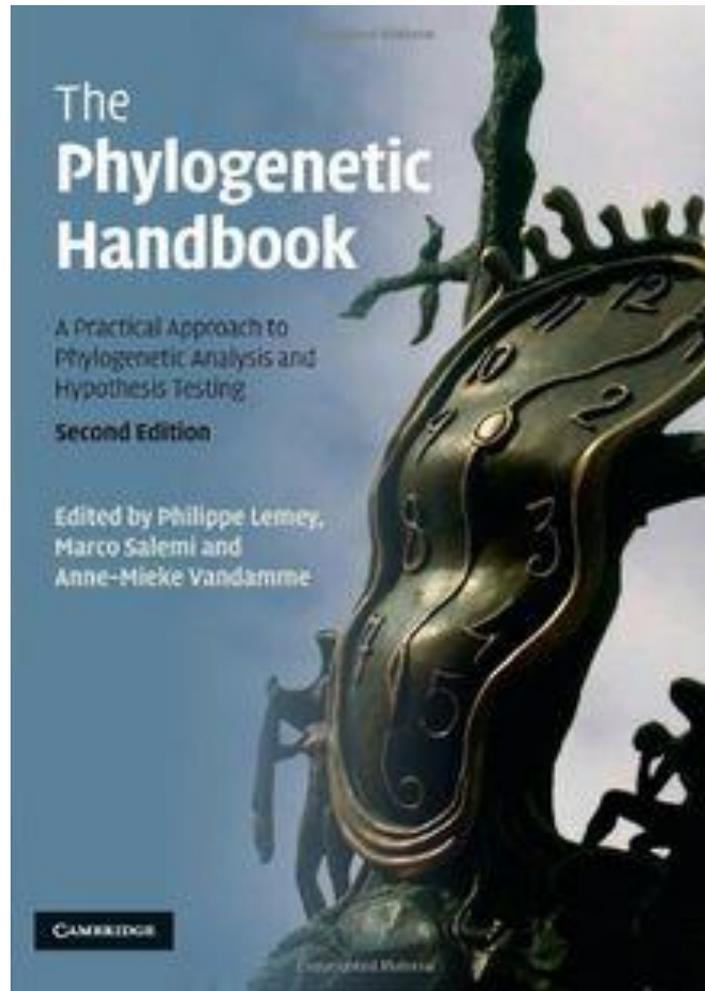


Notions élémentaires d'analyse phylogénétique moléculaire

Tamara Basta-Le Berre

tamara.basta-le-berre@u-psud.fr

Pour approfondir vos connaissances:



édition 2012

1. Phylogénétique moléculaire : définition et applications

2. Le processus d'analyse phylogénétique moléculaire

- Décider quel organisme et quelles séquences seront utilisés
- Obtenir les séquences soit expérimentalement soit à partir d'une base de données
- Assembler les séquences choisies dans un alignement multiple
- Utiliser cet alignement pour générer les arbres phylogénétiques

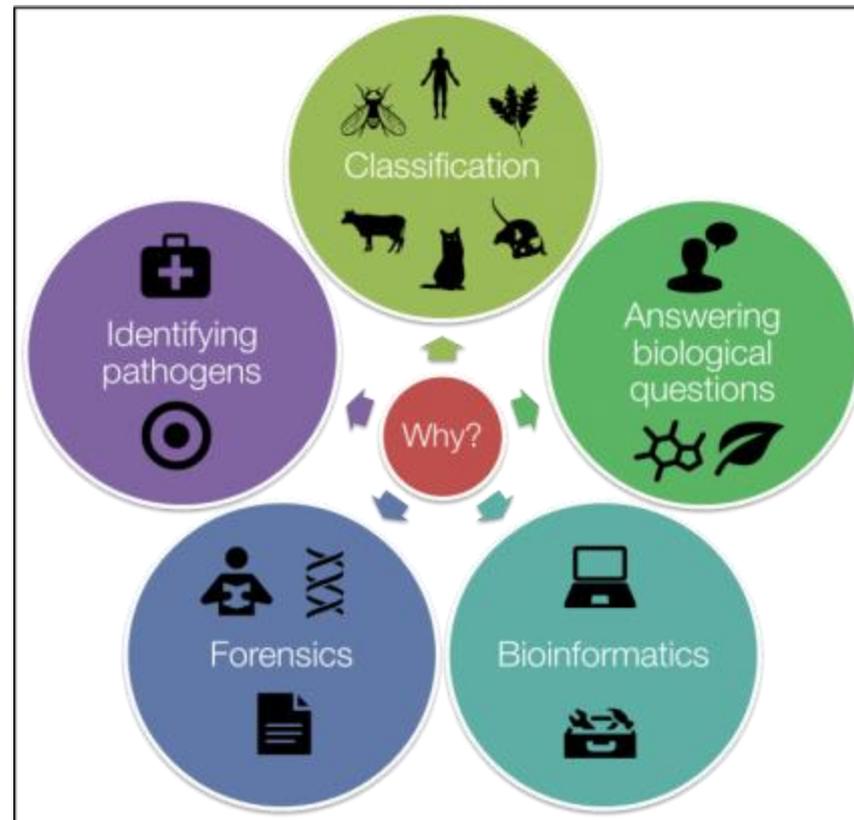
3. Algorithmes pour la phylogénie moléculaire

4. Classification cladistique

Phylogénétique moléculaire : définition et applications

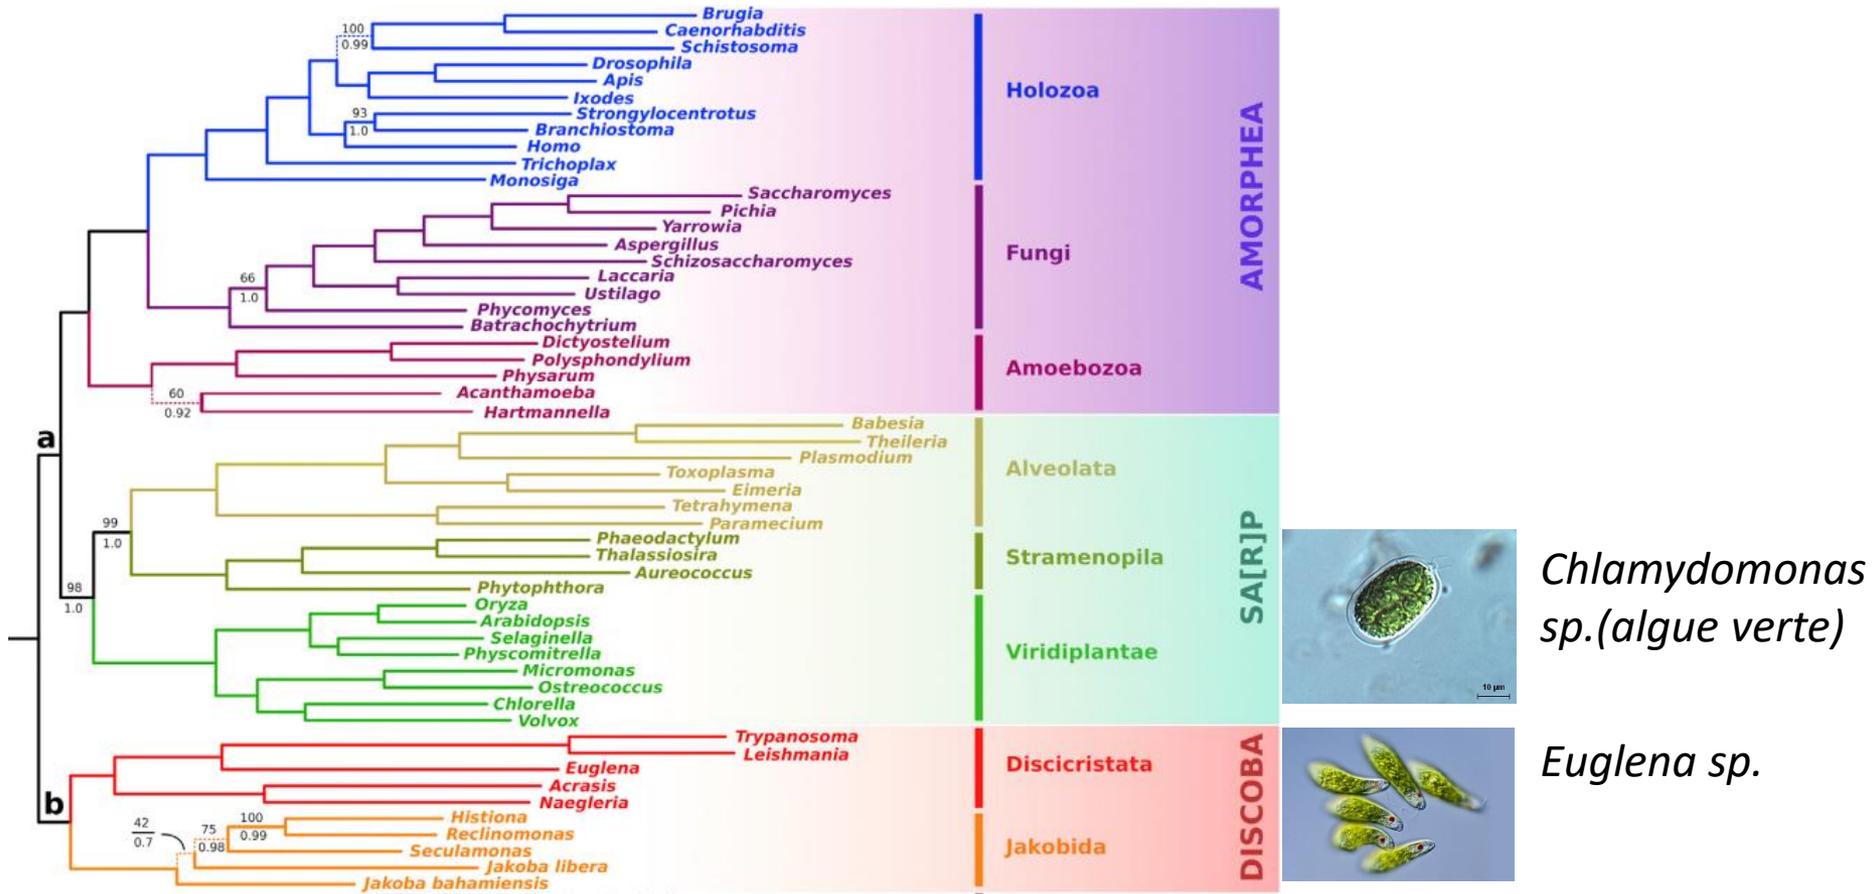
L'analyse phylogénétique moléculaire est l'activité qui consiste à reconstruire l'arbre phylogénétique d'un ensemble de séquences nucléotidiques ou protéiques d'intérêt.

Les applications sont fondamentales pour les études de biologie :



Phylogénétique moléculaire : définition et applications

* *Euglena* (protiste) a été utilisé par le passé (à tort) comme organisme modèle pour l'étude de la photosynthèse chez les plantes → compréhension de l'émergence des transitions majeurs en biologie (nouveau métabolisme).



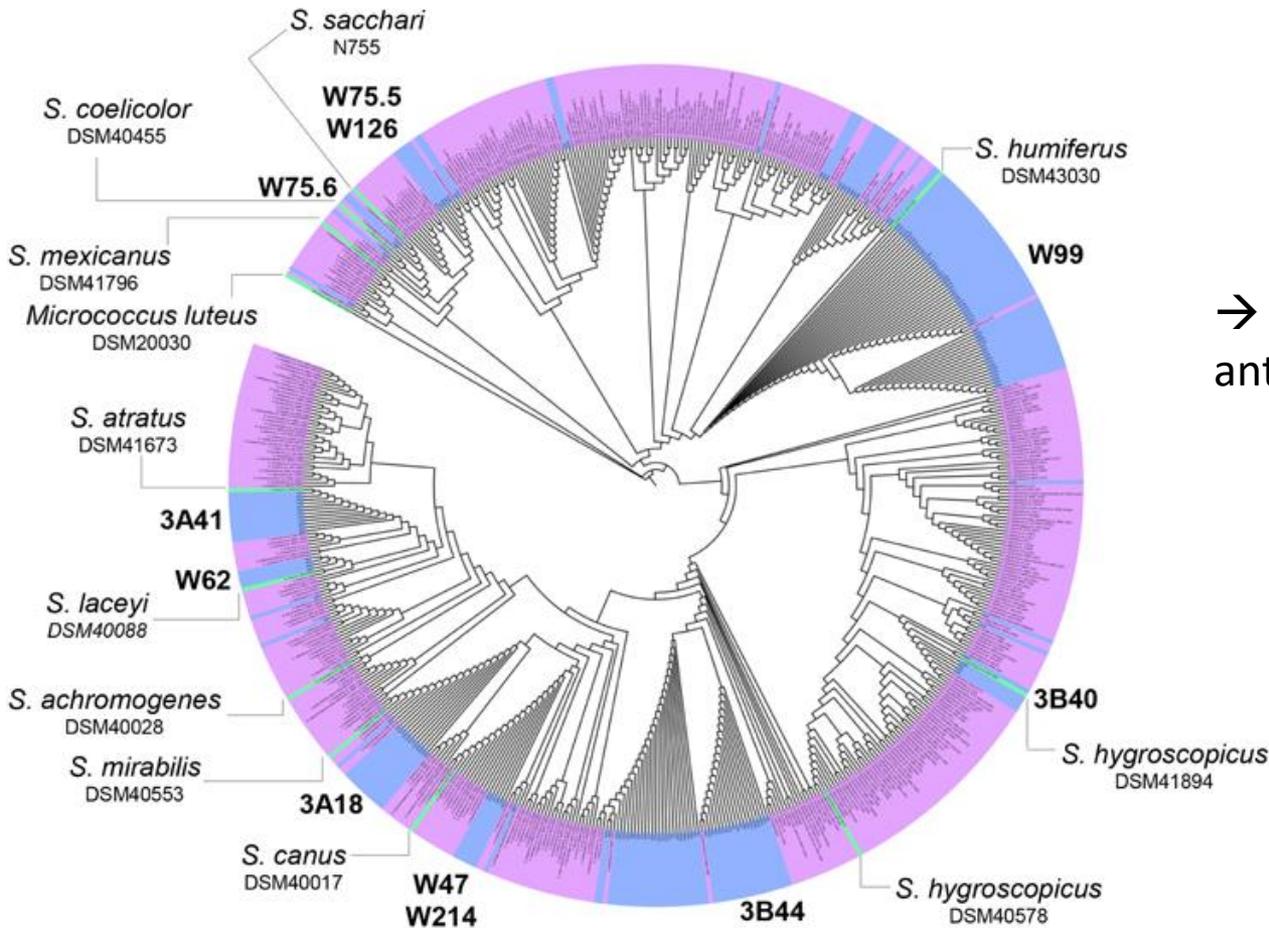
Phylogénétique moléculaire : des applications



Diversity and functions of volatile organic compounds produced by *Streptomyces* from a disease-suppressive soil

Viviane Cordovez^{1,2}, Victor J. Carrion¹, Desalegn W. Etalo¹, Roland Mumm^{3,4}, Hua Zhu⁵, Gilles P. van Wezel^{1,5} and Jos M. Raaijmakers^{1,5*}

→ Recherche ciblée de nouveaux antibiotiques



Phylogénétique moléculaire : définition et applications

SCIENCE ADVANCES | RESEARCH ARTICLE

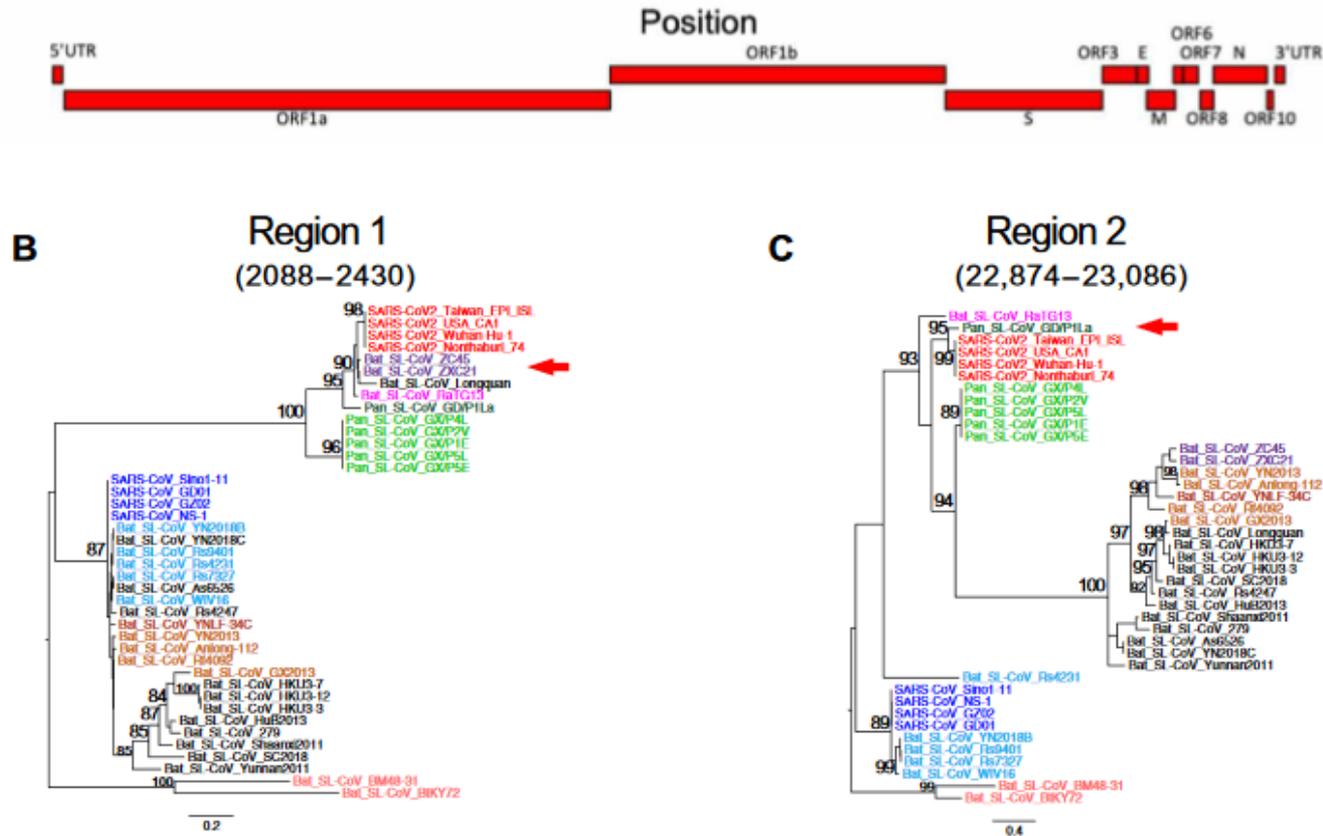
July, 2020

CORONAVIRUS

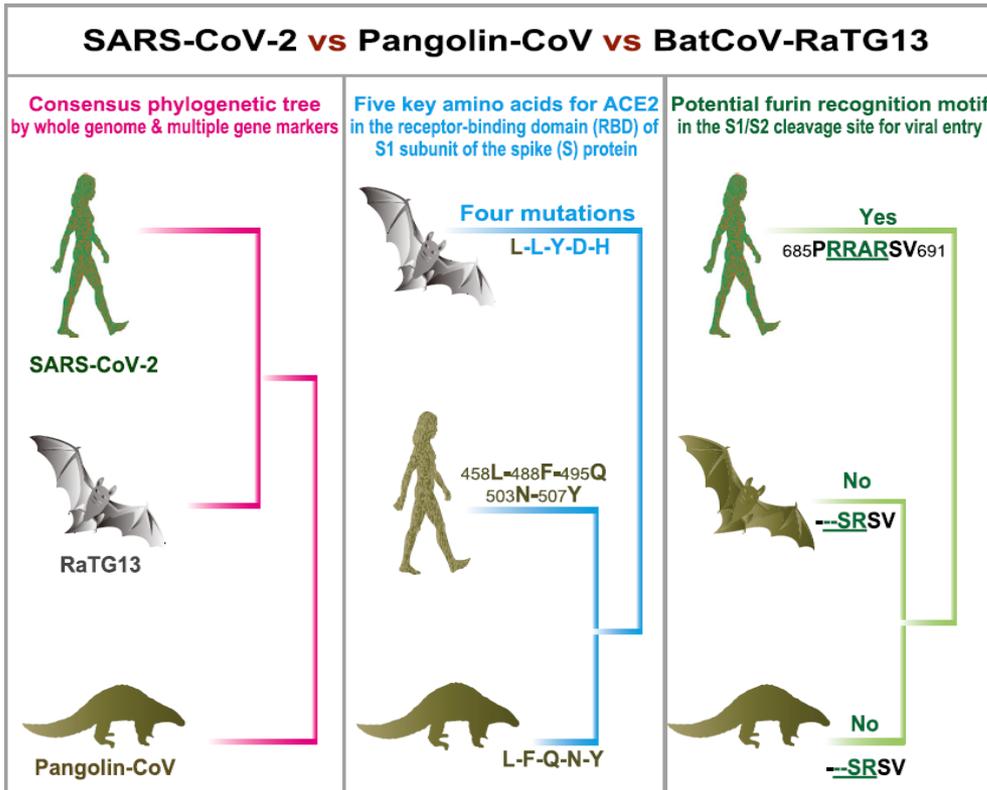
Emergence of SARS-CoV-2 through recombination and strong purifying selection

Xiaojun Li^{1*}, Elena E. Giorgi^{2*}, Manukumar Honnayakanahalli Marichannegowda¹, Brian Foley², Chuan Xiao³, Xiang-Peng Kong⁴, Yue Chen¹, S. Gnanakaran^{2,5}, Bette Korber^{2,5}, Feng Gao^{1,6†}

Copyright © 2020
The Authors, some
rights reserved;
exclusive licensee
American Association
for the Advancement
of Science. No claim to
original U.S. Government
Works. Distributed



Phylogénétique moléculaire : définition et applications



Understanding the origins of SARS-CoV-2 is critical for deterring future zoonosis, discovering new drugs, and developing a vaccine

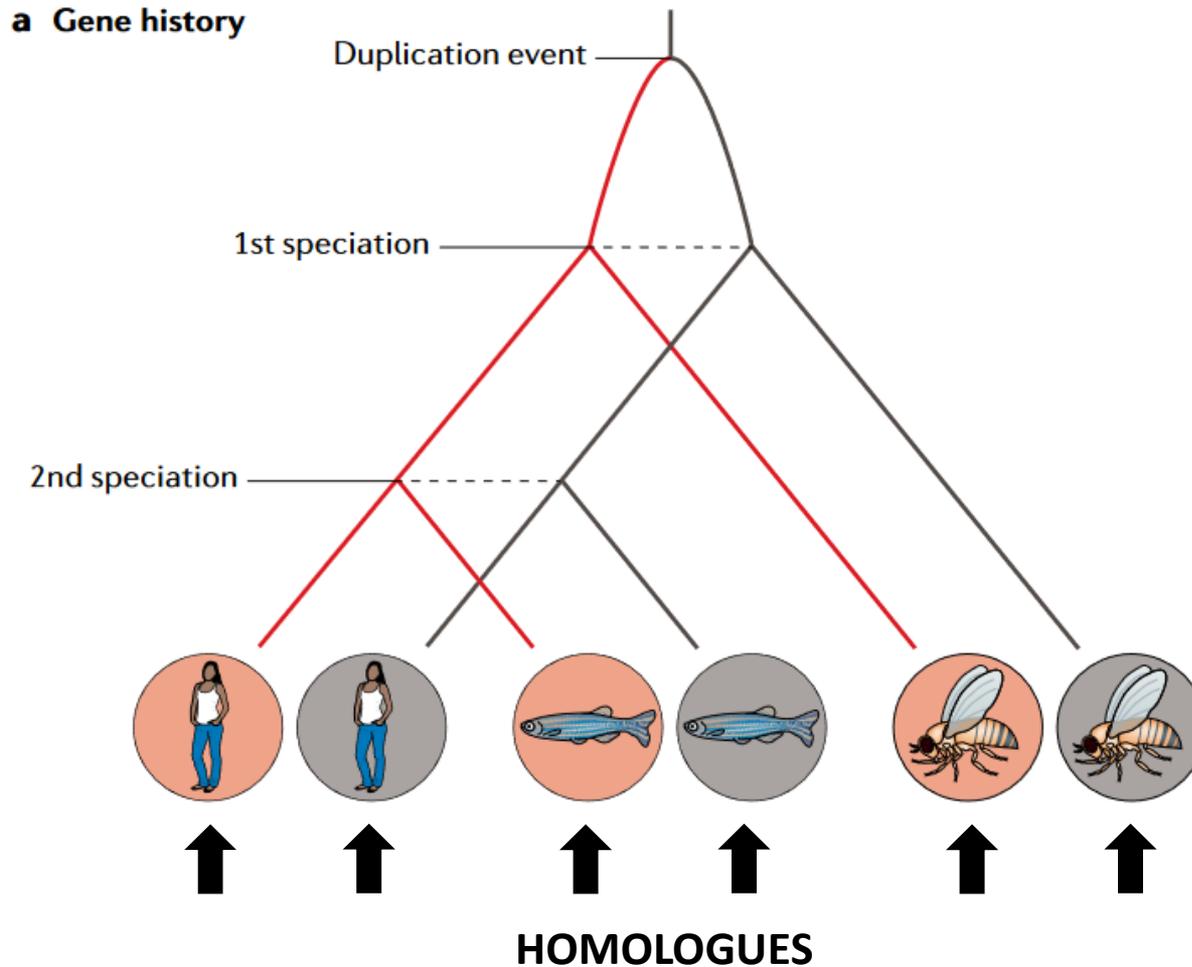
Zhang et al., 2020, Current Biology 30, 1346–1351

Le processus d'analyse phylogénétique moléculaire

- 1. Décider quel organisme et quelles séquences seront utilisés**
2. Obtenir les séquences soit expérimentalement soit à partir d'une base de données
3. Assembler les séquences choisies dans un alignement multiple
4. Utiliser cet alignement pour générer les arbres phylogénétiques

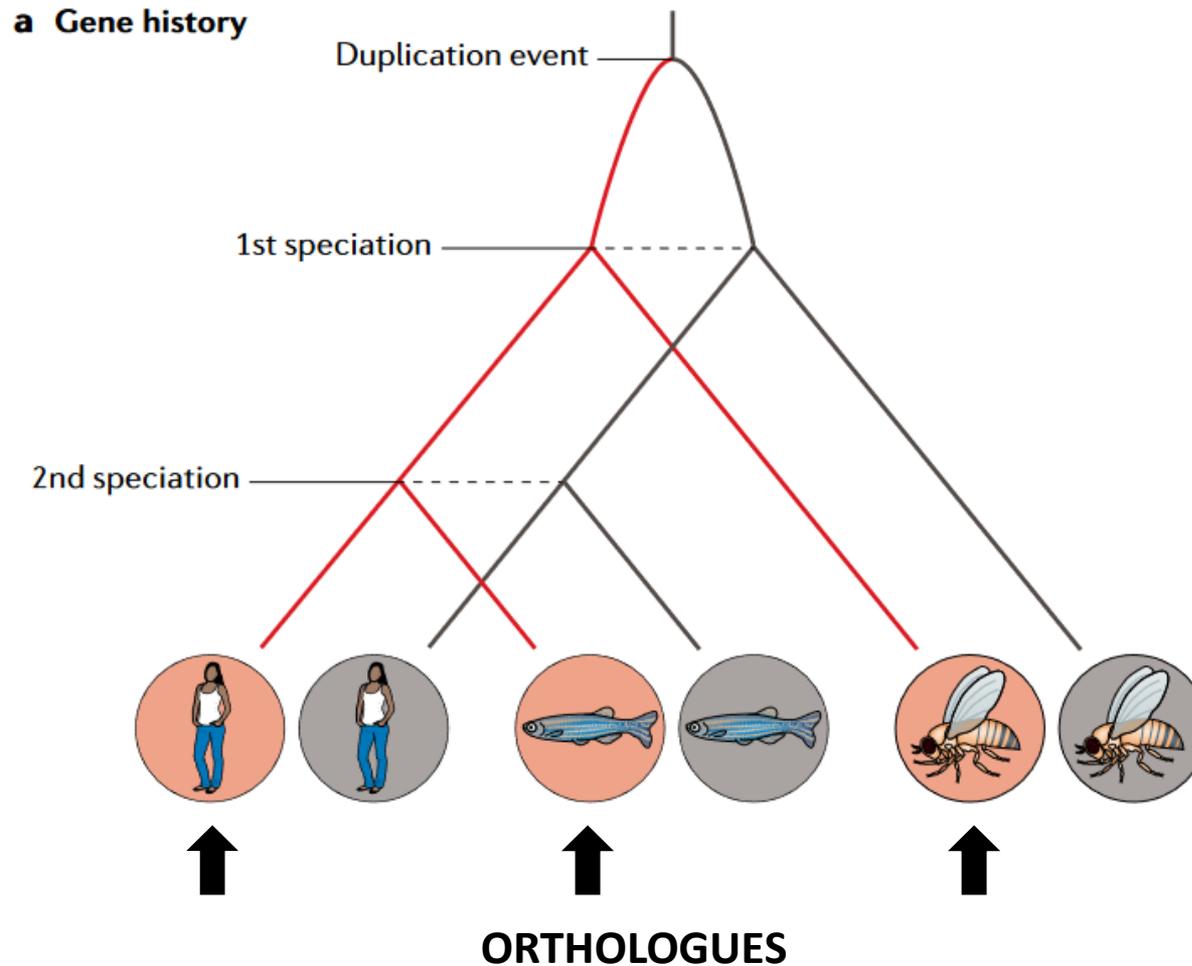
Choix d'organisme et des séquences

→ Gènes **homologues** – ayant un ancêtre en commun



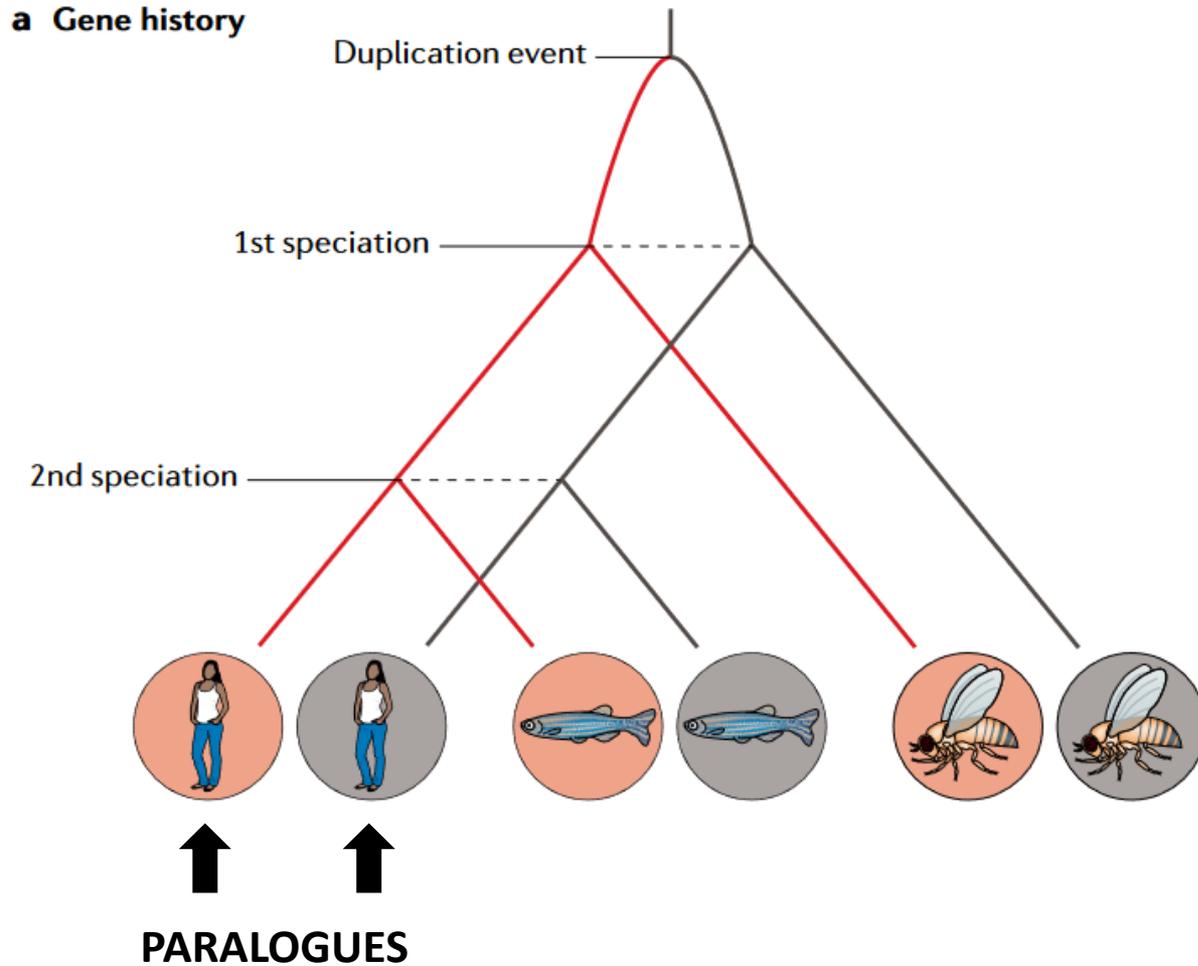
Choix d'organisme et des séquences

→ gènes **orthologues** – les gènes homologues présents chez des espèces différentes



Choix d'organisme et des séquences

→ Gènes **paralogues** – les gènes homologues ayant subi une duplication et que l'on retrouve au sein d'une même espèce



Choix d'organisme et des séquences

- séquences **homologues** – ayant un ancêtre en commun
- 2 séquences nucléotidiques non-homologues présentent 25%-50% d'identité
- 2 séquences protéiques non-homologues présentent jusqu'au 20% d'identité

ATCGTCGTTTATGTCCCCAA

Gène 1

ACCGTCGATAATGTGGGCTT

Gène 2

} 40 % identité de séquence → pas assez d'information pour en déduire la relation de parenté

ATGGTCGATAATGTCCCCAA

Gène 1

ATCGTCGTTTATGTCCCCAA

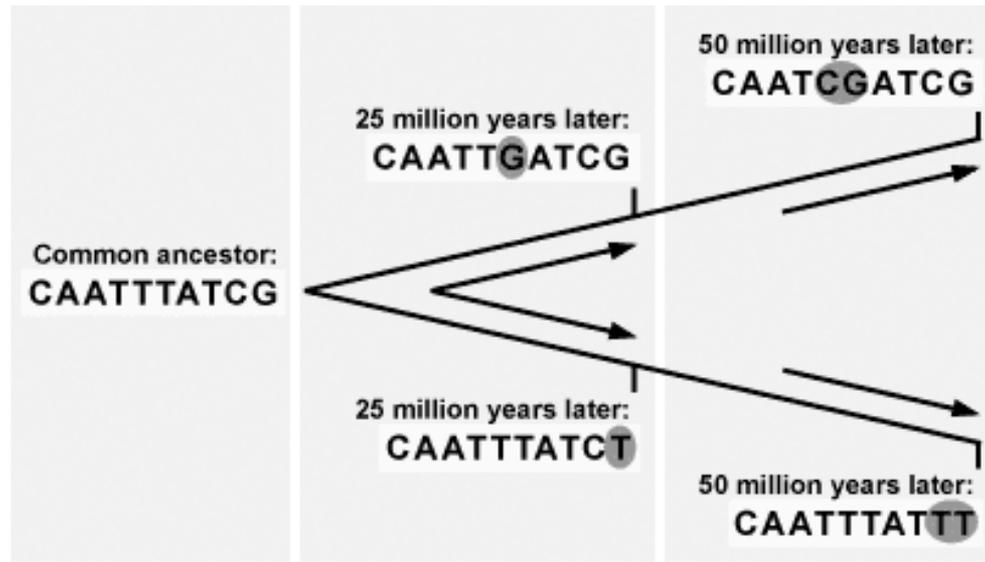
Gène 2

} 80% identité de séquence → ancêtre récent
→ séquences vraisemblablement homologues

- En général utiliser les séquences nucléotidiques avec > 60% identité ou les séquences protéiques avec > 25% d'identité

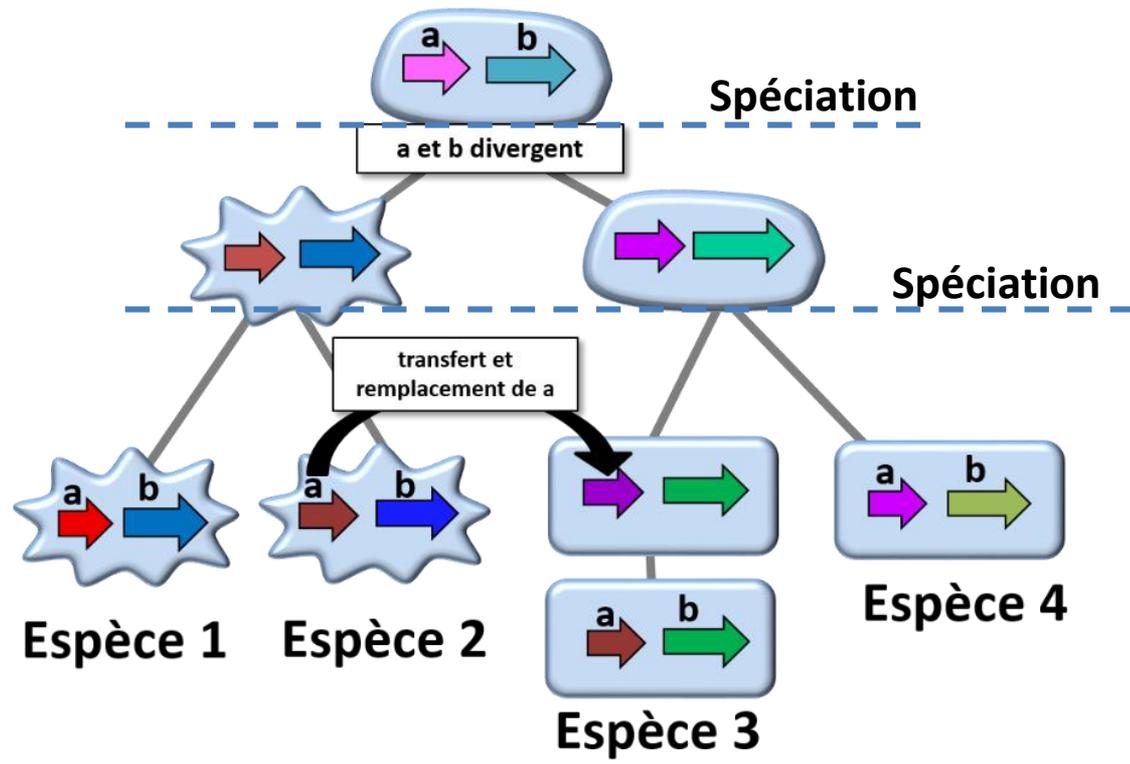
Choix d'organisme et des séquences

→ séquences qui se comportent comme une horloge moléculaire (le taux moyen de mutation sur des longues périodes est constant) → permet de mesurer quand dans le passé deux séquences ont divergé à partir d'un ancêtre commun (CM1)



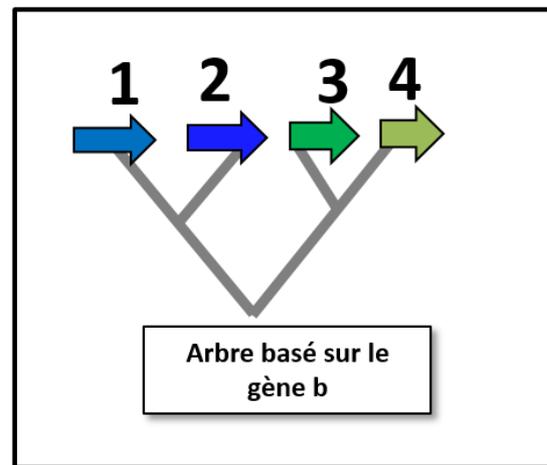
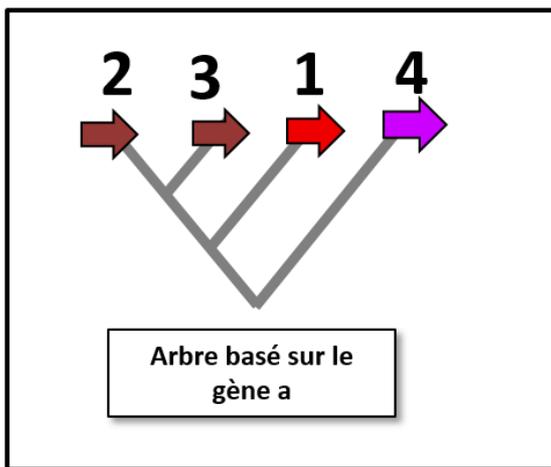
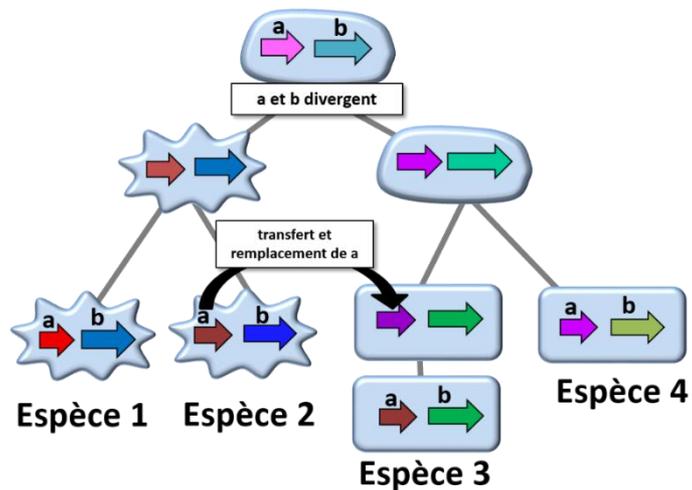
Choix d'organisme et des séquences

→ Pour étudier l'histoire évolutive des espèces les gènes utilisés doivent être des **orthologues** et doivent se transmettre verticalement au sein des lignées (absence des transferts latéraux)



→ L'arbre obtenu à partir des séquences a = arbre obtenu à partir des séquences b?

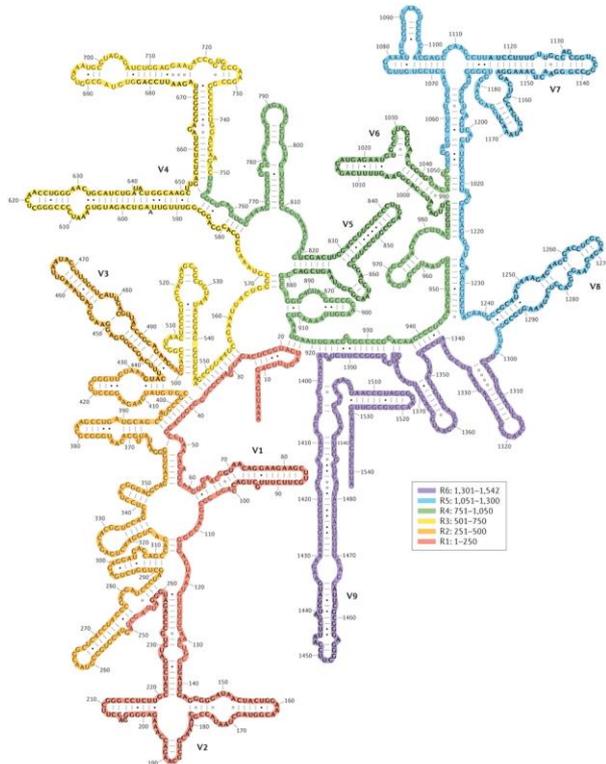
Choix d'organisme et des séquences



Choix d'organisme et des séquences

- la fonction de la séquence doit rester **conservé**
- La séquence doit comporter un **signal phylogénétique robuste** (être suffisamment longue pour comporter les informations statistiquement significatives, avoir un nombre suffisant des variations de séquence)
- l'absence du transfert horizontal des gènes – le gène doit être **hérité verticalement** de la cellule mère aux cellules filles
- si possible choisir le gène pour lequel un **grand nombre de séquences** est déjà disponible

Choix d'organisme et des séquences



Nature Reviews | Microbiology

« the gold standard »: le gène codant pour la 16S rRNA

-présent dans toutes les cellules

-a la même fonction dans toutes les cellules

-comporte 1500 – 2000 nucléotides – assez pour être statistiquement significatif

-comporte environ 50 hélices et 500 nucléotides qui évoluent indépendamment

-suffisamment conservé pour l'aligner facilement et précisément

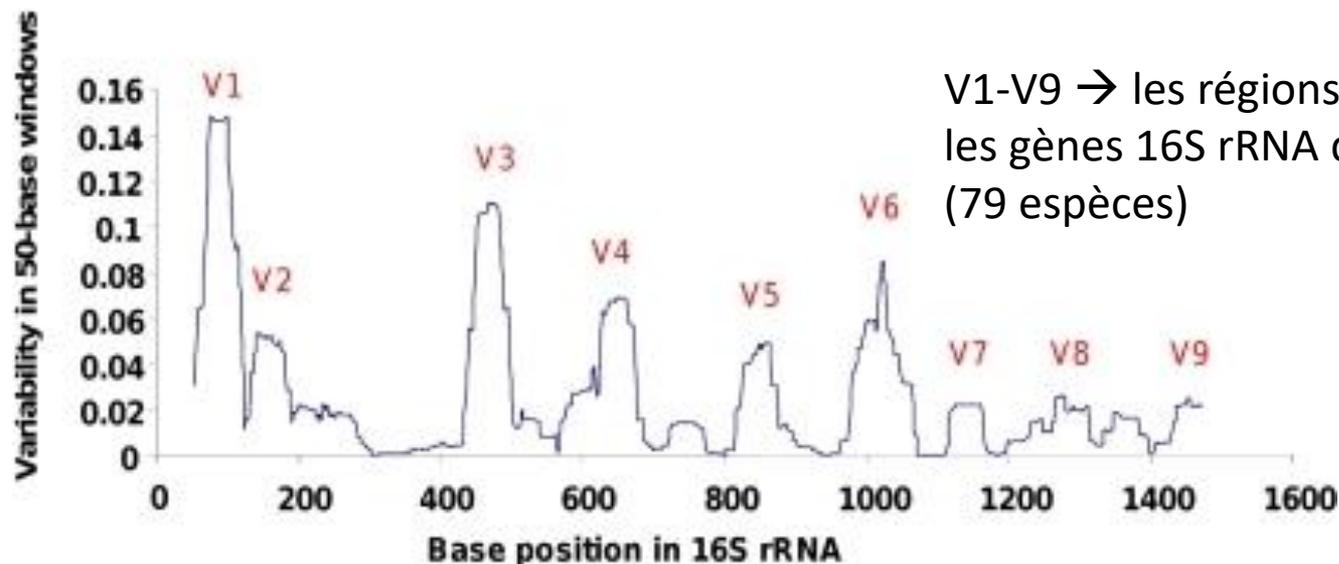
- ne se transmet pas horizontalement (très rare)

Choix d'organisme et des séquences

-comporte des régions qui évoluent *lentement* et d'autres qui évoluent *rapidement*

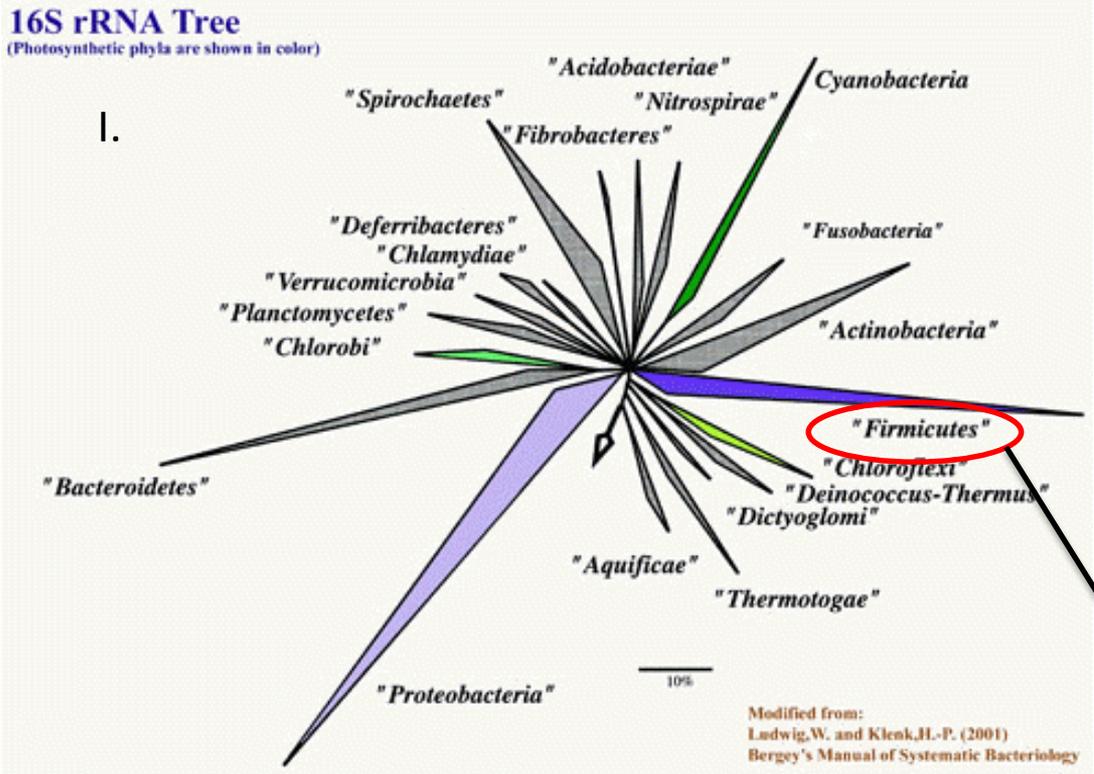
←
utile pour déterminer la
phylogénie des espèces
éloignées

→
utile pour déterminer
la phylogénie des
espèces proches



V1-V9 → les régions hypervariables parmi
les gènes 16S rRNA des *Pseudomonas* sp.
(79 espèces)

Choix d'organisme et des séquences



-I. au départ choisir les séquences qui couvrent l'ensemble des phylums d'un domaine

-II. puis restreindre le choix à des séquences proches du phylum d'intérêt

II. générer un arbre des firmicutes

Le processus d'analyse phylogénétique moléculaire

1. Décider quel organisme et quelles séquences seront utilisés
2. **Obtenir les séquences soit expérimentalement soit à partir d'une base de données**
3. Assembler les séquences choisies dans un alignement multiple
4. Utiliser cet alignement pour générer les arbres phylogénétiques

<http://www.ncbi.nlm.nih.gov/> → National Center for Biotechnology Information

NCBI Resources How To

NCBI National Center for Biotechnology Information

All Databases

Search

- NCBI Home
- Resource List (A-Z)
- All Resources
- Chemicals & Bioassays
- Data & Software
- DNA & RNA
- Domains & Structures
- Genes & Expression
- Genetics & Medicine
- Genomes & Maps
- Homology
- Literature
- Proteins
- Sequence Analysis
- Taxonomy
- Training & Tutorials
- Variation

Welcome to NCBI

The National Center for Biotechnology Information advances science and health by providing access to biomedical and genomic information.

[About the NCBI](#) | [Mission](#) | [Organization](#) | [NCBI News](#) | [Blog](#)

Submit

Deposit data or manuscripts into NCBI databases



Download

Transfer NCBI data to your computer



Learn

Find help documents, attend a class or watch a tutorial



Develop

Use NCBI APIs and code libraries to build applications



Analyze

Identify an NCBI tool for your data analysis task



Research

Explore NCBI research and collaborative projects



Popular Resources

[PubMed](#)

[Bookshelf](#)

[PubMed Central](#)

[PubMed Health](#)

[BLAST](#)

[Nucleotide](#)

[Genome](#)

[SNP](#)

[Gene](#)

[Protein](#)

[PubChem](#)

NCBI Announcements

December 17th webinar: 1000 Genomes Project I

On Thursday December staff will demonstrate how

Registration open for Dec NCBI Minute: "New Face Search in dbGaP Provide

TUTORIELS

Recherche de séquences dans le NCBI
ORFinder

Recherche de séquences dans UniProt

Recherche de séquences homologues par BLAST

Alignement de séquences par Clustal Omega

Choix de sites: Gblocks

Construction d'arbres phylogénétiques avec IQ-Tree

Edition d'arbres avec iTOL

AlphaFold Protein Structure Database

ColabFold – utilisation d'AlphaFold 2

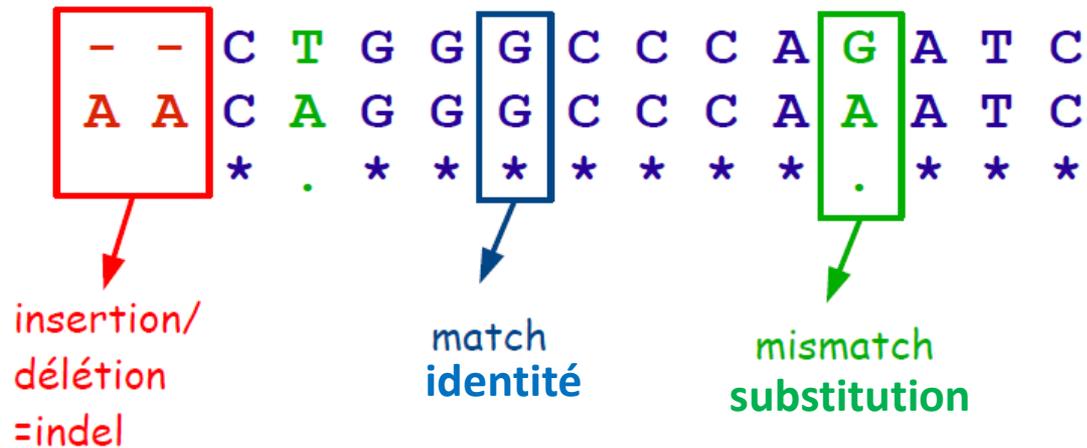
Foldseek – recherche des structures similaires dans le AFDB

Le processus d'analyse phylogénétique moléculaire

1. Décider quel organisme et quelles séquences seront utilisés
2. Obtenir les séquences soit expérimentalement soit à partir d'une base de données
- 3. Assembler les séquences choisies dans un alignement multiple**
4. Utiliser cet alignement pour générer les arbres phylogénétiques

Un alignement qu'est ce que c'est?

→ écriture de deux (ou plus) séquences, l'une sur l'autre de façon à faire apparaître des identités (ou similitudes)



Pour répondre à la question: "quelle est la **similarité** entre 2 séquences ?
et donc: est-ce que ces deux séquences sont **homologues** ? » → **MEME FONCTION**

Comment quantifier la similarité de séquences?

Matrice de score

exemple: on postule qu'une identité vaut +2 et une substitution vaut -1

→ ce postulat peut se résumer sous forme de matrice de scores:

	A	B	C	D	E
A	2	-1	-1	-1	-1
B	-1	2	-1	-1	-1
C	-1	-1	2	-1	-1
D	-1	-1	-1	2	-1
E	-1	-1	-1	-1	2

A	B	C	D	E
A	B	C	D	E
2	2	2	2	2
Score =	10			

A	B	C	D	E
A	A	A	A	A
2	-1	-1	-1	-1
Score =	-2			

→ quelles sont les critères pour déterminer les valeurs que l'on utilise pour les séquences biologiques?

Exemples de matrices de score

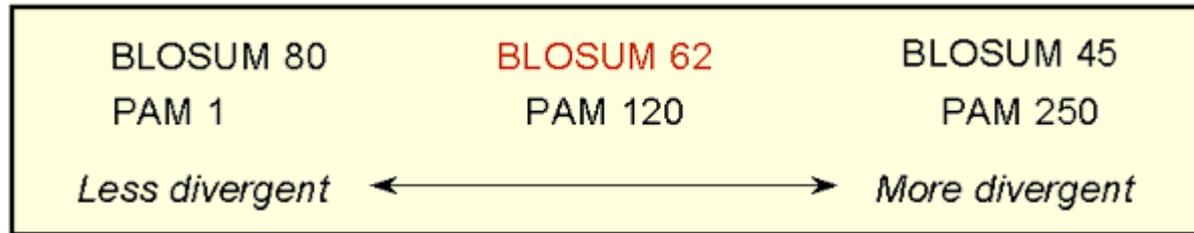
BLOSUM62 : fréquences de substitution d'acides aminés dans des blocs de séquence conservés, sans insertion, présentant au maximum 62% d'identité de séquence.

	C	S	T	P	A	G	N	D	E	Q	H	R	K	M	I	L	V	F	Y	W	
C	9																				C
S	-1	4																			S
T	-1	1	5																		T
P	-3	-1	-1	7																	P
A	0	1	0	-1	4																A
G	-3	0	-2	-2	0	6															G
N	-3	1	0	-2	-2	0	6														N
D	-3	0	-1	-1	-2	-1	1	6													D
E	-4	0	-1	-1	-1	-2	0	2	5												E
Q	-3	0	-1	-1	-1	-2	0	0	2	5											Q
H	-3	-1	-2	-2	-2	-2	1	-1	0	0	8										H
R	-3	-1	-1	-2	-1	-2	0	-2	0	1	0	5									R
K	-3	0	-1	-1	-1	-2	0	-1	1	1	-1	2	5								K
M	-1	-1	-1	-2	-1	-3	-2	-3	-2	0	-2	-1	-1	5							M
I	-1	-2	-1	-3	-1	-4	-3	-3	-3	-3	-3	-3	-3	1	4						I
L	-1	-2	-1	-3	-1	-4	-3	-4	-3	-2	-3	-2	-2	2	2	4					L
V	-1	-2	0	-2	0	-3	-3	-3	-2	-2	-3	-3	-2	1	3	1	4				V
F	-2	-2	-2	-4	-2	-3	-3	-3	-3	-3	-1	-3	-3	0	0	0	-1	6			F
Y	-2	-2	-2	-3	-2	-3	-2	-3	-2	-1	2	-2	-2	-1	-1	-1	-1	3	7		Y
W	-2	-3	-2	-4	-3	-2	-4	-4	-3	-2	-2	-3	-3	-1	-3	-2	-3	1	2	11	W
C		S	T	P	A	G	N	D	E	Q	H	R	K	M	I	L	V	F	Y	W	

Exemples de matrices de score

	C	S	T	P	A	G	N	D	E	Q	H	R	K	M	I	L	V	F	Y	W					
C	9																				C				
S	-1	4									substitution neutre														S
T	-1	1	5								substitution sur-représentée, probablement favorable														T
P	-3	-1	-1	7																					P
A	0	1	0	-1	4																				A
G	-3	0	-2	-2	0	6																			G
N	-3	1	0	-2	-2	0	6				substitution sous-représentée, probablement défavorable														N
D	-3	0	-1	-1	-2	-1	1	6																	D
E	-4	0	-1	-1	-1	-2	0	2	5																E
Q	-3	0	-1	-1	-1	-2	0	0	2	5															Q
H	-3	-1	-2	-2	-2	-2	1	-1	0	0	8										H				
R	-3	-1	-1	-2	-1	-2	0	-2	0	1	0	5									R				
K	-3	0	-1	-1	-1	-2	0	-1	1	1	-1	2	5								K				
M	-1	-1	-1	-2	-1	-3	-2	-3	-2	0	-2	-1	-1	5							M				
I	-1	-2	-1	-3	-1	-4	-3	-3	-3	-3	-3	-3	-3	1	4						I				
L	-1	-2	-1	-3	-1	-4	-3	-4	-3	-2	-3	-2	-2	2	2	4					L				
V	-1	-2	0	-2	0	-3	-3	-3	-2	-2	-3	-3	-2	1	3	1	4				V				
F	-2	-2	-2	-4	-2	-3	-3	-3	-3	-3	-1	-3	-3	0	0	0	-1	6			F				
Y	-2	-2	-2	-3	-2	-3	-2	-3	-2	-1	2	-2	-2	-1	-1	-1	-1	3	7		Y				
W	-2	-3	-2	-4	-3	-2	-4	-4	-3	-2	-2	-3	-3	-1	-3	-2	-3	1	2	11	W				
C																					C				

Quelle matrice choisir?



utiliser pour l'alignement des séquences très conservées - évolutivement très proches (haut % identité)

BLOSUM 62 matrice utilisée par défaut par nombreux algorithmes d'alignement (EMBOSS, BLAST)

utiliser pour l'alignement des séquences peu conservées

Comment peut on aligner deux séquences?

→ alignement **LOCAL**:

i) cherche à repérer, dans deux séquences, uniquement des régions de plus grande similitude

EMBOSS – Matcher, Water, **BLAST**

Algorithme de Smith et Waterman, 1981:

i) n'importe quelle case de la matrice de comparaison peut être considérée comme point de départ

ii) tout score somme qui devient inférieur à zéro stoppe la progression du calcul

Page de résultats - score

score est normalisé (bits), il permet de comparer 2 alignements, et de dire lequel est le meilleur → oui mais quel score = homologie?

```
> sp|Q92125.1|ANXA7\_XENLA  RecName: Full=Annexin A7; AltName: Full=Annexin-7; AltName: Full=Annexin VII; AltName: Full=Synexin  
Length=512
```

```
GENE ID: 397854 LOC397854 | annexin VII [Xenopus laevis]  
(10 or fewer PubMed links)
```

```
Score = 40.0 bits (92), Expect = 0.011, Method: Compositional matrix adjust.  
Identities = 45/128 (35%), Positives = 57/128 (44%), Gaps = 34/128 (26%)
```

```
Query 26 PKPGGWNTGGSRYPGQGSPGGNRYPPQGGGGWGQPHG-----GGWGQ 67  
P PGG+ G YPG +PG P GG G+G P G GG+G  
Sbjct 67 PAPGGYPGGMPSYPG--APGFGA--PAGGQGYGAPPGAPAYGVPGYGGPGFNAPAGGYGA 122  
  
Query 68 PHGGGWGQPHGGGWGQPHGGGWGQGGGTHSQWNKPSKPKTNMKHMAGAAAAGAVVGGGLGG 127  
P+ GG+G P GG+G P GG G GG +++PS GA G + G + G  
Sbjct 123 PNAGGFGVPPAGGYGSP--GGAPGYGG-----FSQPS-----SQSYGAGGPGQMPGQMPG 170  
  
Query 128 YMLGSAMS 135  
M G A S  
Sbjct 171 QMPGQAPS 178
```

longueur: 128
identité: 35%
gap: 26%

```
> sp|Q92125.1|ANXA7\_XENLA  RecName: Full=Annexin A7; AltName: Full=Annexin-7; AltName: Full=Annexin VII; AltName: Full=Synexin  
Length=512
```

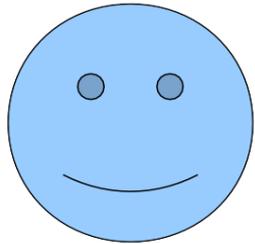
```
GENE ID: 397854 LOC397854 | annexin VII [Xenopus laevis]  
(10 or fewer PubMed links)
```

```
Score = 34.7 bits (76), Expect = 0.62, Method: Compositional matrix adjust.  
Identities = 34/86 (39%), Positives = 41/86 (47%), Gaps = 23/86 (26%)
```

```
Query 26 PKPGGWNTGGSRYPGQGSPGGNRYPPQGGGGWGQPHG-----GGWGQ 67  
P PGG+ G YPG +PG P GG G+G P G GG+G  
Sbjct 67 PAPGGYPGGMPSYPG--APGFGA--PAGGQGYGAPPGAPAYGVPGYGGPGFNAPAGGYGA 122  
  
Query 68 PHGGGWGQPHGGGWGQPHGGGWGQGG 93  
P+ GG+G P GG+G P GG G GG  
Sbjct 123 PNAGGFGVPPAGGYGSP--GGAPGYGG 147
```

longueur: 86
identité: 39%
gap: 26%

E-value - définition



est ce qu'un score de
46.6 bits
est le signe d'une véritable
homologie ?

Si les 2 séquences n'avaient
aucune homologie,
est ce qu'on aurait pu obtenir
un score de 46.6 ?

E-value de X


=

on s'attendrait à trouver X alignements de score équivalent **purement par chance** contre une banque de données de **taille équivalente**

$s = 46 \succ E\text{-value} = 4e-4$: je m'attends à trouver en moyenne 0.0004 alignements de score 46 purement par hasard (si je blaste 2500 séquences aléatoires, j'en obtiendrai ~ 1)

$s = 267 \succ E\text{-value} = 1e-70$: il faut que je blaste $1e70$ séquences aléatoires avant de tomber au hasard sur un alignement de cette qualité ...

E-value - définition



faux-positifs: on a un alignement, mais les séquences ne sont pas homologues

Alignement multiple de séquences

- En général, le biologiste dispose de multiples séquences d'intérêt
- Besoin d'un alignement multiple pour identifier les résidus conservés (importants pour la fonction) et inférer un arbre phylogénétique

```
Q9XSN2 HBA1_EOGR 1 VLSAADKTNVKAAWSKVGGNAGEFGAEALERMLF LGFPTTKTYFPHF.DLSHGSAQVKAHGKKVGD
Q9XSK1 HBA4_BUBBU 1 VLSAADKSNVKAAWGKVGGAADYGAELERMLF LSFPTTKTYFPHF.DLSHGSAQVKGHGAKVAN
Q7M3B8 HBA1_HAPGR 1 VLSSADKTNIKTAWGAIIGSHAADHGAELERMLF LSFPTTKTYFPHF.DMSHGSGQI.AHGKKVAD
P83124 HBA1_GEONI 1 MLTEDDKQLIQHVWETVLEHQEDFGAEALERMLF TVYPSTKTYFPHF.DLHHGSEQIRHGHGKKVVG
P18974 HBA1_IGUIG 1 VLTEDDKNHIRAIWGHVDNNPEAFGVEALTRLFLAYPATKTYFAHF.DLNPGSAQIKAHGKKVVD
Q9PVM4 HBAA_SERQU 1 SLSGKDKSVVKAFWDKMSPKSAEIGAELGRMLTVYPTTKTYFSHWADVGPDSAQVKKHGATIMA
P20244 HBA1_TORMA 1 VLSEGNKKAIKNL LQKIHSQTEVLGAELARLFECHPQTKSYF PKFSGFSANDKRVKHGALV LK
```

- On recherche un alignement global, cependant inexploitable en pratique: pour 5 séquences de 500 AA mémoire requise est de 10 Po (10^{15} octets)
- Alignements multiples utilisent toujours des heuristiques (la solution n'est pas toujours optimale et nécessite d'optimiser « à la main »)

Alignement multiple de séquences

→ Choix de programme d'alignement (<https://www.ebi.ac.uk/jdispatcher/msa>):

Clustal Omega

New MSA tool that uses seeded guide trees and HMM profile-profile techniques to generate alignments. Suitable for medium-large alignments.

[Launch Clustal Omega](#)

Kalign

Very fast MSA tool that concentrates on local regions. Suitable for large alignments.

[Launch Kalign](#)

MAFFT

MSA tool that uses Fast Fourier Transforms. Suitable for medium-large alignments.

[Launch MAFFT](#)

MUSCLE

Accurate MSA tool, especially good with proteins. Suitable for medium alignments.

[Launch MUSCLE](#)

MView

Transform a Sequence Similarity Search result into a Multiple Sequence Alignment or reformat a Multiple Sequence Alignment using the MView program.

[Launch MView](#)

T-Coffee

Consistency-based MSA tool that attempts to mitigate the pitfalls of progressive alignment methods. Suitable for small alignments.

[Launch T-Coffee](#)

WebPRANK

The EBI has a new phylogeny-aware multiple sequence alignment program which makes use of evolutionary information to help place insertions and deletions. Try it out at [WebPRANK](#).

Alignement multiple de séquences

→ Choix de programme d'alignement en fonction du nombre de séquences leur degré de conservation et la qualité de l'alignement:

Tableau 5.6 - Quelques programmes d'alignement multiple.

	Rapidité	Séquences proches	Séquences éloignées	Qualité
Multalin	++	+++	+	++
Clustal W	+	++	++	+++
Muscle	+++	+++	+	+++
MAFFT	++	++	+	+++
T-Coffee	+	+	+++	+++
DIALIGN	+	+	+++	+

Le processus d'analyse phylogénétique moléculaire

1. Décider quel organisme et quelles séquences seront utilisés
2. Obtenir les séquences soit expérimentalement soit à partir d'une base de données
3. Assembler les séquences choisies dans un alignement multiple
→ **extraire les positions pertinentes (GBlocks)**
4. Utiliser cet alignement pour générer les arbres phylogénétiques

Le processus d'analyse phylogénétique moléculaire

1. Décider quel organisme et quelles séquences seront utilisés
2. Obtenir les séquences soit expérimentalement soit à partir d'une base de données
3. Assembler les séquences choisies dans un alignement multiple
→ extraire les positions pertinentes (GBlocks)
4. **Utiliser cet alignement pour générer les arbres phylogénétiques**

Calcul de la distance évolutive

Organism	Sequence	Analysis
A	CGUAGACCUGAC	For A → B, three differences occur out of a total of twelve; thus $\frac{3}{12} = 0.25$
B	CCUAGAGCUGGC	
C	CCAAGACGUGGC	
D	GCUAGAUGUGCC	

(a) Sequence alignment and analysis

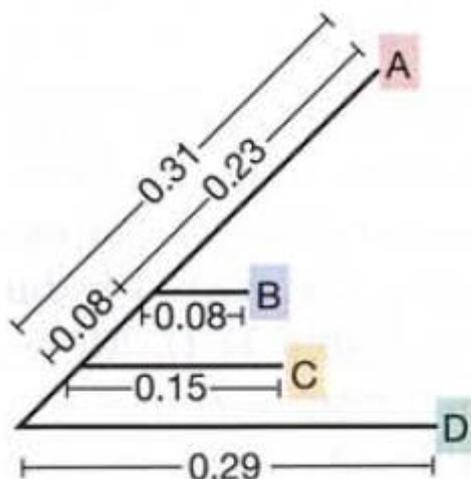
Evolutionary distance	Corrected evolutionary distance
E_D A → B 0.25	0.30
E_D A → C 0.33	0.44
E_D A → D 0.42	0.61
E_D B → C 0.25	0.30
E_D B → D 0.33	0.44
E_D C → D 0.33	0.44

(b) Calculation of evolutionary distance

→ correction selon un modèle évolutif: plus qu'un changement à pu se produire à une position donnée

Calcul de la distance évolutive

Construction de l'arbre phylogénétique: traitement informatique des données de *distances* donnant le meilleur ajustement (cf. Algorithmes pour la phylogénie moléculaire)



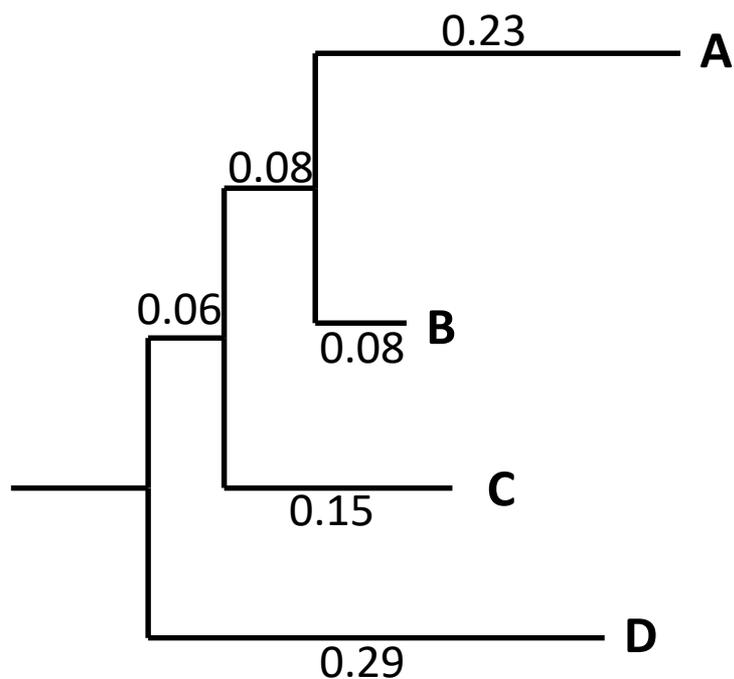
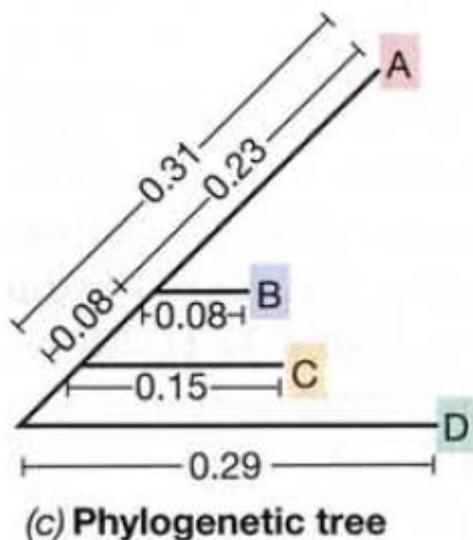
(c) Phylogenetic tree

Evolutionary distance		Corrected evolutionary distance
E_D	A → B 0.25	0.30
E_D	A → C 0.33	0.44
E_D	A → D 0.42	0.61
E_D	B → C 0.25	0.30
E_D	B → D 0.33	0.44
E_D	C → D 0.33	0.44

(b) Calculation of evolutionary distance

Calcul de la distance évolutive

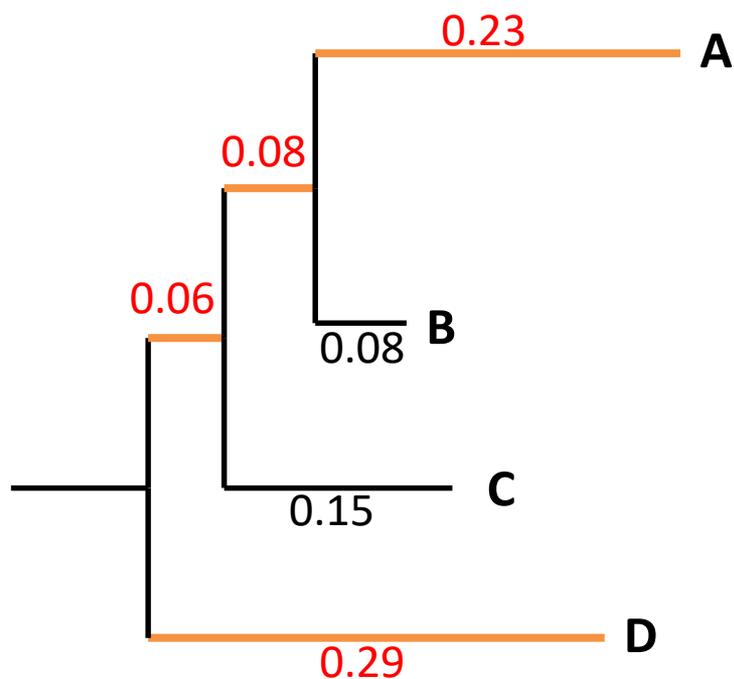
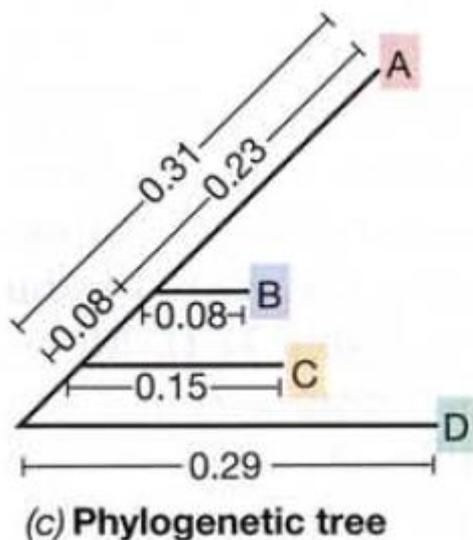
Construction de l'arbre phylogénétique: traitement informatique des données de distances donnant le meilleur ajustement



Quelle est la distance évolutive entre les espèces A et D?

Calcul de la distance évolutive

Construction de l'arbre phylogénétique: traitement informatique des données de distances donnant le meilleur ajustement



Quelle est la distance évolutive entre les séquences A et D?

$$(0.23 + 0.08 + 0.06) + 0.29 = 0.66$$

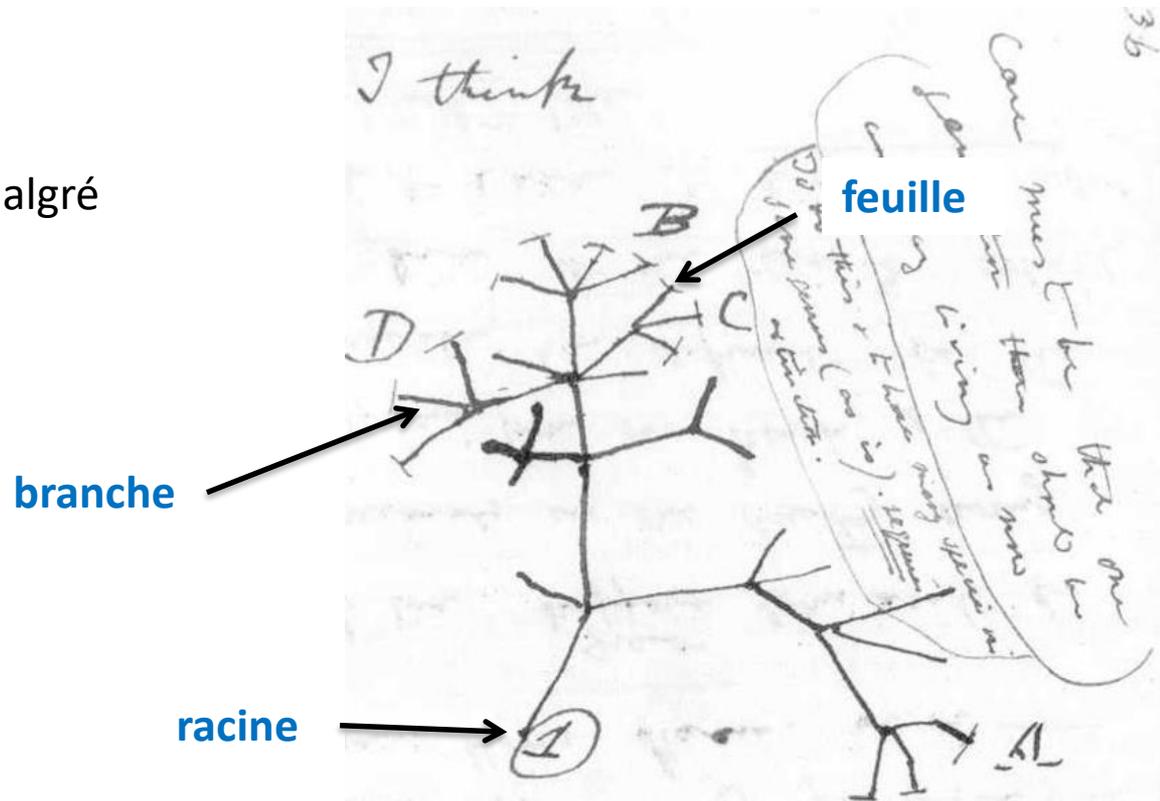
Comment lire un arbre phylogénétique

« Fortunately, one can interpret trees and use them for organizing knowledge of biodiversity without knowing the details of phylogenetic inference.

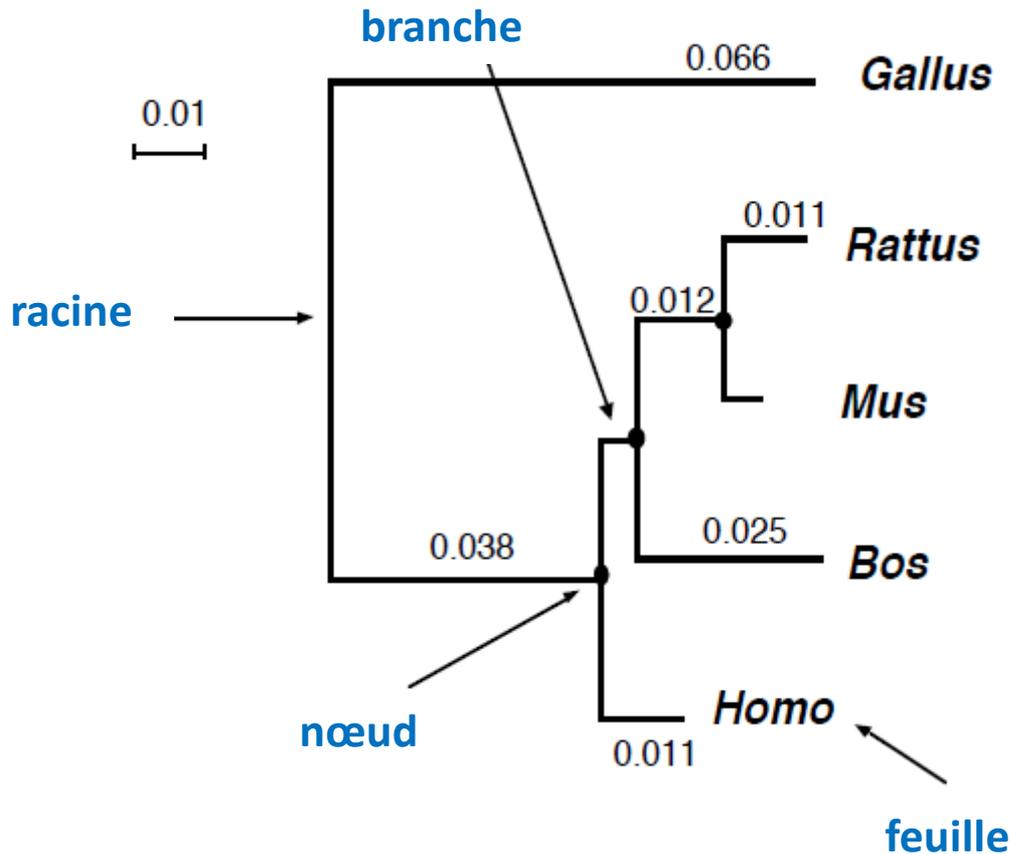
The reverse is, however, not true. **One cannot really understand phylogenetics if one is not clear what an evolutionary tree is.**”

Baum et al. , 2005 Science

-l'idée centrale de Darwin: malgré leur diversité les organismes modernes sont tous les descendants d'un ancêtre commun universel



Comment lire un arbre phylogénétique



feuille: les extrémités des branches, ce sont les organismes modernes ou leurs macromolécules (protéines, ADN, ARN)

nœud: le dernier ancêtre commun de tous les organismes reliés par ce nœud

branche: relie les nœuds, représente le chemin évolutif parcouru entre l'ancêtre (nœud) et la feuille; la longueur de branches correspond au temps (si *échelle* = temps) ou la quantité de changement évolutif (si *échelle* = distance évolutive)

racine: c'est la « base » de l'arbre – l'ancêtre commun de tous les organismes/molécules dans l'arbre

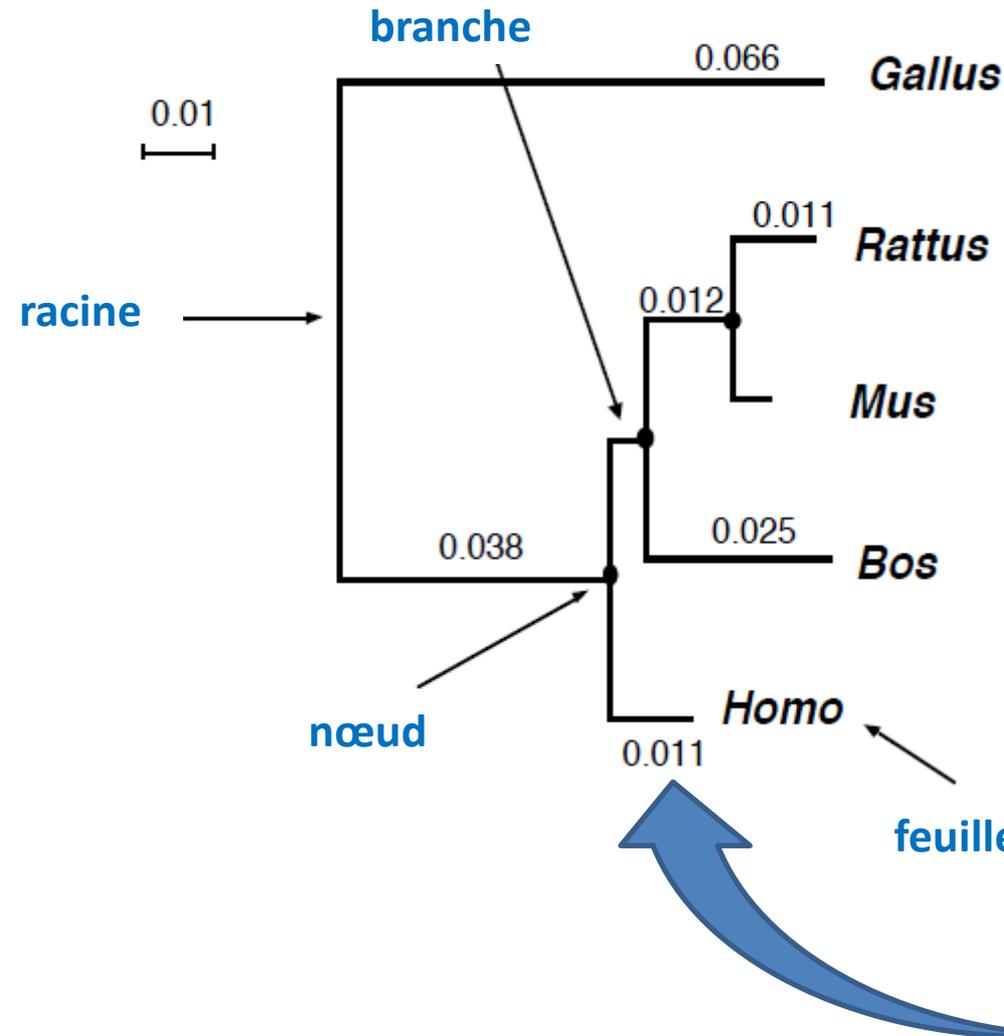
Comment lire un arbre phylogénétique

feuille: les extrémités des branches, ce sont les organismes modernes ou leurs macromolécules (protéines, ADN, ARN)

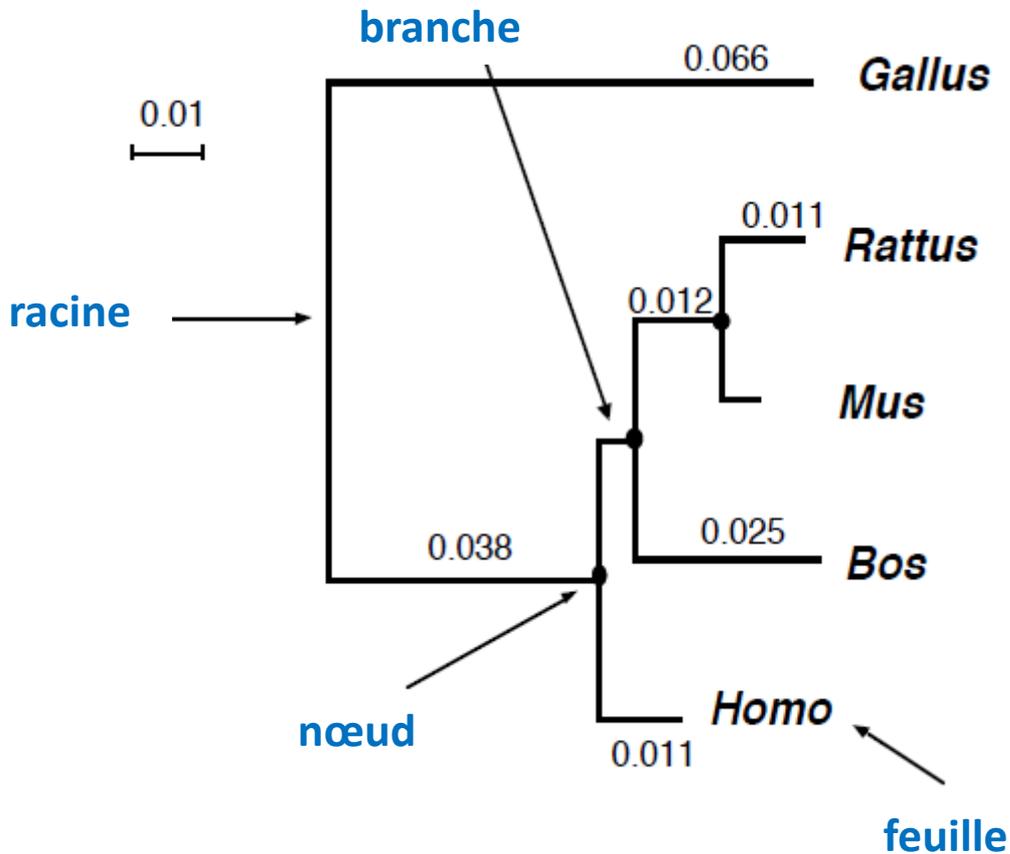
nœud: le dernier ancêtre commun de tous les organismes reliés par ce nœud

branche: relie les nœuds, représente le chemin évolutif parcouru entre l'ancêtre (nœud) et la feuille; la longueur de branches correspond au temps (si *échelle* = temps) ou la quantité de changement évolutif (si *échelle* = distance évolutive)

Utilisé plus fréquemment



Comment lire un arbre phylogénétique

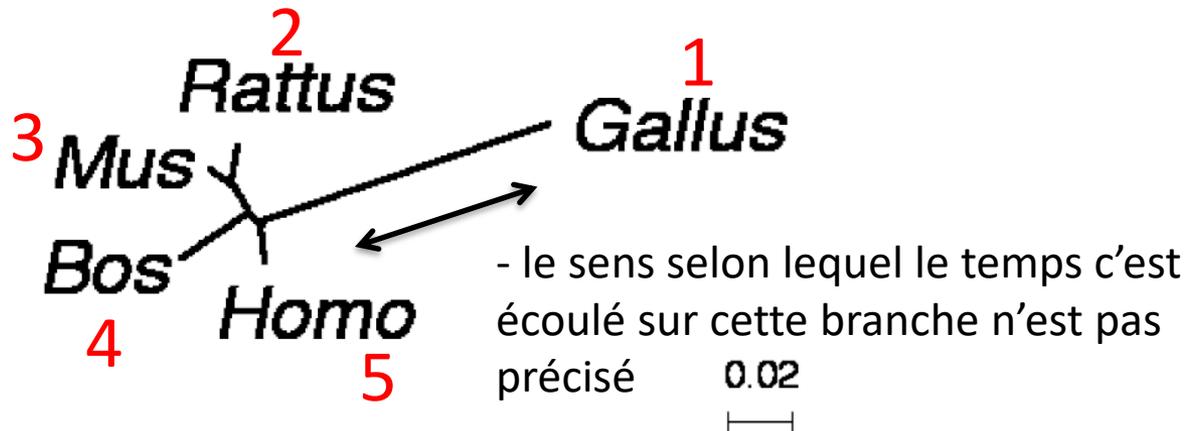


La longueur des branches horizontales est proportionnelle à la quantité d'évolution entre les séquences et leurs ancêtres (unité = substitution / site).

Comment lire un arbre phylogénétique

Arbres non racinés: le sens d'écoulement évolutif n'est pas précisé

- graphisme circulaire



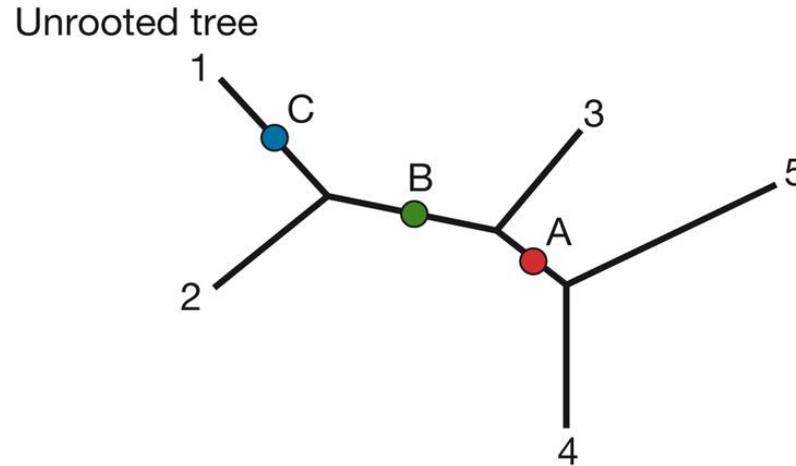
- le sens selon lequel le temps c'est écoulé sur cette branche n'est pas précisé

0.02
|—|

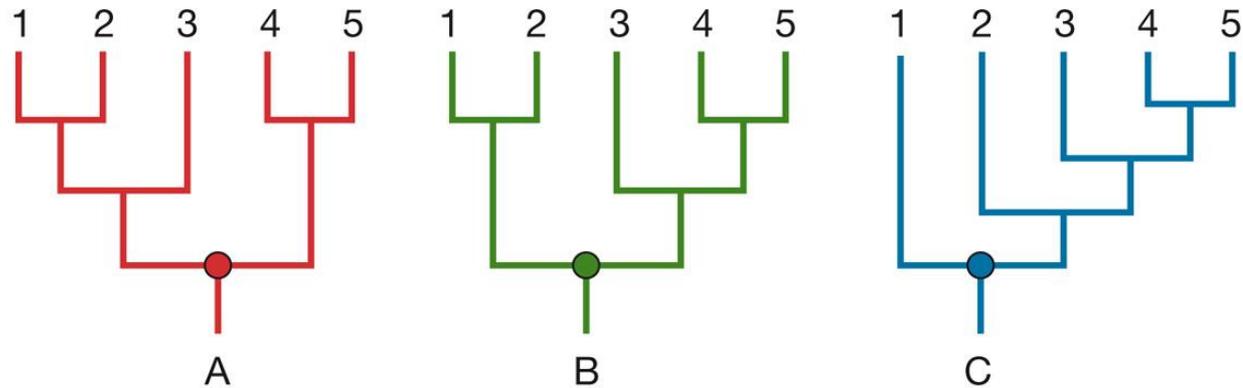
- la racine pourrait être placé par exemple sur la branche du poulet (*Gallus*) ou de la souris (*Mus*) → cette dernière possibilité est erronée !

Comment lire un arbre phylogénétique

- 1 **Gallus (oiseau)**
- 2 **Rattus (mammifère)**
- 3 **Mus (mammifère)**
- 4 **Bos (mammifère)**
- 5 **Homo (mammifère)**



Rooted trees



-la racine C est la seule qui décrit correctement l'évolution de ces organismes

Comment lire un arbre phylogénétique

Pour enraciner un arbre on peut utiliser un **groupe externe**:

- inclure dans les séquences analysés des séquences provenant d'organismes externes au groupe d'intérêt

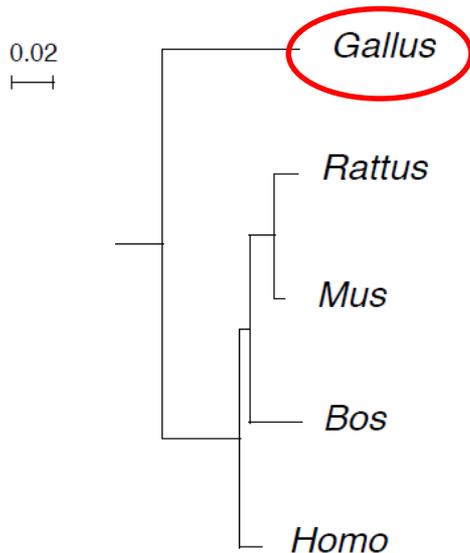
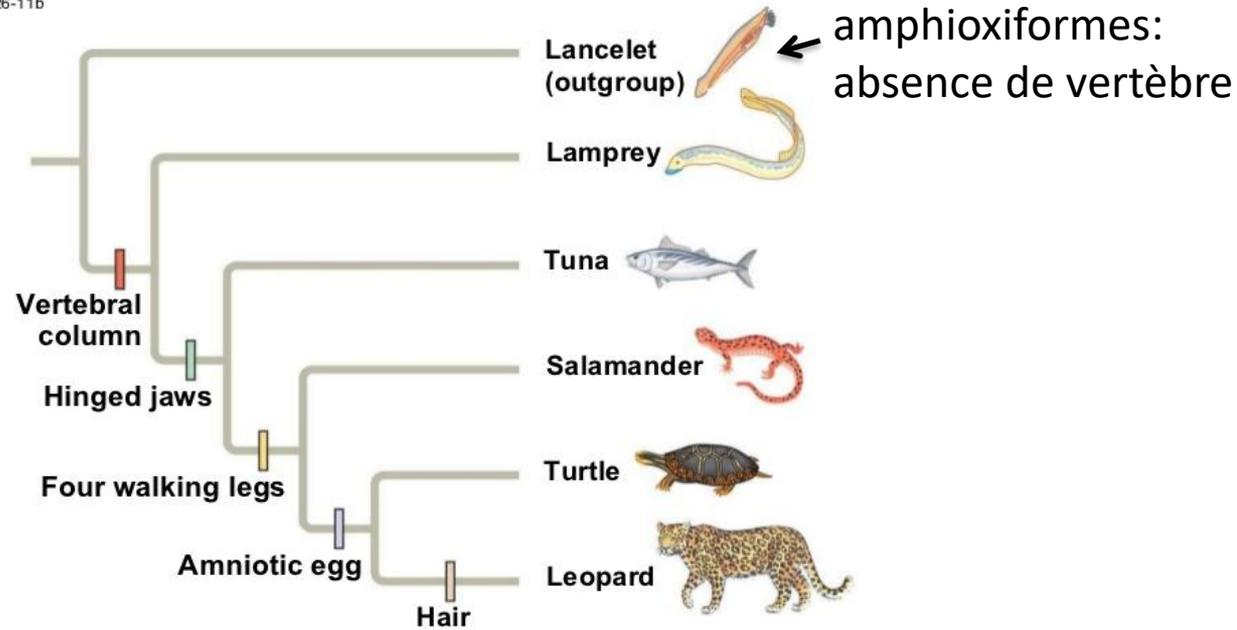


Fig. 26-11b



(b) Phylogenetic tree

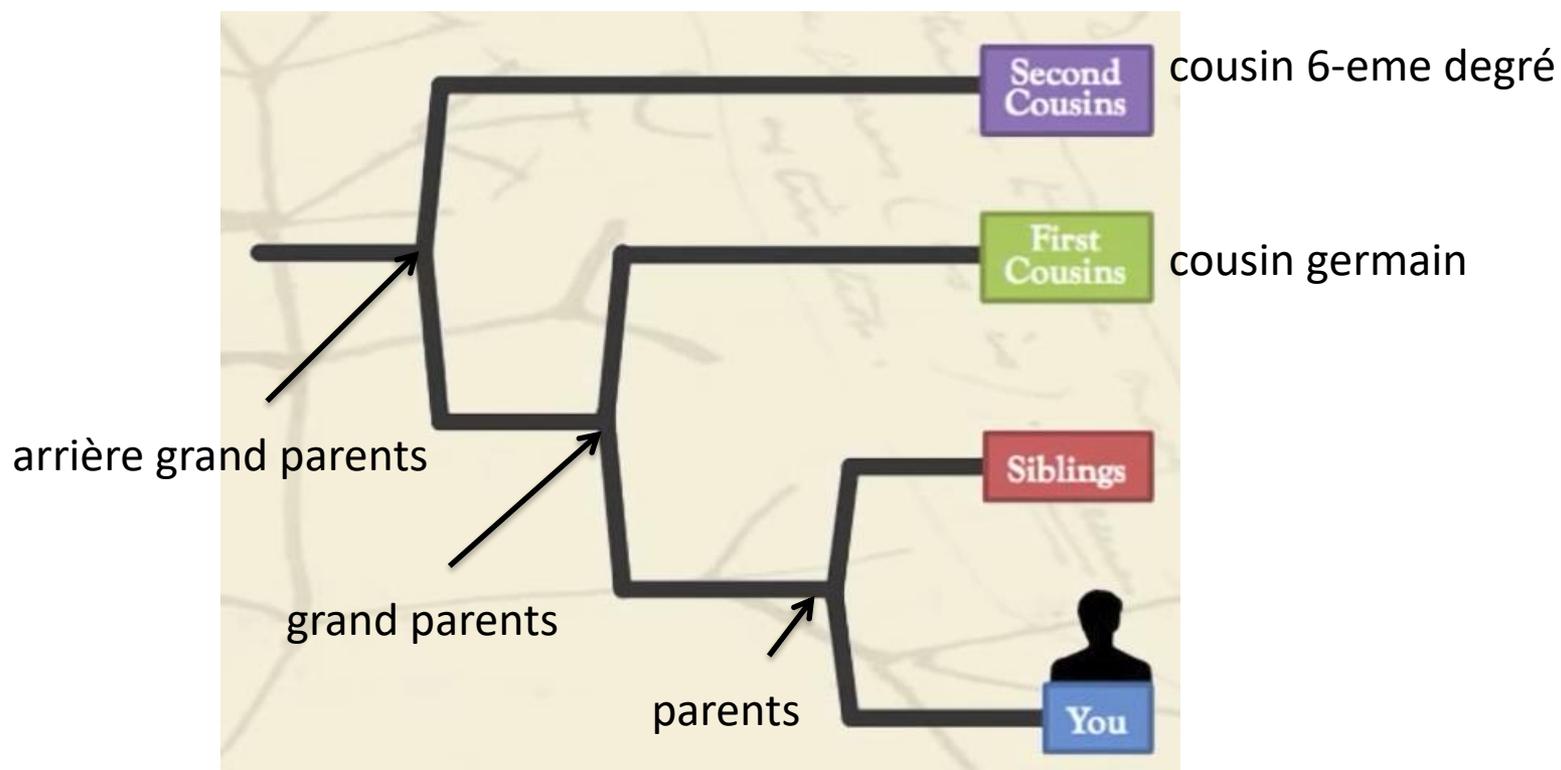
Copyright © 2008 Pearson Education, Inc., publishing as Pearson Benjamin Cummings.

Léopard est plus proche phylogénétiquement de la tortue que du salamandre – comment on déduit cela?

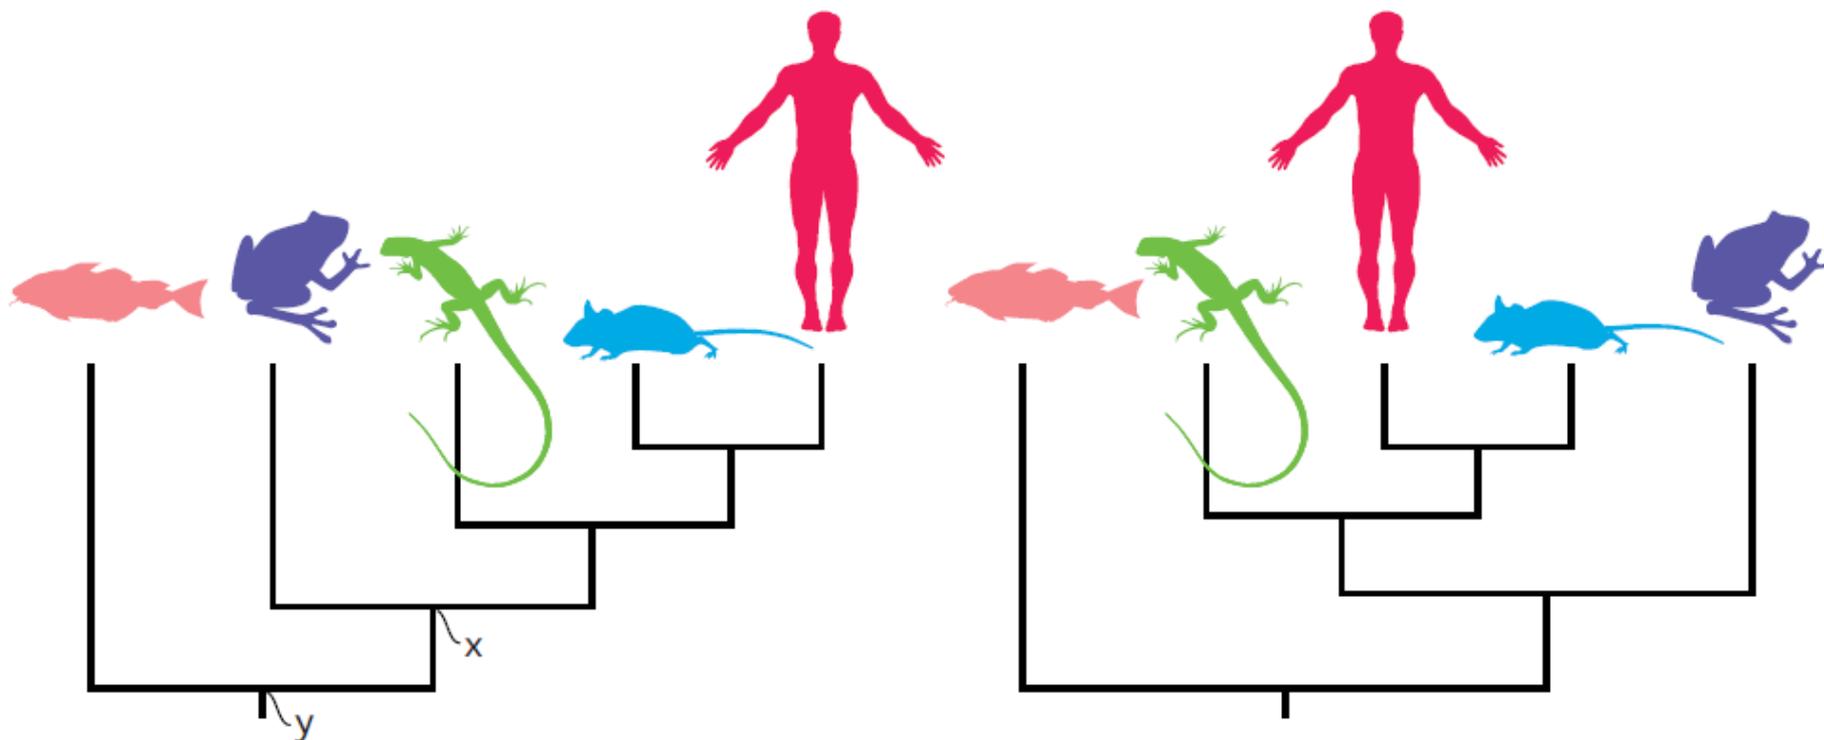
Comment lire un arbre phylogénétique

Qu'est ce que cela vaut dire: les espèces A et B sont plus apparentés que les espèces A et C?
Dans un arbre phylogénétique, qui est plus proche de qui ?

-les liens de parenté plus ou moins proches sont déterminés en fonction du dernier ancêtre commun: nous sommes plus proches de notre cousin germain que de notre cousin au 6-eme degré car notre dernier ancêtre commun (grand parents) a vécu une génération plutôt



Comment lire un arbre phylogénétique



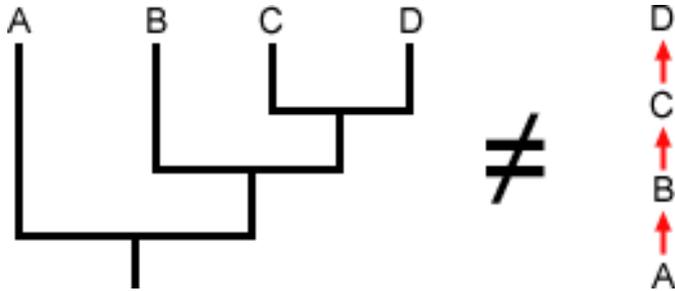
La grenouille est elle plus proche parent du poisson ou de l'homme?

Et pour cette arbre?

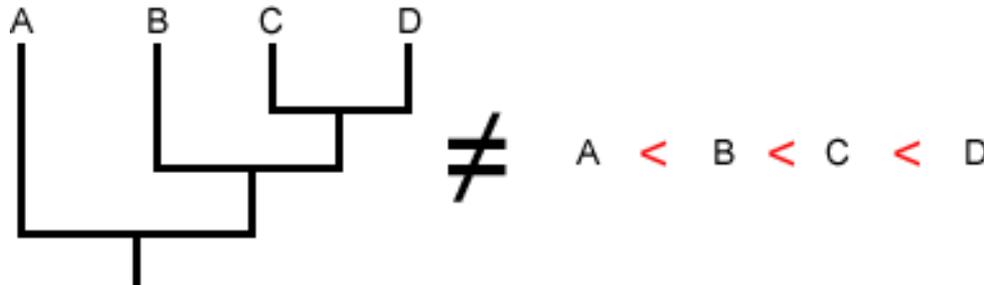
Comment lire un arbre phylogénétique

Quelques idées fausses:

1. Les relations de parenté établies au cours de l'évolution produisent ressemblent à un arbre et non pas une échelle.



2. Les relations d'organismes supérieurs/inferieurs n'existent pas



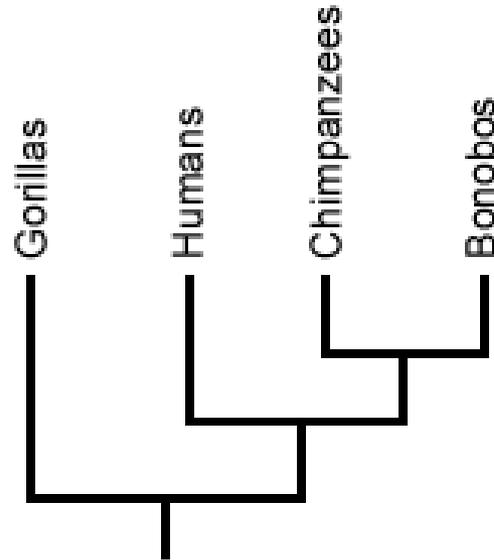
wrong



right

Comment lire un arbre phylogénétique

3. Les humains ne sont pas les descendants des singes!



Les humains et les chimpanzés ont un ancêtre commun qui n'était ni un chimpanzé ni un homme.

Les humains ne sont pas plus « évolués » que les autres êtres vivants!

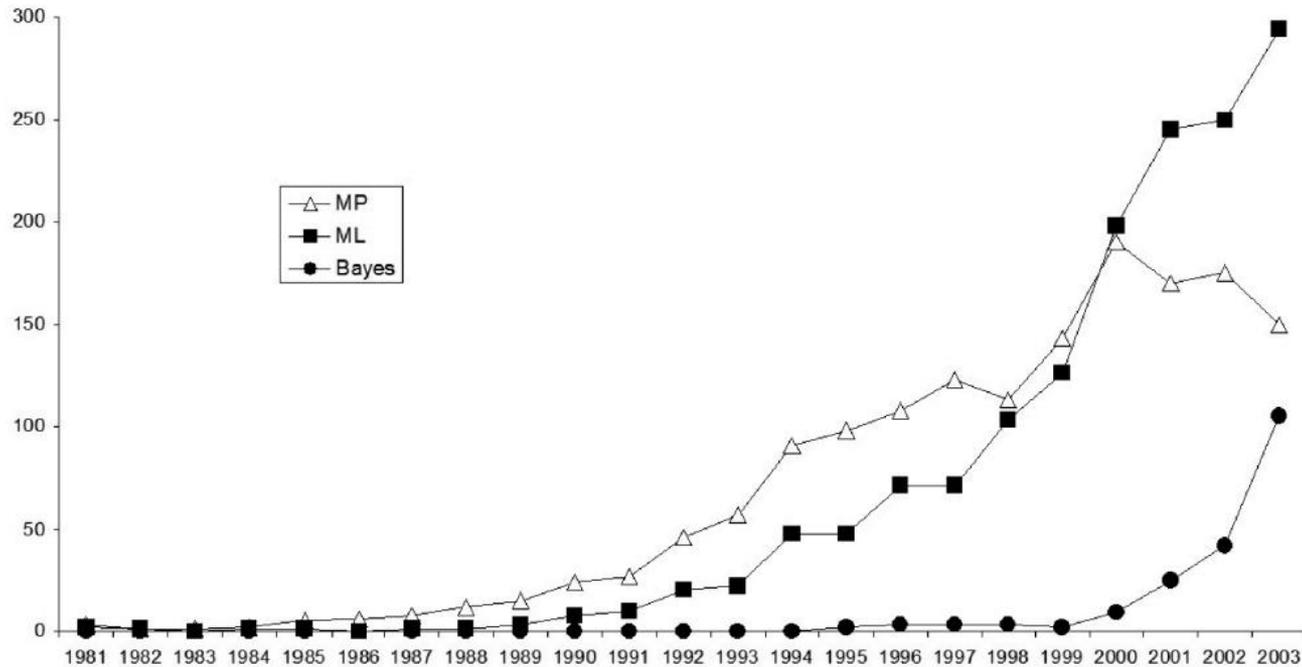
Algorithmes pour la phylogénie moléculaire

→ Sont nombreux!



Algorithmes pour la phylogénie moléculaire

- Parcimonie
- Méthodes de distance
- Maximum de vraisemblance
- L'approche Bayésienne



LES MÉTHODES PROBABILISTES EN PHYLOGÉNIE MOLÉCULAIRE

(1) Les modèles d'évolution des séquences et le maximum de vraisemblance

Frédéric DELSUC et Emmanuel J. P. DOUZERY

Laboratoire de Paléontologie, Phylogénie et Paléobiologie,
Institut des Sciences de l'Évolution de Montpellier (ISEM), UMR 5554-CNRS,
Université Montpellier II, Montpellier, France
delsuc@isem.univ-montp2.fr

(2) L'approche bayésienne

Frédéric DELSUC et Emmanuel J. P. DOUZERY

Laboratoire de Paléontologie, Phylogénie et Paléobiologie,
Institut des Sciences de l'Évolution de Montpellier (ISEM), UMR 5554-CNRS,
Université Montpellier II, Montpellier, France
E-mail : douzery@isem.univ-montp2.fr

Algorithmes pour la phylogénie moléculaire

Consiste à probabiliser entièrement le processus évolutif (définir les probabilités de tous les évènements évolutifs possibles depuis n'importe quelle séquence ancestrale jusqu'aux feuilles), et à trouver quel est le scénario évolutif (topologie d'arbre et la longueur de ces branches) , qui a la plus forte probabilité d'avoir donné la naissance aux séquences analysées.

Solidement ancré dans les mathématiques et statistiques garantissant (*à condition que les données ont évolué selon les hypothèses probabilistes et que leur nombre tend vers l'infini*) que l'arbre trouvé sera l'arbre vrai des séquences analysées

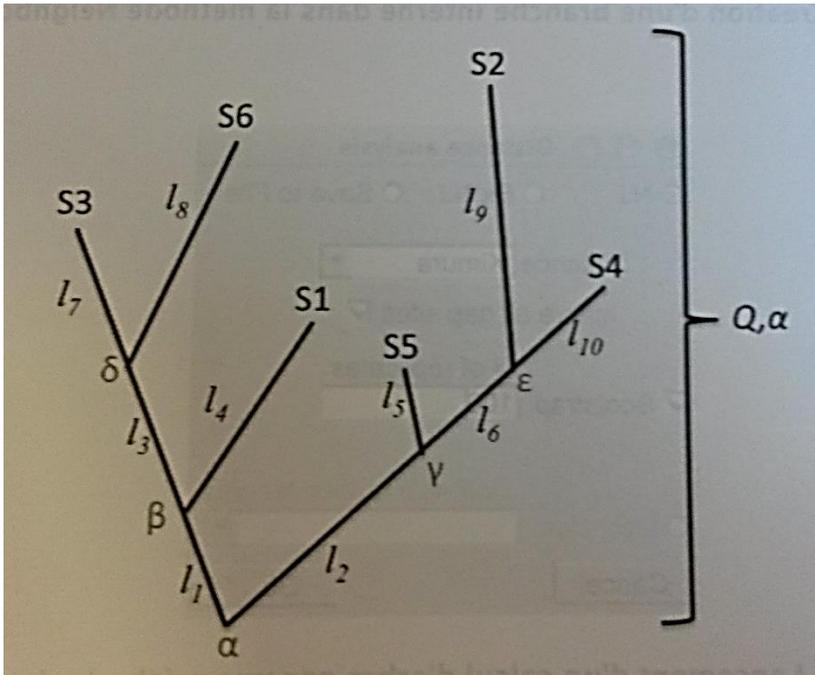
Algorithmes pour la phylogénie moléculaire

LE MAXIMUM DE VRAISEMBLANCE

Objectif: calculer la vraisemblance du modèle, c'est-à-dire *la probabilité des données pour les valeurs des paramètres du modèle*

Les paramètres:

- (i) Un arbre enraciné arbitrairement et ses longueurs de branches ($l = \text{nr. subst./site}$, lettres grecques = résidus ancestraux inconnus, toutes les combinaisons de valeurs sont envisagées)
- (ii) Matrice de taux Q^* commune à toutes les branches
- (iii) Valeur α qui détermine la variation de taux d'évolution entre sites

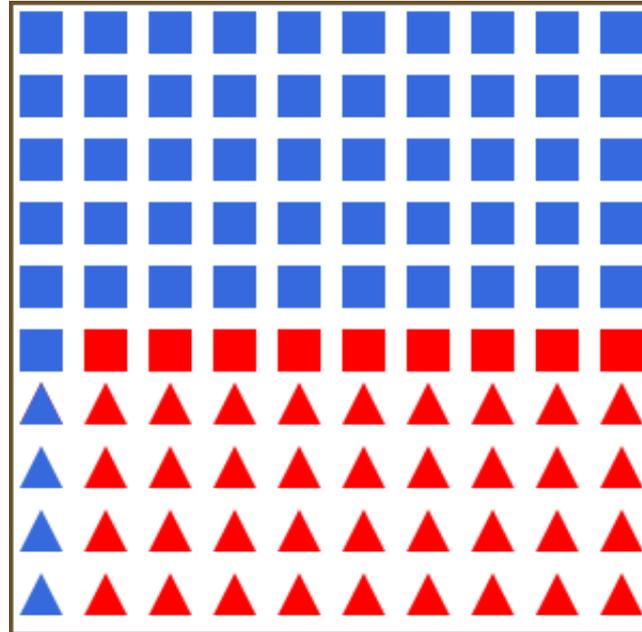


* Permet de modéliser le processus d'évolution d'un site d'une séquence

Algorithmes pour la phylogénie moléculaire

→ la vraisemblance est la probabilité conditionnelle d'observer les données sous un modèle particulier:

100 objets
60 carrés
9 carrés rouges



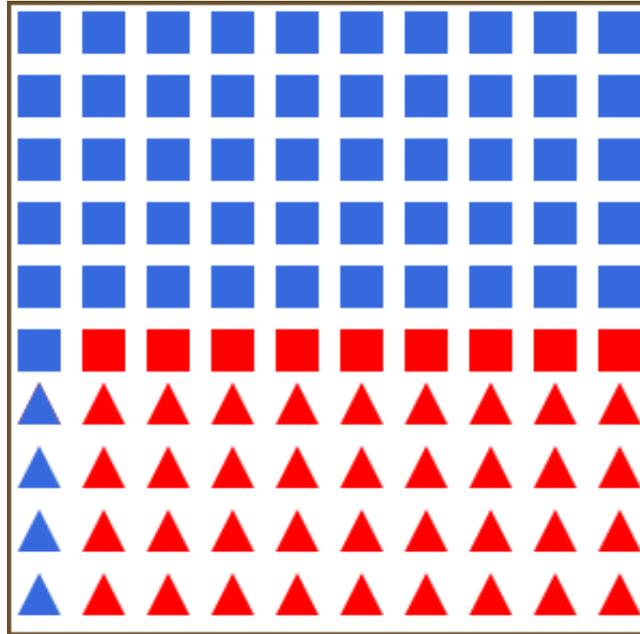
→ Probabilité de tirer un carré? $P(\text{Carré})=?$

<https://sciencetonante.wordpress.com/2012/10/08/les-probabilites-conditionnelles-bayes-level-1/>
<https://sciencetonante.wordpress.com/2012/10/15/linference-bayesienne-bayes-level-2/>

Algorithmes pour la phylogénie moléculaire

→ la vraisemblance est la probabilité conditionnelle d'observer les données sous un modèle particulier:

100 objets
60 carrés
9 carrés rouges

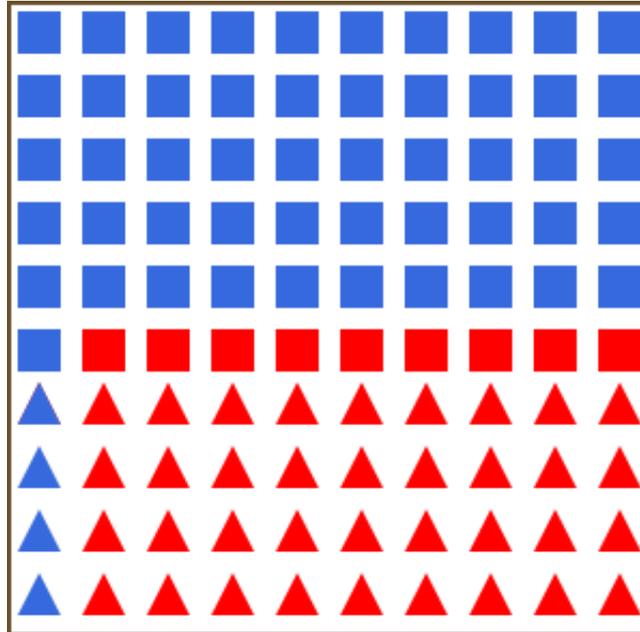


→ Probabilité de tirer un carré? $P(\text{Carré}) = 60/100 = 60\%$

Algorithmes pour la phylogénie moléculaire

→ la vraisemblance est la probabilité conditionnelle d'observer les données sous un modèle particulier:

100 objets
60 carrés
9 carrés rouges

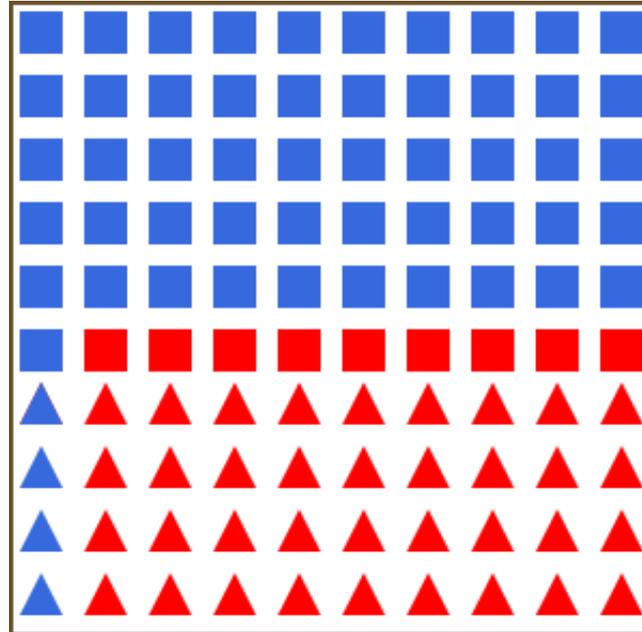


→ Probabilité de tirer un carré sachant qu'il est rouge? $P(\text{Carré} \mid \text{Rouge}) = ?$

Algorithmes pour la phylogénie moléculaire

→ la vraisemblance est la probabilité conditionnelle d'observer les données sous un modèle particulier:

100 objets
60 carrés
9 carrés rouges
36 triangles rouges



→ Probabilité de tirer un carré sachant qu'il est rouge? On considère uniquement les objets rouges (Carré | Rouge) = $9/45 = 20\%$

Algorithmes pour la phylogénie moléculaire

→ la vraisemblance est la probabilité conditionnelle d'observer les données sous un modèle particulier:

la probabilité que l'objet soit un carré est fortement affectée par le fait de savoir qu'il est rouge. La « probabilité que l'objet soit carré »

$$P(\text{Carré}) = 60\%$$

n'est pas la même que la « probabilité que l'objet soit carré *sachant qu'il est rouge* »

$$P(\text{Carré} \mid \text{Rouge}) = 9/45 = 20\%$$

ni la même que la « probabilité que l'objet soit rouge *sachant qu'il est carré* »

$$P(\text{Rouge} \mid \text{Carré}) = 9/60 = 15\%$$

Algorithmes pour la phylogénie moléculaire

→ la vraisemblance est la probabilité conditionnelle d'observer les données sous un modèle particulier:

la probabilité que l'objet soit un carré est fortement affectée par le fait de savoir qu'il est rouge. La « probabilité que l'objet soit carré »

$$P(\text{Carré}) = 60\%$$

n'est pas la même que la « probabilité que l'objet soit carré *sachant qu'il est rouge* »

$$P(\text{Carré} \mid \text{Rouge}) = 9/45 = 20\%$$

ni la même que la « probabilité que l'objet soit rouge *sachant qu'il est carré* »

$$P(\text{Rouge} \mid \text{Carré}) = 9/60 = 15\%$$

→ comment connaître $P(\text{Rouge} \mid \text{Carré})$ si on connaît $P(\text{Carré} \mid \text{Rouge})$?

Algorithmes pour la phylogénie moléculaire

→ comment connaître $P(\text{Rouge} | \text{Carré})$ si on connaît $P(\text{Carré} | \text{Rouge})$?



Thomas Bayes
(1701 – 1761)

→ Théorème de Bayes

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)}$$

$$P(\text{Carré} | \text{Rouge}) = P(\text{Rouge} | \text{Carré}) \times P(\text{Carré}) / P(\text{Rouge})$$

$$= 9/60 \times 60/100 / 45/100 = 0.09/0.45 = 0.2 = \mathbf{20\%}$$

→ Probabilité de tirer un carré sachant qu'il est rouge? On considère uniquement les objets rouges $(\text{Carré} | \text{Rouge}) = 9/45 = \mathbf{20\%}$

Algorithmes pour la phylogénie moléculaire

APPROCHE BAYESIENNE



Thomas Bayes
(1701 – 1761)

→ formule de Bayes : permet de calculer les *probabilités à posteriori* d'une hypothèse en se basant sur **les données connues**

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)}$$

→ Utilisé en médecine (Quelle est la probabilité d'avoir la maladie si je suis dépisté positif?), identification des messages spam (Quelle est la probabilité que le message est un spam si il contient le mot viagra?)

→ Si la **qualité des données** est bonne le théorème de Bayes donnera des résultats fiables (« garbage in - garbage out »)

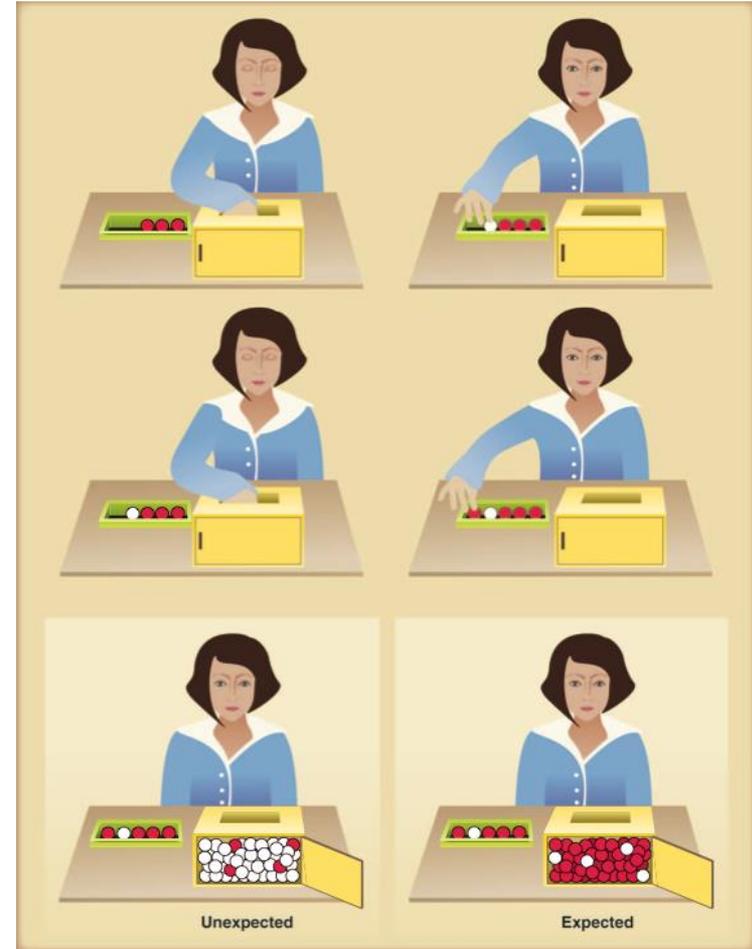
Algorithmes pour la phylogénie moléculaire

→ notre cerveau fait des raisonnements bayésiens inconscients

Test réalisé sur des enfants de 8 (!) mois:

Capacité d'émettre une hypothèse sur le contenu de la boîte à partir de l'échantillon qu'on leur avait présenté

→ Les enfants sont capables de réaliser des inductions bayésiennes



Algorithmes pour la phylogénie moléculaire

L'approche Bayésienne appliqué à la phylogénie moléculaire:

$$\Pr[\text{Tree} \mid \text{Data}] = \frac{\Pr[\text{Data} \mid \text{Tree}] \times \Pr[\text{Tree}]}{\Pr[\text{Data}]}$$

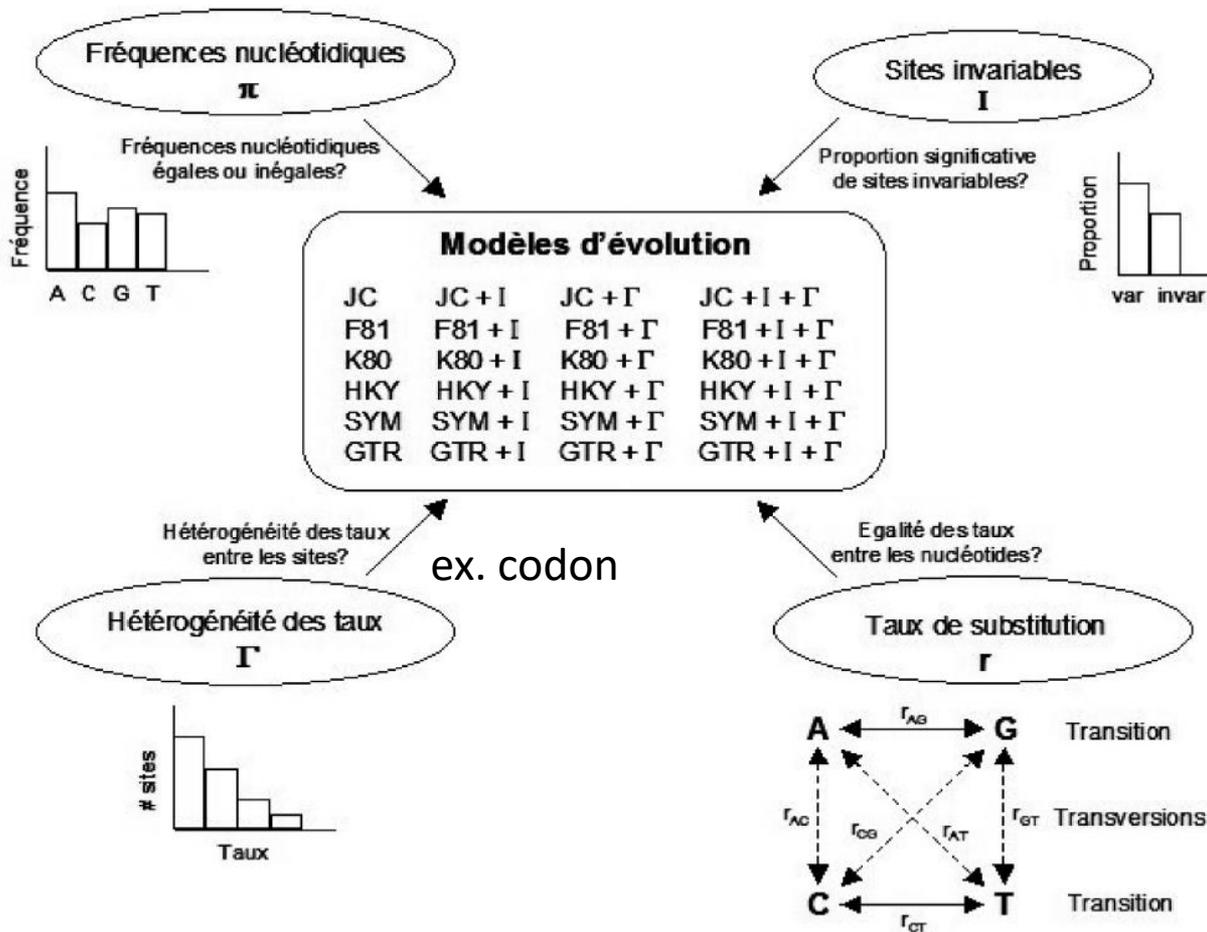
[Data] = données = alignement de séquences

[Tree] = arbre = topologie de l'arbre y compris la longueur de branches (*évolution des séquences*)

- *La méthode bayésienne produit une collection d'arbres dont l'information phylogénétique peut être résumée en calculant le consensus majoritaire.*
- *La fréquence avec laquelle les différents nœuds apparaissent dans les arbres visités représente leur probabilité postérieure associée*

Algorithmes pour la phylogénie moléculaire

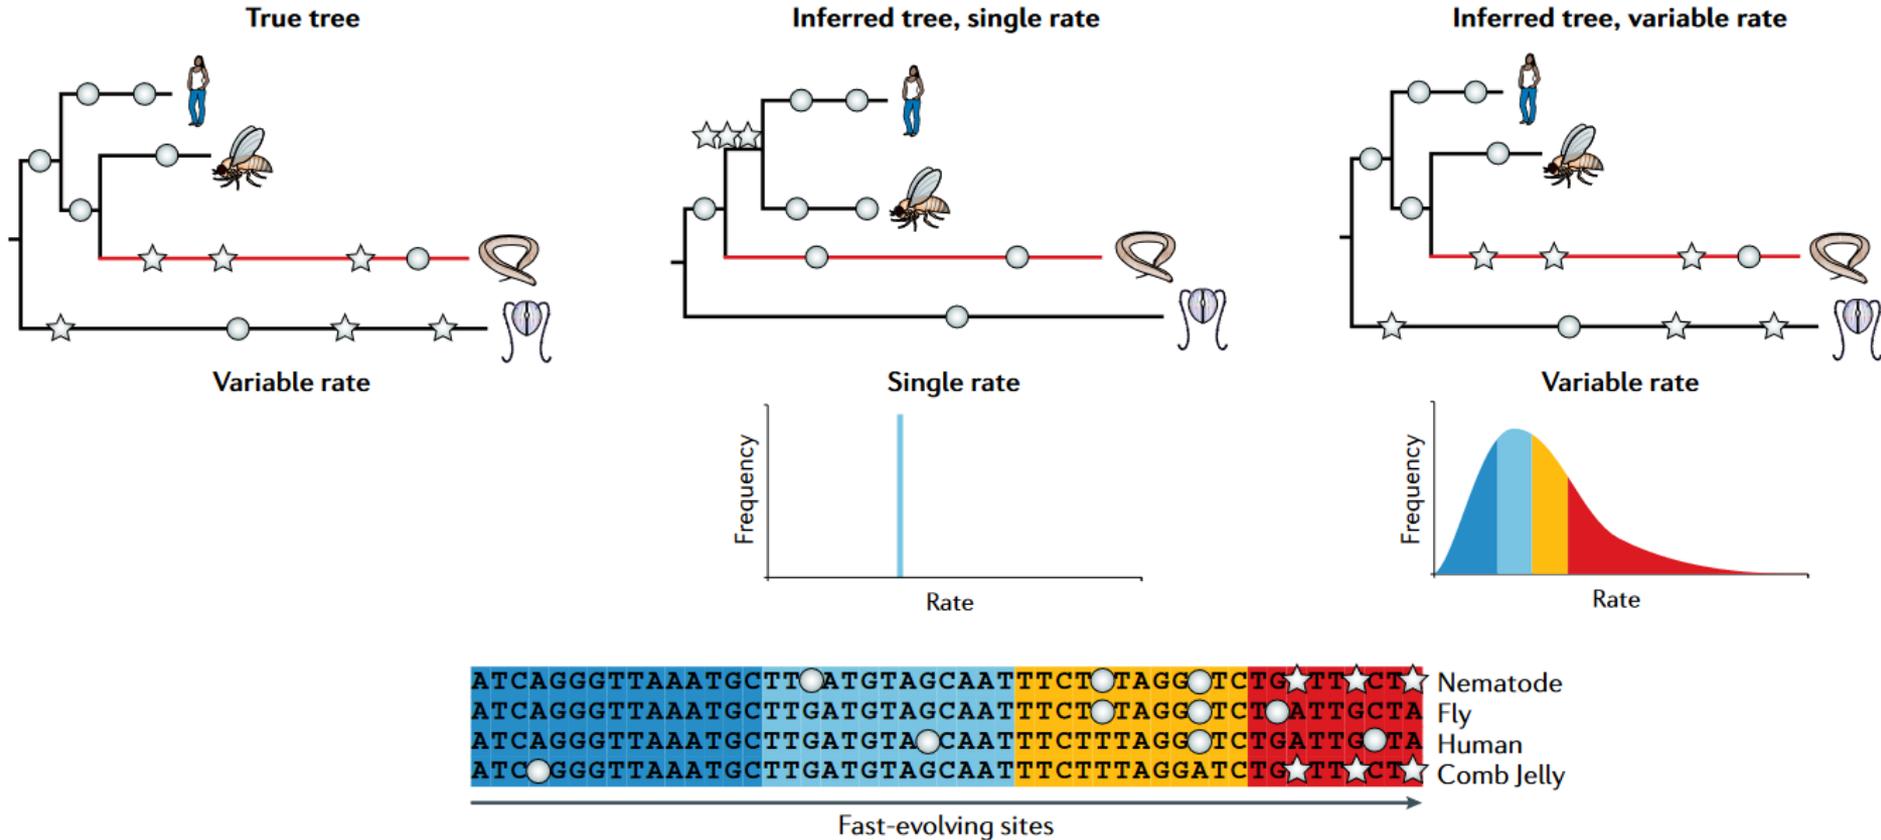
→ pour être statistiquement robustes et performantes, les méthodes probabilistes nécessitent l'incorporation de *modèles* qui décrivent de la façon la plus réaliste possible les processus biologiques *d'évolution des séquences*



r (transition) > r (transversion)

Algorithmes pour la phylogénie moléculaire

Hétérogénéité des taux de substitution entre les sites

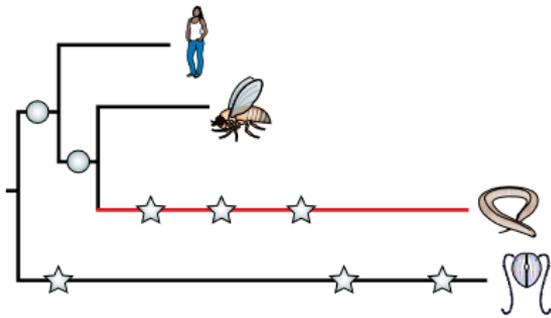


Kapli P, Yang Z, Telford MJ. Phylogenetic tree building in the genomic age. *Nat Rev Genet.* 2020 Jul;21(7):428-444. doi: 10.1038/s41576-020-0233-0. Epub 2020 May 18. PMID: 32424311.

Algorithmes pour la phylogénie moléculaire

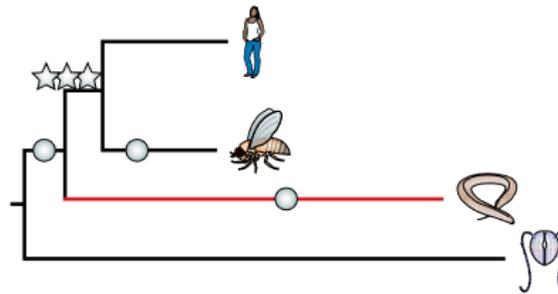
Hétérogénéité de composition entre les sites

True tree

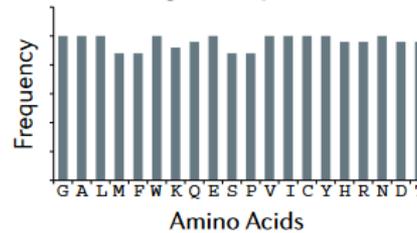


Variable composition

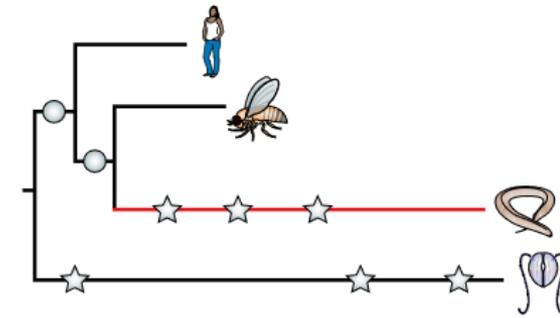
Inferred tree, single composition



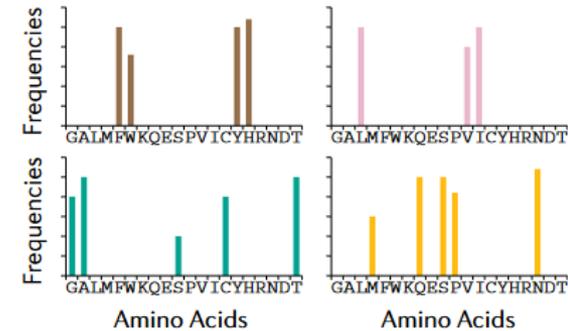
Single composition



Inferred tree, variable composition



Variable composition



SCS●SDEKDYWTFFFWL★VHHHRRRDGAMQED●NPNPPYLI★LLIV★ Nematode
 SCS●SDEKDYWTFFFWLIVVHHHRRRDGAMQED●NPNPPYLI★LLIVV Fly
 SCSCSDEKDYWTFFFWLIVVHHHRRRDGAMQED●NPNPPYLI★LLIVV Human
 SCSCSDEKDYWTFFFWL★VHHHRRRDGAMQED●SNPNPPYLI★LLIV★ Comb Jelly

Algorithmes pour la phylogénie moléculaire

→ les méthodes probabilistes sont robustes vis-à-vis du non-respect de leur hypothèse de base mais par conséquent très dépendantes du modèle d'évolution choisi

A.

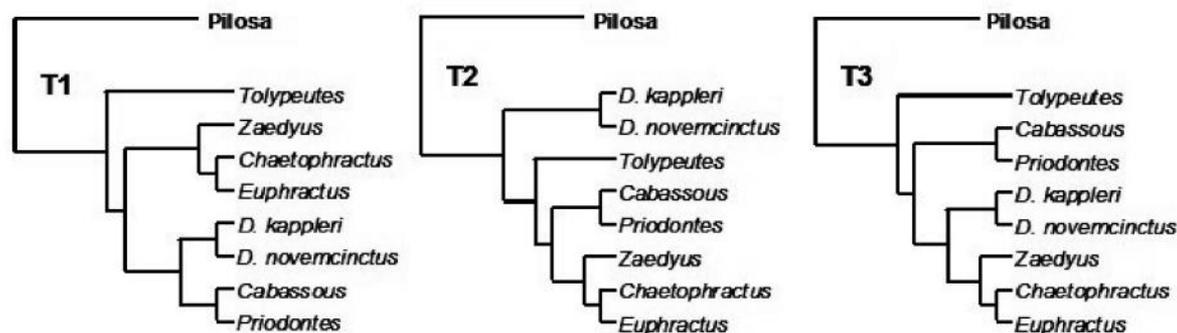
	Complexité du modèle			
	-	+I	+ Γ_8	+I + Γ_8
JC69	-4954,46 (T1)	-4762,20 (T1)	-4722,89 (T1)	-4722,79 (T1)
F81	-4920,87 (T1)	-4725,38 (T1)	-4680,57 (T1)	-4680,52 (T1)
K80	-4772,73 (T2)	-4565,29 (T2)	-4515,29 (T1)	-4515,05 (T1)
HKY85	-4721,72 (T2)	-4505,24 (T2)	-4433,33 (T3)	-4433,28 (T3)
TN93ef	-4701,20 (T2)	-4499,26 (T2)	-4457,37 (T1)	-4457,19 (T1)
TN93	-4670,37 (T2)	-4667,27 (T2)	-4413,94 (T1)	-4413,91 (T1)
K81	-4771,03 (T2)	-4563,07 (T2)	-4512,60 (T1)	-4512,33 (T1)
K81uf	-4720,69 (T2)	-4503,85 (T2)	-4431,75 (T3)	-4431,68 (T3)
TI Mef	-4745,65 (T2)	-4545,29 (T2)	-4495,33 (T1)	-4495,19 (T1)
TIM	-4698,19 (T2)	-4490,40 (T2)	-4424,72 (T1)	-4424,71 (T1)
TVMef	-4726,08 (T2)	-4516,96 (T2)	-4476,06 (T1)	-4475,76 (T1)
TVM	-4693,69 (T2)	-4482,63 (T2)	-4426,06 (T3)	-4426,00 (T3)
SYM	-4701,20 (T2)	-4499,26 (T2)	-4457,37 (T1)	-4457,19 (T1)
GTR	-4670,37 (T2)	-4467,27 (T2)	-4413,94 (T1)	-4413,91 (T1)

Complexité du modèle: - (top) to + (bottom)

→ selon le modèle choisi - trois topologies différentes

→ l'approche bayésienne est sensible à l'inadéquation du modèle utilisé pour décrire l'évolution des séquences

B.



Algorithmes pour la phylogénie moléculaire

→ Le principe de bootstrap:

Rééchantillonnage numérique par **tirage aléatoire avec remplacement** des sites nucléotidiques à introduire dans le nouveau jeu de données:

Jeu de données réel:

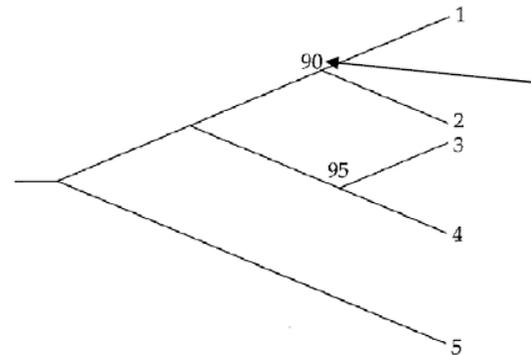
Taxa	Sequence
1	GCAGTACT...
2	GTAGTACT...
3	ACAATACC...
4	ACAACACT...
5	GCGGCATT...

Jeu de données rééchantillonné:

(tirage aléatoire des sites 6,1,6,...)

1	AGATACTC...
2	AGATGCTT...
3	AAACACTC...
4	AAACACCC...
5	AGACATCC...

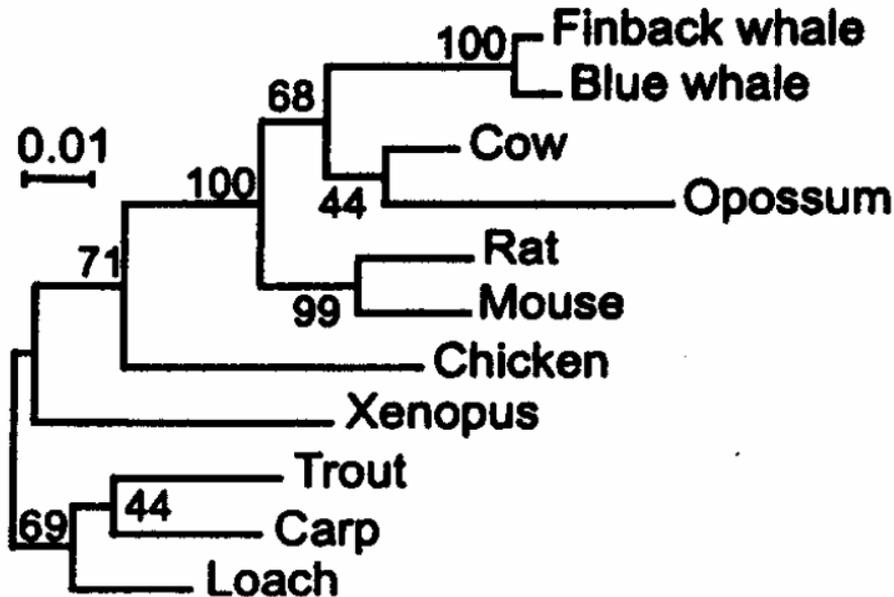
Un total de 100 jeux de données
et donc 100 arbres sont obtenus
dont 90 → clade (12)
et 95 → clade (34)



"proportion
de bootstrap"
= niveau de
confiance

Algorithmes pour la phylogénie moléculaire

Interprétation des valeurs de **proportion de bootstrap** pour une branche donnée d'un arbre phylogénétique: \approx probabilité de confiance que la longueur de la branche soit supérieure à zéro (la branche est dite "significative" si $>95\%$ ou 99%)



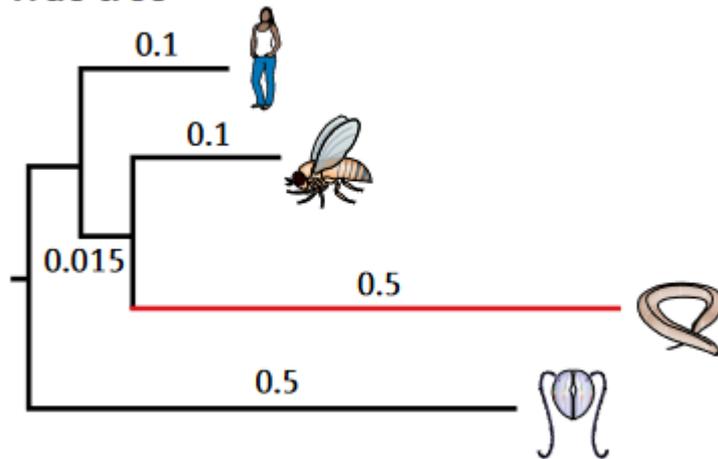
ex. arbre consensus sur 500 bootstraps avec méthode ML sur données de séquences de la cytochrome oxidase (gène mitochondrial)

(Nei & Kumar, 2000)

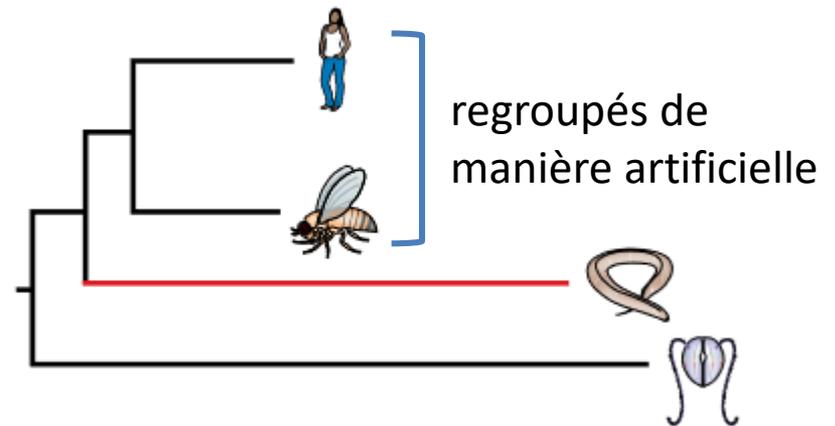
Algorithmes pour la phylogénie moléculaire

→ Les taux hétérogènes de substitution au sein des différentes espèces peuvent conduire à l'**attraction de longues branches**, un artéfact connu de l'analyse phylogénétique

True tree

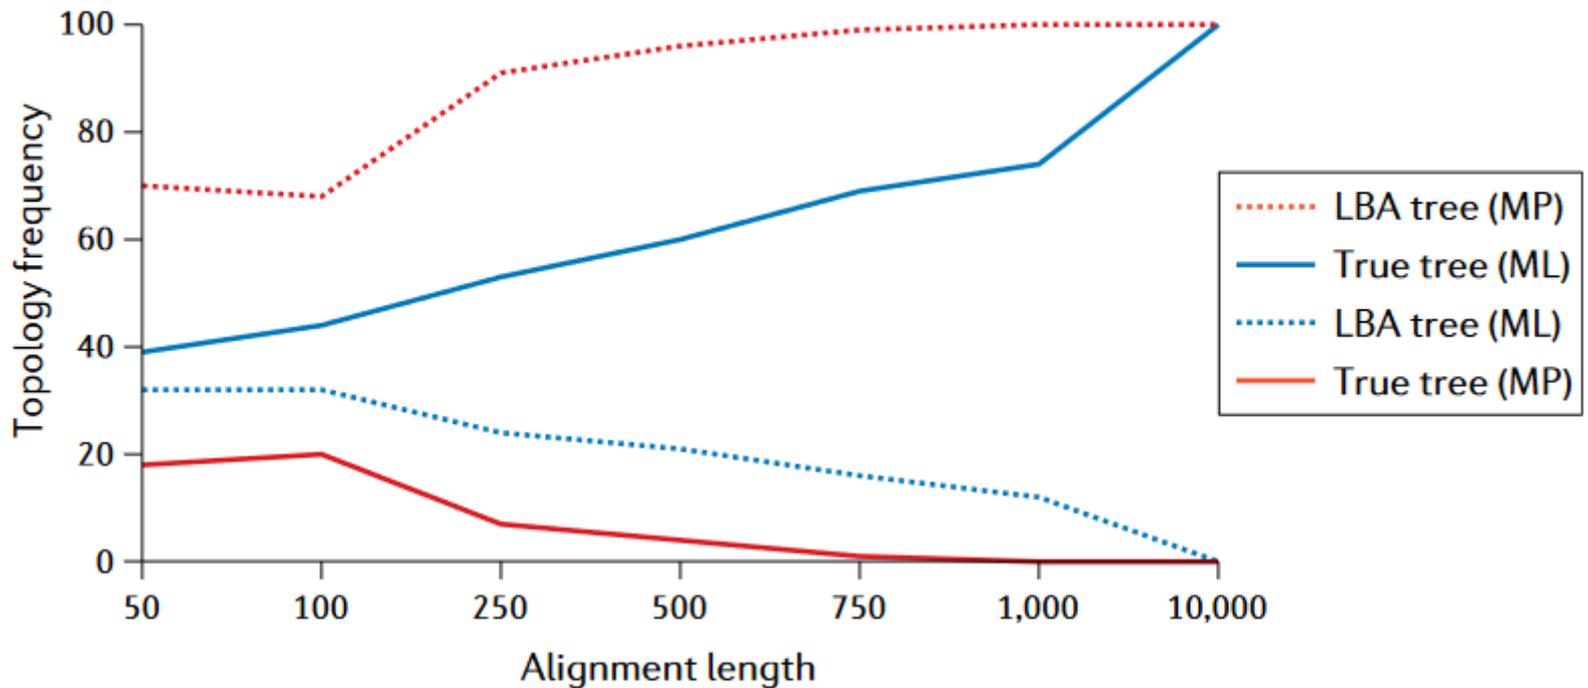


LBA tree

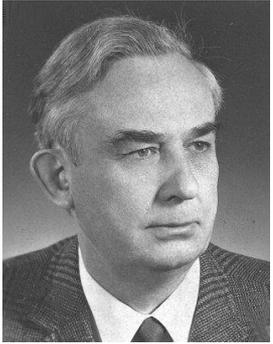


Algorithmes pour la phylogénie moléculaire

b Maximum likelihood versus maximum parsimony



Classification cladistique



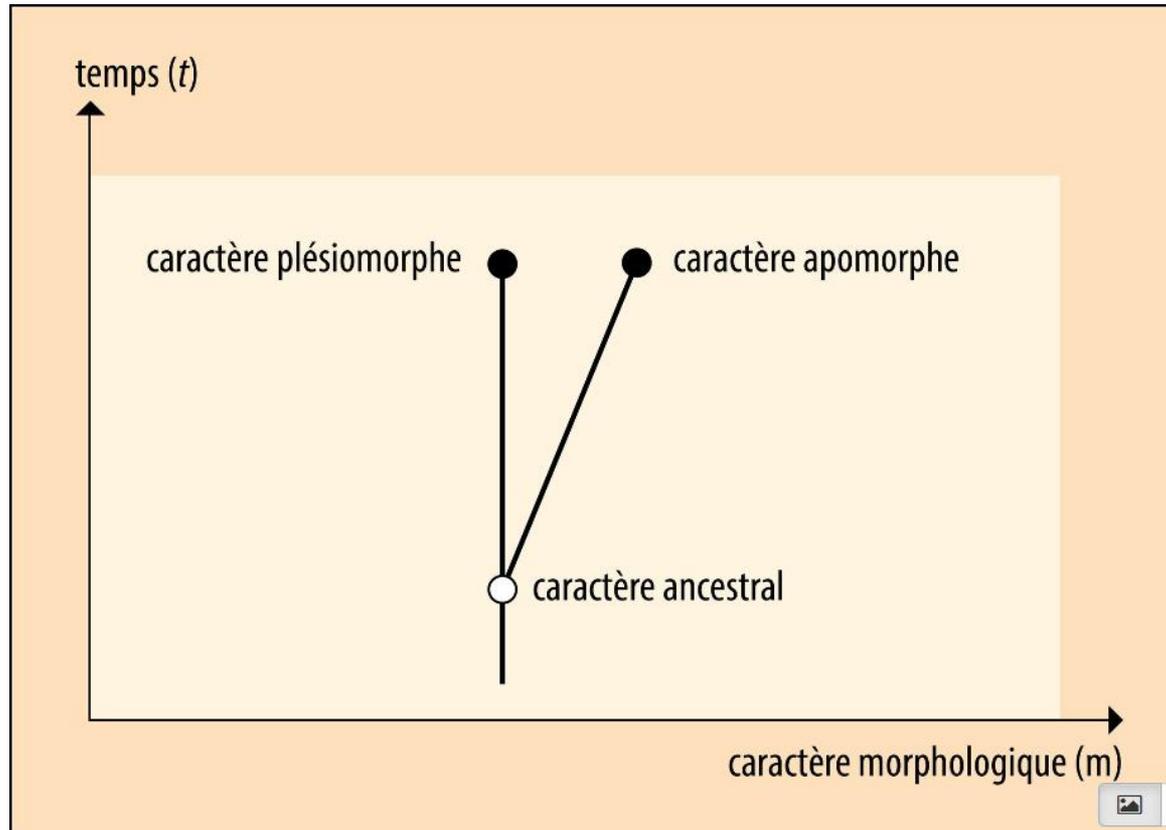
Willi Hennig
(1913-1976)

→ Entomologiste Allemand, révolutionne au milieu du XX siècle la classification du vivant en jetant les bases de la **cladistique**

1950, Grundzüge einer Theorie der *Phylogenetischen Systematik*

→ la distinction – pour un caractère donné – entre les états **plésiomorphes** (primitifs ou généraux) et **apomorphes** (évolués ou particuliers).

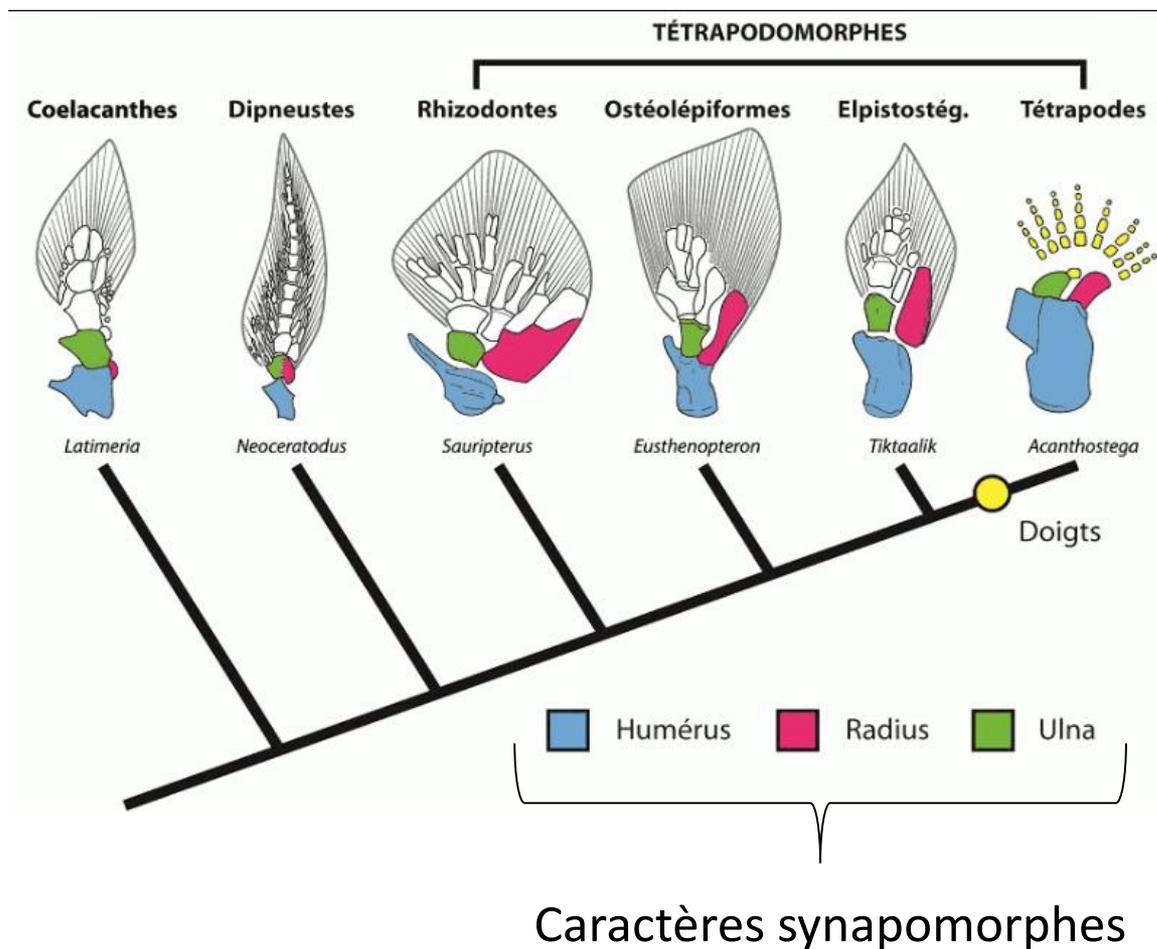
Classification cladistique



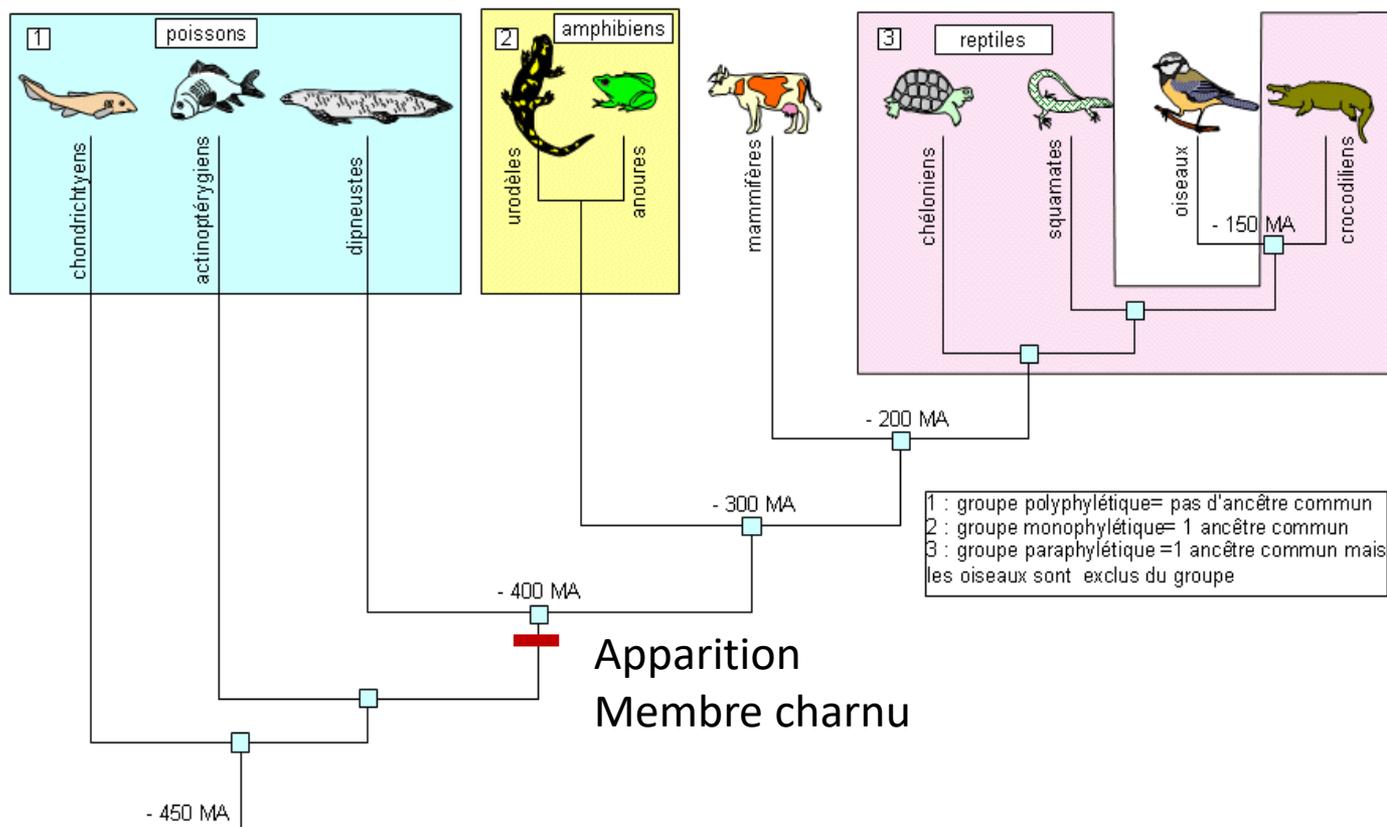
→ le caractère se transforme au cours du temps (apomorphe) , soit il perdure sans changer (plésiomorphe)

Classification cladistique

Exemple de membre charnu

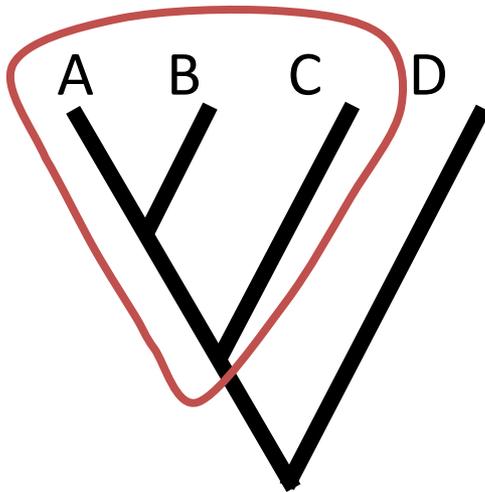


Classification cladistique



Classification cladistique

- Les relations entre les espèces ou les taxons sont indiquées par les états apomorphes *qu'ils partagent* = **synapomorphies**
- Ces relations sont illustrées par un arbre dichotomique ou **cladogramme**

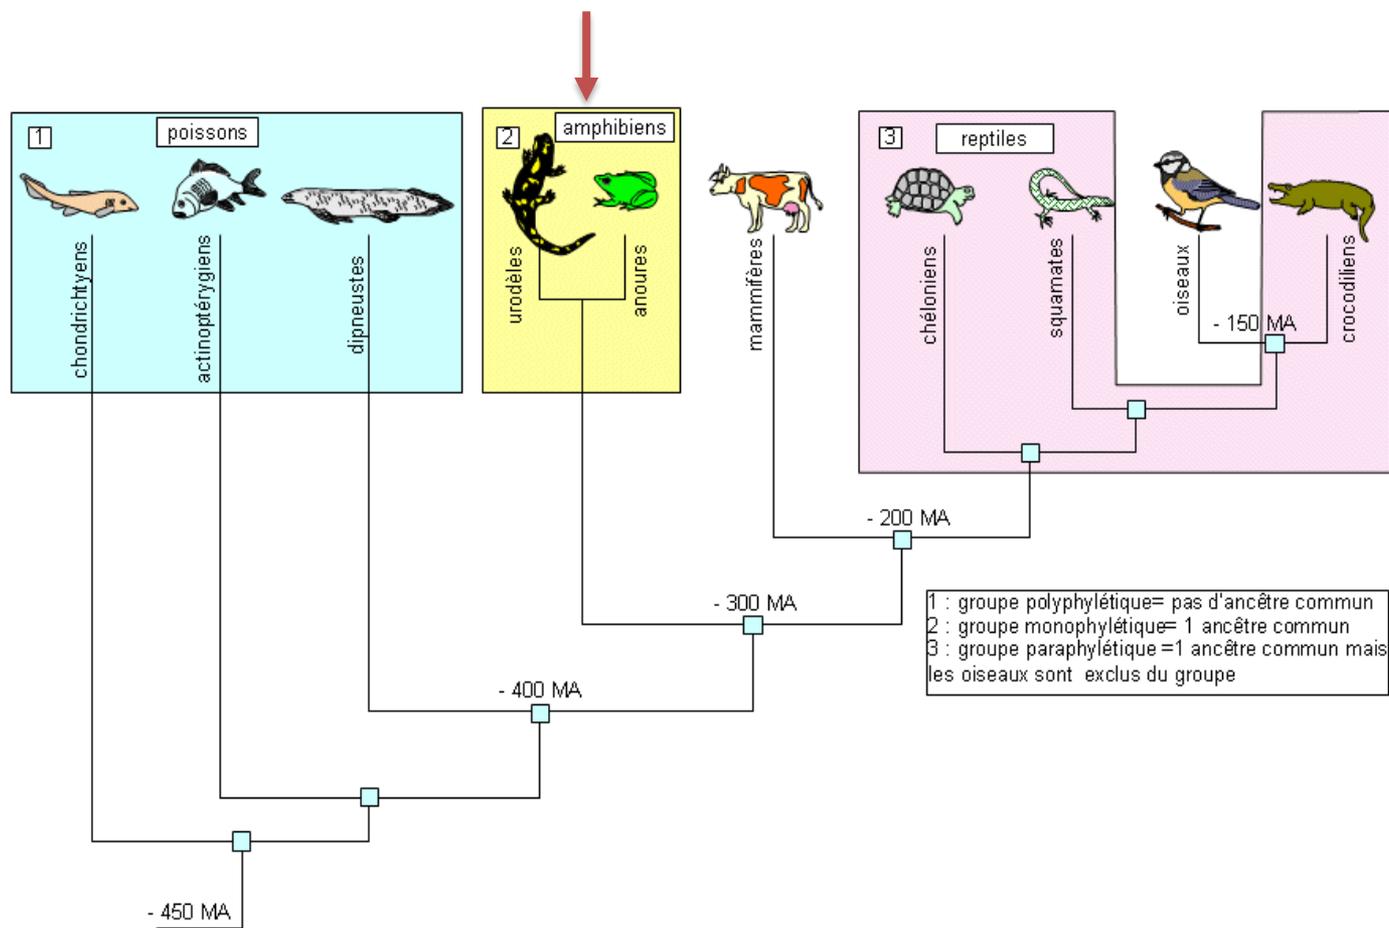


Clade: groupe *monophylétique* d'organismes comprenant tous les descendants d'un ancêtre commun

Uniquement les groupes monophylétiques (clades) sont considérés par la classification cladistique – à des différents niveaux taxonomiques (domaine, règne, ordre, famille etc.)

Classification cladistique

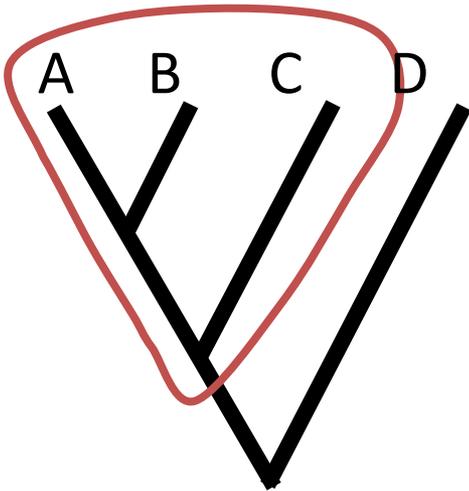
Amphibiens – groupe monophylétique



Classification cladistique

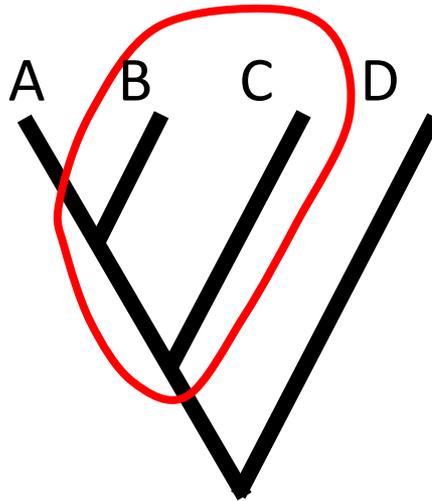
Monophyletic group

Includes an ancestor
all of its descendants



Paraphyletic group

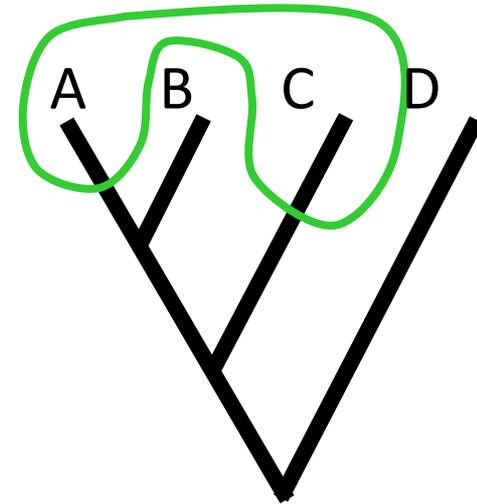
Includes ancestor and
some, but not all of its
descendants



Taxon A is highly derived
and looks very different
from B, C, and ancestor

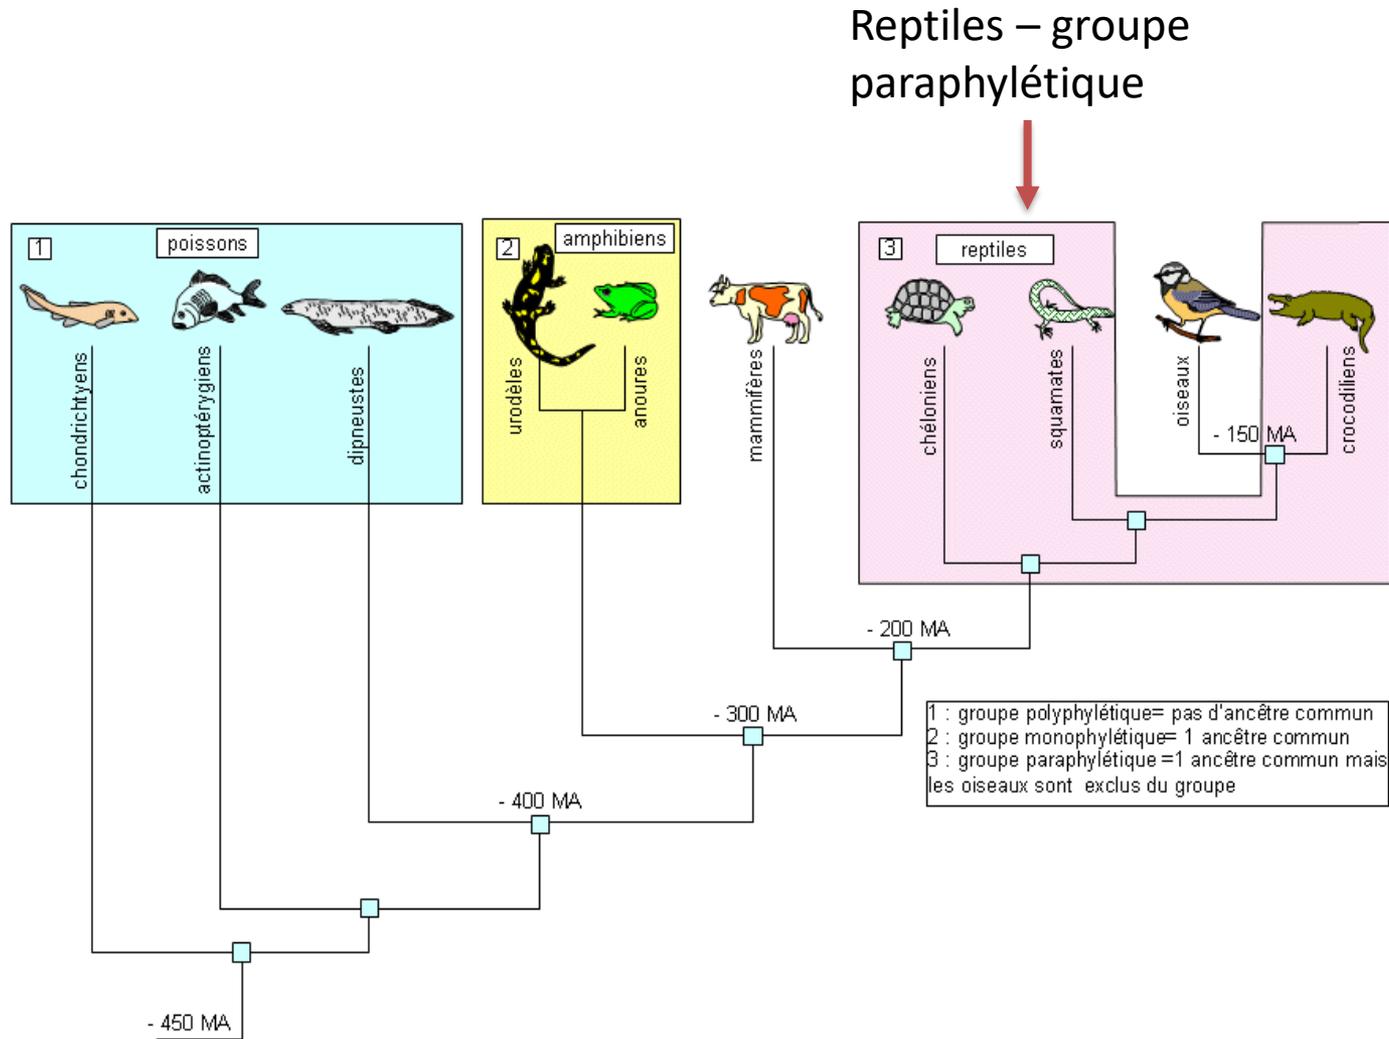
Polyphyletic group

Includes two convergent
descendants but not their
common ancestor



Taxon A and C share
similar traits through
convergent evolution

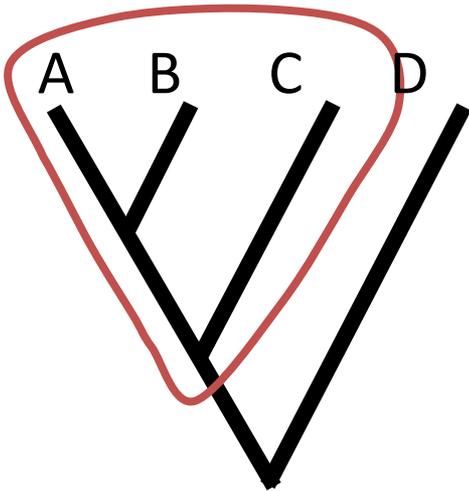
Classification cladistique



Classification cladistique

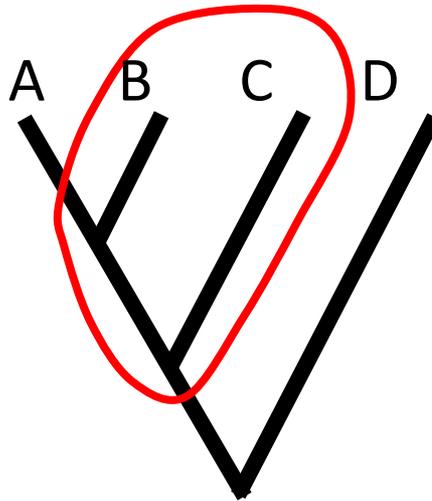
Monophyletic group

Includes an ancestor
all of its descendants



Paraphyletic group

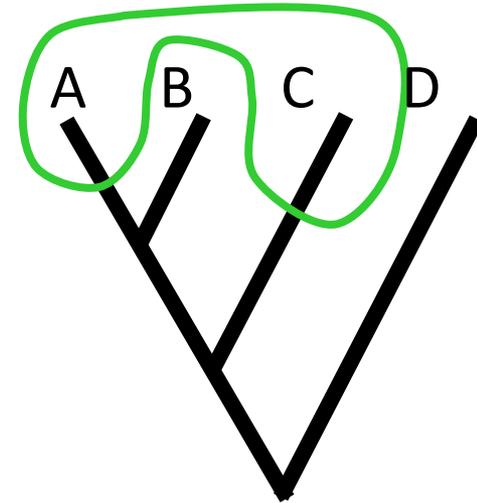
Includes ancestor and
some, but not all of its
descendants



Taxon A is highly derived
and looks very different
from B, C, and ancestor

Polyphyletic group

Includes two convergent
descendants but not their
common ancestor



Taxon A and C share
similar traits through
convergent evolution

Classification cladistique

Poissons – groupe polyphylétique

