est l'ensemble des feuilles descendantes de  $x$ .

$\text{clade}(w) = \{a_2, b_1\}$

$\text{clade}(x) = \{c_1, d_1\}$


$\text{clade}(y) = \{a_1, a_2, b_1\}$

$\text{clade}(z) = \{a_1, a_2, b_1, c_1, d_1\}$




Clades non-préservés:  $\{a_2, b_1\}$

$G'$ :




# Préservation des clades

- Préserver un maximum de clades est équivalent à minimiser la distance **Robinson-Foulds** entre  $G$  et  $G'$ .




# Correction par orthologie

- **Entrée**: une arbre d'espèces  $S$  binaire, et un arbre de gènes  $G$  binaire, et des relations d'orthologie  $R$  à satisfaire.
- **Sortie**: un arbre  $G'$  qui satisfait  $R$  et **qui préserve un maximum de clades de  $G$** .




# L'algo en un exemple

- $a_1, d_2$  ne veulent pas être paralogues
  - $\text{lca}(a_1, d_2)$  devrait être une spéciation
- Quels clades peut-on préserver?




$$R = \{(a_1, d_2)\}$$




# L'algo en un exemple

- Peut-on préserver  $\text{clade}(u) = \{a_1, b_1, c_1, d_1\}$  ?




$$R = \{(a_1, d_2)\}$$




# L'algo en un exemple

- Peut-on préserver  $\text{clade}(u) = \{a_1, b_1, c_1, d_1\}$  ?
  - ▣ On peut montrer que NON, c'est impossible.
  - ▣ Si on conserve  $\text{clade}(u)$ ,  $a_1$  et  $d_2$  resteront paralogues




$$R = \{(a_1, d_2)\}$$




# L'algo en un exemple

- Peut-on préserver  $\text{clade}(w) = \{a_1, b_1\}$  ?




# L'algo en un exemple

- Peut-on préserver  $\text{clade}(w) = \{a_1, b_1\}$  ?
  - ▣ Oui, il existe une solution préserve  $\text{clade}(w)$ .




# L'algo en un exemple

- Peut-on préserver  $\text{clade}(x) = \{a_1, b_1\}$  ?
  - ▣ Oui, il existe une solution préserve  $\text{clade}(x)$ .



# L'algo en un exemple

- For some constraint  $(a, b)$  in  $P$  :
  - Let  $g = \text{LCA}(a, b)$
  - Let  $h_{a,b}$  be the highest node on the path from  $a$  to  $g$  such that  $s(h_{a,b})$  is a descendant of  $s(g)$ .
  - Every node on the path from  $h_{a,b}$  to  $g$  (excluding  $h$  and  $g$ ) corresponds to an unpreservable clade.
  - Define  $h_{b,a}$  analogously




# L'algo en un exemple

- For some constraint  $(a, b)$  in  $P$  :
  - Let  $g = \text{LCA}(a,b)$
  - Let  $h_{a,b}$  be the highest node on the path from  $a$  to  $g$  such that  $s(h_{a,b})$  is a descendant of  $s(g)$ .
  - Every node on the path from  $h_{a,b}$  to  $g$  (excluding  $h$  and  $g$ ) corresponds to an unpreservable clade.
  - Define  $h_{b,a}$  analogously
- For every constraint  $(a, b)$  in  $P$ 
  - Compute  $h_{a,b}$  and  $h_{b,a}$
  - Find the unpreservable clades they imply
- Identifies all unpreservable clades.
- Can be done in time  $O(|P| |V(G)|)$

# L'algo en un exemple


- On sait dire si un clade peut être préservé ou non, individuellement.
- Mais peut-on tous les préserver simultanément?



$$R = \{(a_1, d_2)\}$$

# L'algo en un exemple

- Oui! On prend tous les sous-arbres maximaux préservables (i.e. qui n'ont pas d'ancêtre préservable mis-à-part la racine).




$$R = \{(a_1, d_2)\}$$

- Ici, les sous-arbres enracinés en
  - $\{w, x, b_2, y\}$
- (les feuilles sont toujours préservables)

# L'algo en un exemple


- On joint ces sous-arbres sous une polytomie.



$$R = \{(a_1, d_2)\}$$

# L'algo en un exemple


- Trouver la resolution qui maximise le nombre d'orthologies (faisable de façon "greedy").
- R sera satisfait.



$$R = \{(a_1, d_2)\}$$

# L'algo en un exemple

- Cette résolution permet de satisfaire R tout en préservant un maximum de clades.
- Il se peut qu'on doive répéter récursivement dans les sous-arbres considérés.



$$R = \{(a_1, d_2)\}$$

# Résultats

- Avec une méthode basée sur la synténie (Lafond, Swenson et El-Mabrouk, 2013), nous avons inféré des relations d'orthologie sur 1000 familles de genes.
- Nous avons corrigé les arbres d'Ensembl sur ces 1000 familles de gènes.
- Nous avons comparé nos arbres corrigé en utilisant le test statistique **"AU Test"**
  - 82.3% des arbres corrigés étaient statistiquement viables
  - 17.7% de nos arbres ont donc été rejetés statistiquement
  - 14.8% des arbres Ensembl ont été rejetés

# Extension à la paralogie

- Cet algorithme permet seulement de satisfaire des **relations d'orthologie**.
- Et si des relations **d'orthologie + paralogie** étaient données?
- Problème: il se pourrait qu'il n'existe même pas de solution possible.
  - ▣ Comment savoir?



# Validation de relations d'orthologie et paralogie

[Orthology and paralogy constraints: satisfiability and consistency](#)


M Lafond, N El-Mabrouk

BMC genomics 15 (2014)

# Graphe d'orthologie/paralogie

Orthologues = (a,b) (a, c) (c, d)

Paralogues = (a, d) (b, c) (b, d)





 Orthologues

 Paralogues


# Graphe d'orthologie/paralogie

Arbre de gènes => relations




# Graphe d'orthologie/paralogie

Relations => Arbre de gènes (??)




# Graphe d'orthologie/paralogie





# Satisfaisabilité de relations




**Problème:** est-ce qu'un graphe de relations  $R$  donné est **satisfaisable**?  
Est-ce qu'il existe un arbre de gènes contenant les relations de  $R$  ?



**Theorème** (Hernandez-Rosalez & al., 2012):



Un graphe de relations  $R$  est satisfiable SSI  
 $R_{\text{BLACK}}$  est " $P_4$ -free" (n'a pas de chemin **induit**  
sur 4 sommets).






# S-Consistance

On pourrait exiger que l'arbre de gènes construit soit consistant avec S




# S-Consistance

On pourrait exiger que l'arbre de gènes construit soit consistant avec S




# S-Consistance

On pourrait exiger que l'arbre de gènes construit soit consistant avec S





# S-Consistance

On pourrait exiger que l'arbre de gènes construit soit consistant avec S



## Theorème:


Un graphe de relations  $R$  est  $S$ -Consistant SSI  $R$  est satisfaisable, **et tout sous-graphe de 3 sommets de  $R$  est "en accord" avec  $S$ .**



# Relations inconnues



Il se peut que l'on n'ait pas assez d'informations sur une relation d'orthologie/paralogie

e.g. gènes qui ont un seuil BLAST "borderline"



**Problème** : soit R une graphe de relations avec des relations "inconnues", peut-on choisir ces inconnues pour rendre R:



- **satisfaisable?**
- **S-Consistant?**



**Problème** : soit R une graphe de relations avec des relations "inconnues", peut-on choisir ces inconnues pour rendre R:



□ **satisfaisable?**  $O(n^3)$

□ **S-Consistent?**  $O(n^3)$



# Idée de l'algorithme



Essayer "tout noir", et "tout bleu".



# Idée de l'algorithme

Essayer "tout noir", et "tout bleu".

Si  $R_{\text{BLACK}}$  et  $R_{\text{BLUE}}$  sont connexes dans les 2 cas, pas de solution.




# Idée de l'algorithme

Essayer "tout noir", et "tout bleu".

Si  $R_{\text{BLACK}}$  et  $R_{\text{BLUE}}$  sont connexes dans les 2 cas, pas de solution.

Ici,  $R_{\text{BLACK}}$  de "tout bleu" n'est pas connexe.




# Idée de l'algorithme

Essayer "tout noir", et "tout bleu".

Si  $R_{\text{BLACK}}$  et  $R_{\text{BLUE}}$  sont connexes dans les 2 cas, pas de solution.

Ici,  $R_{\text{BLACK}}$  de "tout bleu" n'est pas connexe.




# Idée de l'algorithme

Essayer "tout noir", et "tout bleu".

Si  $R_{\text{BLACK}}$  et  $R_{\text{BLUE}}$  sont connexes dans les 2 cas, pas de solution.

Ici,  $R_{\text{BLACK}}$  de "tout bleu" n'est pas connexe.


Bien! On répète sur chaque composante connexe.



# Expériences

Nous avons inféré 265 graphes d'orthologie/paralogie avec **ProteinOrtho**, avec 5 jeux de paramètres  $\{-2, -1, 0, +1, +2\}$ .


*Strict => Moins d'orthologies*



*Lousse => Plus d'orthologies*

# Expériences


*Strict => Moins d'orthologies*



*Lousse => Plus d'orthologies*

# Expériences


*Strict => Moins d'orthologies*



*Lousse => Plus d'orthologies*


# Expériences

*Strict => Moins d'orthologies*




*Lousse => Plus d'orthologies*

# Expériences



# Expériences avec l'inconnu

*Strict => Moins d'orthologies*




*Lousse => Plus d'orthologies*

OK, ce n'est presque jamais satisfaisable. Mais peut-on trouver des relations robustes?

# Expériences avec l'inconnu


*Strict => Moins d'orthologies*




*Lousse => Plus d'orthologies*

OK, ce n'est presque  
jamais satisfaisable.  
Mais peut-on trouver  
des relations  
robustes?


# Expériences avec l'inconnu



Si strict et lousse sont en accord, on devrait pouvoir faire confiance. Le reste est posé comme "inconnu".



# Expériences avec l'inconnu



En combinant +2/-2, les relations partielles deviennent

**satisfiable** pour 98% des familles

**S-consistent** pour 65% des familles

# Expériences avec l'inconnu

			NON Satisfaisable	NON S-Consistant
 $\cap$  -2/+2	1.9%	35.1%		
 $\cap$  -2/+1	2.6%	35.1%		
 $\cap$  -1/+1	4.2%	44.8%		
 $\cap$  -1/+2	4.1%	40.8%		



# Superarbres de gènes et réconciliation

[Reconstructing a SuperGeneTree minimizing reconciliation](#)



M Lafond, A Ouangraoua, N El-Mabrouk

BMC bioinformatics 16 (2015)



# TP53: plusieurs arbres de gènes

## Ensembl

## PhylomeDB



## TreeFam





## HOGENOM

# TP53: plusieurs arbres de gènes


Ensembl

Phylome

Ensembl + PhylomeDB + TreeFam + HOGENOM + ...



eeFam



HOGENOM

\_PE3#

82

0.37

MACEUGS\_1045\_PE1#

HOGENOM\_1045\_PE1#

HOGENOM\_1045\_PE1#


HOGENOM\_1045\_PE1#

# TP53: plusieurs arbres de gènes

Ensembl


Phylome

Ensembl + PhylomeDB + TreeFam + HOGENOM + ...



**SUPERGENETREE !**

eeFam



HOGENOM

\_PE3#


82

0.37


MACEUGS\_1045\_PE1#

NORDB4\_3552\_E13#


# Clusters d'orthologues




# Clusters d'orthologues



# Clusters d'orthologues



# Clusters d'orthologues






# Clusters d'orthologues




# Problème du superarbre

## Arbres de gènes



## Arbre d'espèces






- **Étiquettes des gènes = espèces**
- **Copies multiples (paralogs)**
  - ▣ e.g.  $a_1, a_2, a_3$

# Problème du superarbre

## Arbres de gènes





- Objectif : trouver un superarbre de gènes qui les contient tous



# Problème du superarbre

## Arbres de gènes





- Objectif : trouver un superarbre de gènes qui les contient tous



# Problème du superarbre

## Arbres de gènes





- Objectif : trouver un superarbre de gènes qui les contient tous



# Problème du superarbre

## Arbres de gènes





- Objectif : trouver un superarbre de gènes qui les contient tous



# Problème du superarbre

## Arbres de gènes

- Objectif : trouver un superarbre de gènes qui les contient tous



# Superarbres de gènes

- Nos arbres sont dits **compatibles** s'il existe un superarbre les contenant tous
- Trouver un superarbre (ou déterminer l'incompatibilité) est un vieux problème
  - ▣ Algorithme BUILD (*Aho & al., 1981*)
- Qu'est-ce qui est différent avec les superarbres de **gènes** ?





# Superarbres de gènes

- Nos arbres sont dits **compatibles** s'il existe un superarbre les contenant tous
- Trouver un superarbre (ou déterminer l'incompatibilité) est un vieux problème
  - ▣ Algorithme BUILD (*Aho & al., 1981*)
- Qu'est-ce qui est différent avec les superarbres de **gènes** ?
  - ▣ Réconciliation






# Superarbres de gènes

- Il peut exister un nombre exponentiel de superarbres.
  - ▣ Lequel est le "meilleur"?
- Nous avons exploré des façons de choisir un tel superarbre selon les informations de l'arbre d'espèces  $S$
- Plus spécifiquement, nous utilisons la réconciliation avec  $S$  pour choisir un superarbre.




# Superarbre de gènes




# Superarbre de gènes






# Superarbre de gènes



**QUI EST LE  
MEILLEUR???**






# Superarbre de gènes






# Superarbre de gènes

S



# Superarbre de gènes

S




# Problème du superarbre de gènes

- **Entrée:** un ensemble d'arbres de gènes compatibles  $G = \{G_1, \dots, G_k\}$  et un arbre d'espèces  $S$
- **Sortie:** un superarbre de gènes  $G^*$  qui:
  - contient tous les arbres de  $G$
  - minimise  $\#dups(G^*, S)$

# Problème du superarbre de gènes


- **Entrée:** un ensemble d'arbres de gènes compatibles  $G = \{G_1, \dots, G_k\}$  et un arbre d'espèces  $S$
- **Sortie:** un superarbre de gènes  $G^*$  qui:
  - contient tous les arbres de  $G$
  - minimise  $\#dups(G^*, S)$
- NP-complet
- Difficile à approximer à un facteur  $n^{1-\varepsilon}$  près

# Idée de la réduction (en surface)









**Réduction du problème de "vertex coloring":  
trouver le min. # de couleurs pour colorier  $V(G)$  t.q.  
les sommets adjacents sont de couleur différente**

# Idée de la réduction (en surface)




**Réduction du problème de "vertex coloring":  
trouver le min. # de couleurs pour colorier  $V(G)$  t.q.  
les sommets adjacents sont de couleur différente**

# Idée de la réduction (en surface)




**On génère un arbre par sommet tel que  $v_i, v_j$  sont adjacents SSI  $G_i, G_j$  partagent une étiquette.**

# Idée de la réduction (en surface)




On génère un arbre par sommet tel que  $v_i, v_j$  sont adjacents SSI  $G_i, G_j$  partagent une étiquette.

# Idée de la réduction (en surface)



**Un coloriage est équivalent à partitionner les arbres en sous-arbres d'espèces disjointes.**


# Idée de la réduction (en surface)



**Un coloriage est équivalent à partitionner les arbres en sous-arbres d'espèces disjointes.**

**Chaque partie nécessite 0 duplications.**


# Idée de la réduction (en surface)



**Un coloriage est équivalent à partitionner les arbres en sous-arbres d'espèces disjointes.**

**Chaque partie nécessite 0 duplications.**

# Idée de la réduction (en surface)




# Algorithmes exacts

- Construction d'un superarbre par programmation dynamique sur les  $2^n$  sous-ensemble des  $n$  gènes
  - Nécessite un temps total de  $O(4^n)$
- Énumération de tous les superarbres possibles, calcul de la réconciliation sur chacun
  - Temps  $\Omega(n * n^{n/2})$
- Nouvel algorithme (non-publié)
  - Prog. dynamique sur les vecteurs de nœuds (1 nœud par arbre)
  - Temps  $O(4^k n^k)$ , où  $k = \text{nb d'arbres}$



# Conclusion

# Pipeline de correction d'arbres



# Travaux futurs

- Toutes les méthodes supposent que l'on a accès à un **arbre d'espèces S exact**
  - ▣ Comment modéliser des erreurs sur S (e.g. S non-binaire) ?
- Étendre les méthodes de la thèse à d'autres types d'événements, e.g. transferts horizontaux, coalescence profonde, ...
- **Correction** de relations d'orthologie et paralogie (et non seulement la validation).

# Travaux futurs

- Thèse axée sur les résultats théoriques.
- Comment les méthodes présentées peuvent-elles devenir pratiques?
  - ▣ Résolution de polytomies: logiciel ProfileNJ (avec E. Noutahi).
  - ▣ Correction de relations: comment inférer de bonnes relations d'orthologie/paralogie?
  - ▣ Superarbres: algorithme FPT? Restriction à des jeux de données biologiquement plausibles?

# Remerciements

- Nadia El-Mabrouk
- Tous les membres du LBIT !
- Chercheurs collaborateurs:
  - ▣ Cédric Chauve, Riccardo Dondi, Aïda Ouangraoua, Céline Scornovacca, Krister M. Swenson, Éric Tannier
- Copine, famille et amis !
- Supporteurs financiers: FRQNT, CRSNG, DIRO, FESP, Hydro-Québec