Introduction à la phylogénétique

Gwen Kettenburg
Diapositives adaptées de Richard Ree et Andrew Hipp, Université de Chicago

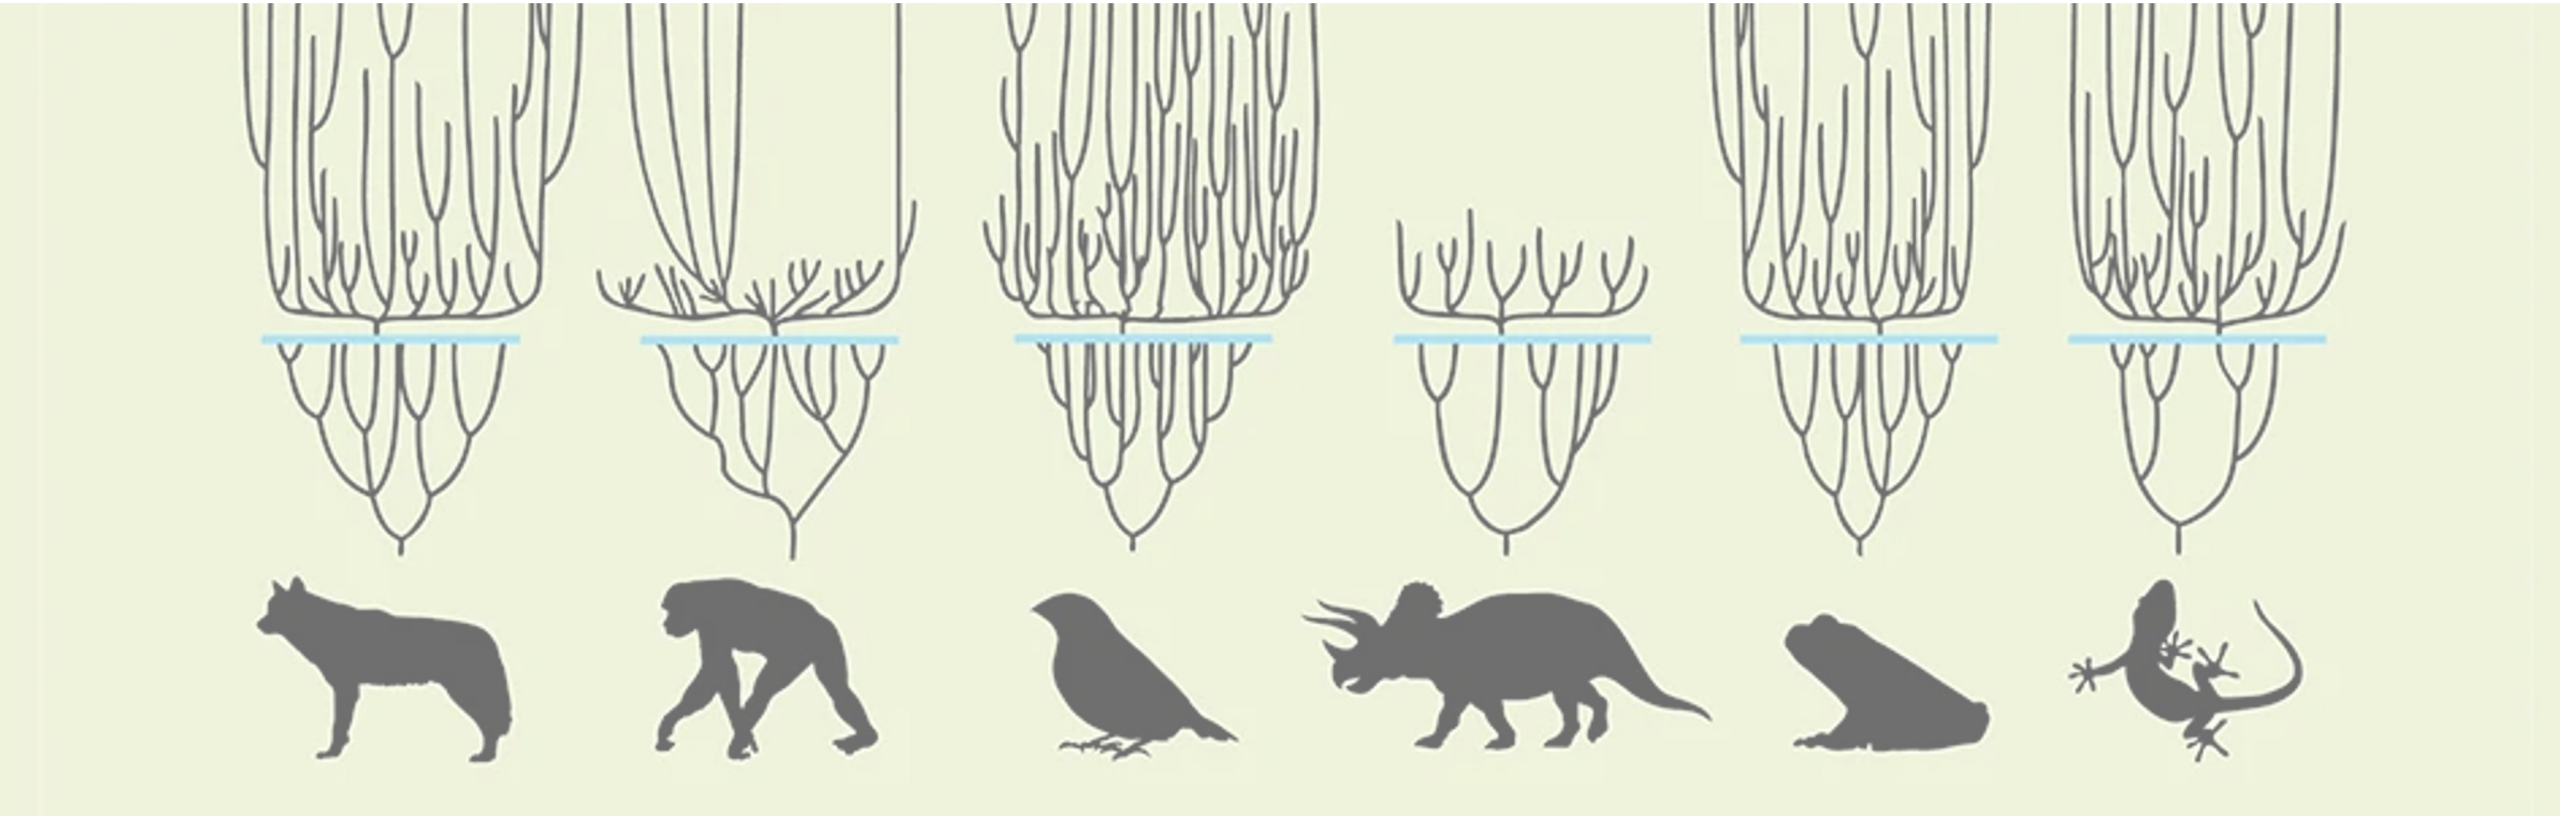

Qu’est-ce qu’une phylogénie ?

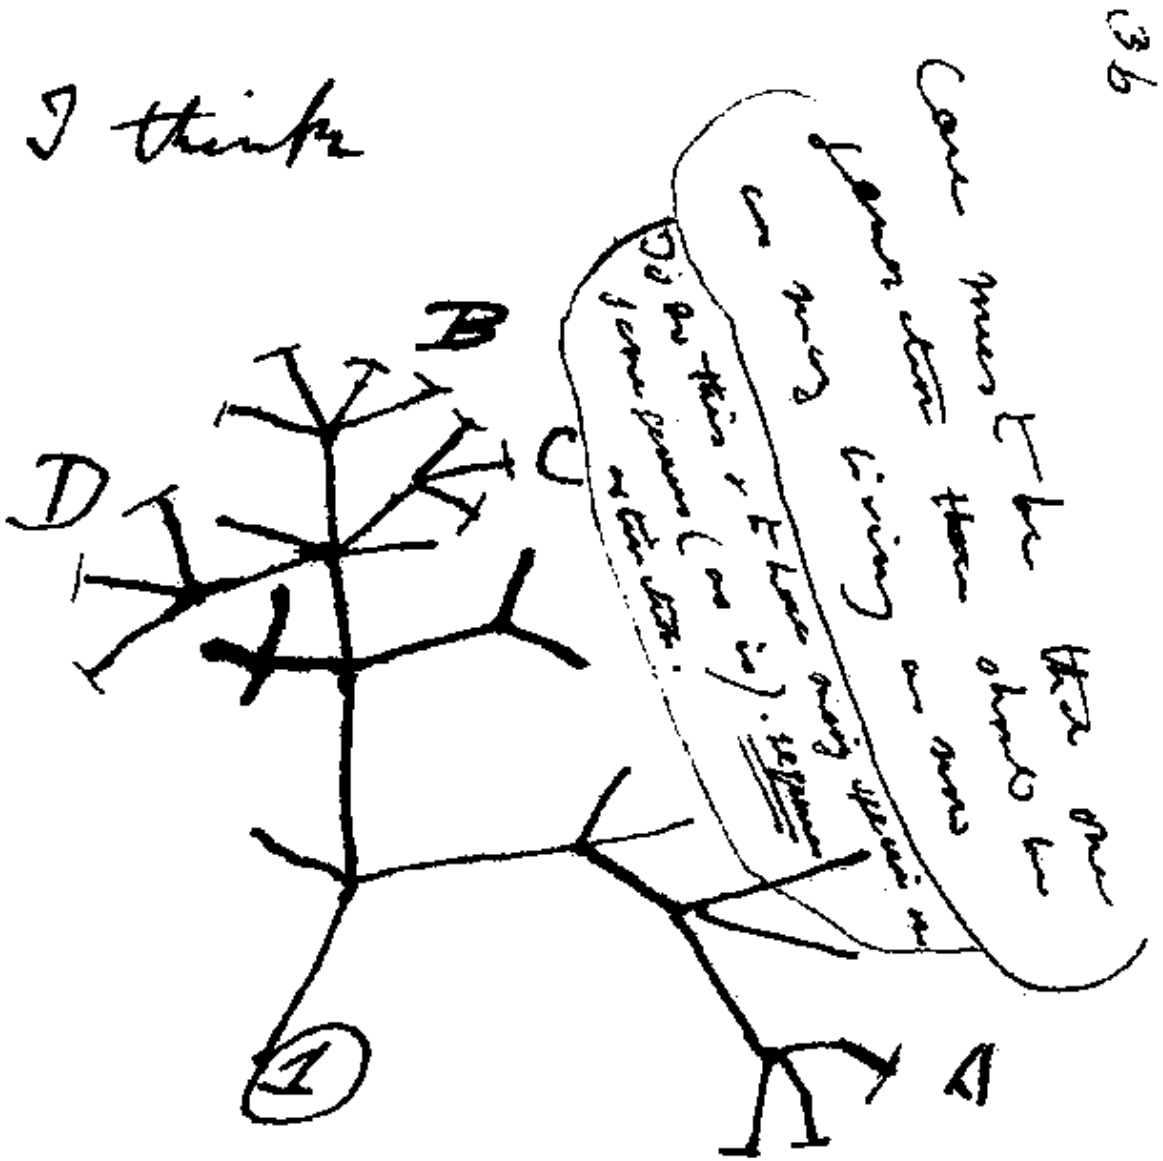

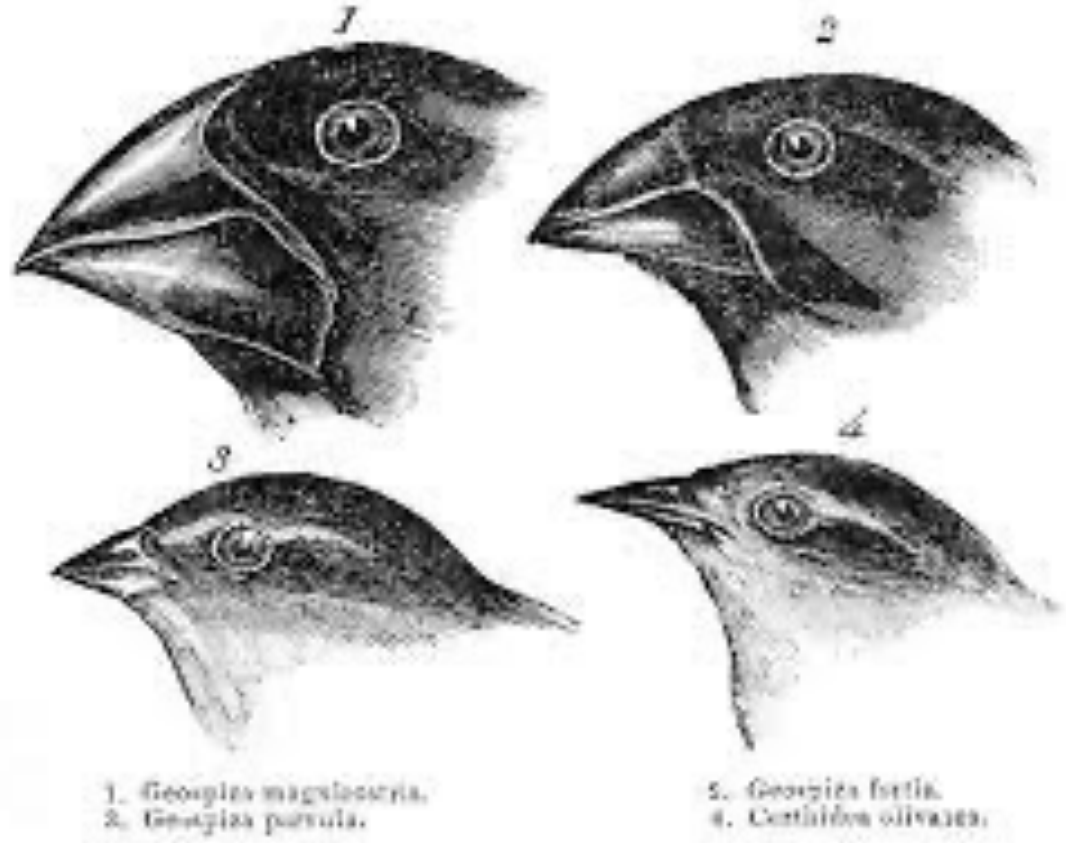

Qu’est-ce qu’une phylogénie ?

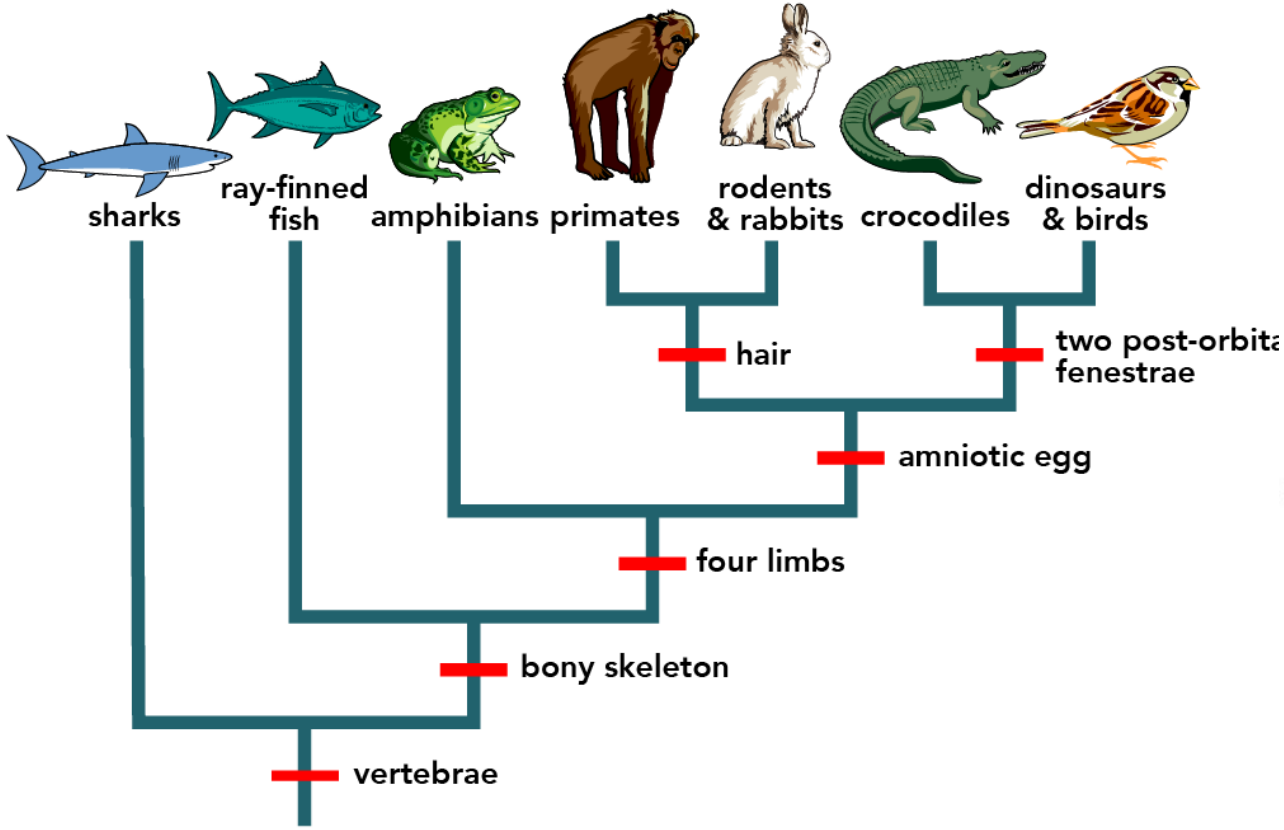

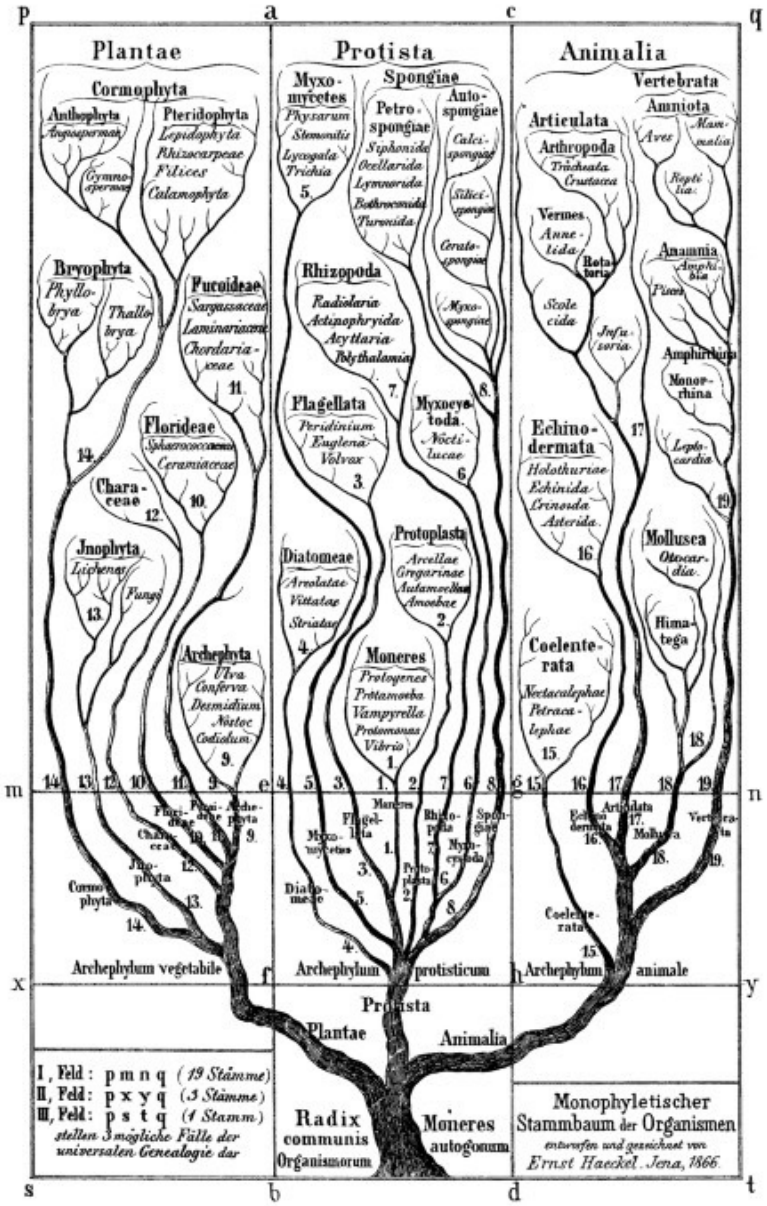

Baum et. al, Nature, 2008

Hossfeld and Levit, Nature, 2016

Qu’est-ce qu’une phylogénie ?

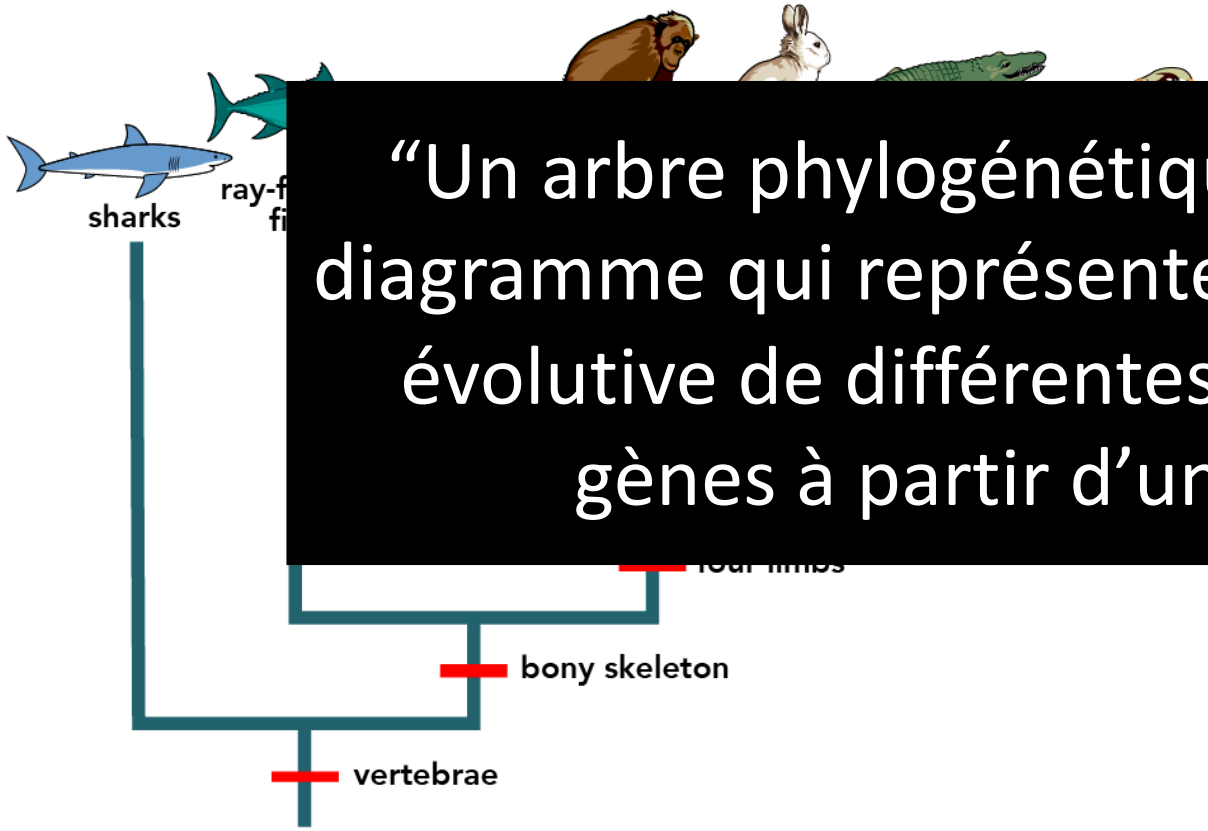

“Un arbre phylogénétique, ou phylogénie, est un diagramme qui représente les lignes de descendance évolutive de différentes espèces, organismes ou gènes à partir d’un ancêtre commun.”

Baum et. al, Nature, 2008

Hossfeld and Levit, Nature, 2016

Objectifs:

- Volet cours magistral
  - Apprenez les bases de ce qu'est une phylogénie
  - Apprendre à lire les phylogénies
  - Bases de la modélisation phylogénétique
- Composant didacticiel
  - Apprenez à créer un arbre phylogénétique à partir de données de séquençage
  - Utilisation de séquences de protéines du cytochrome B du lémurien dans le logiciel RAxML
  - Modifier et visualiser l'arborescence dans R et FigTree

Nucleotide BLAST
nucleotide ▶ nucleotide

R Studio®

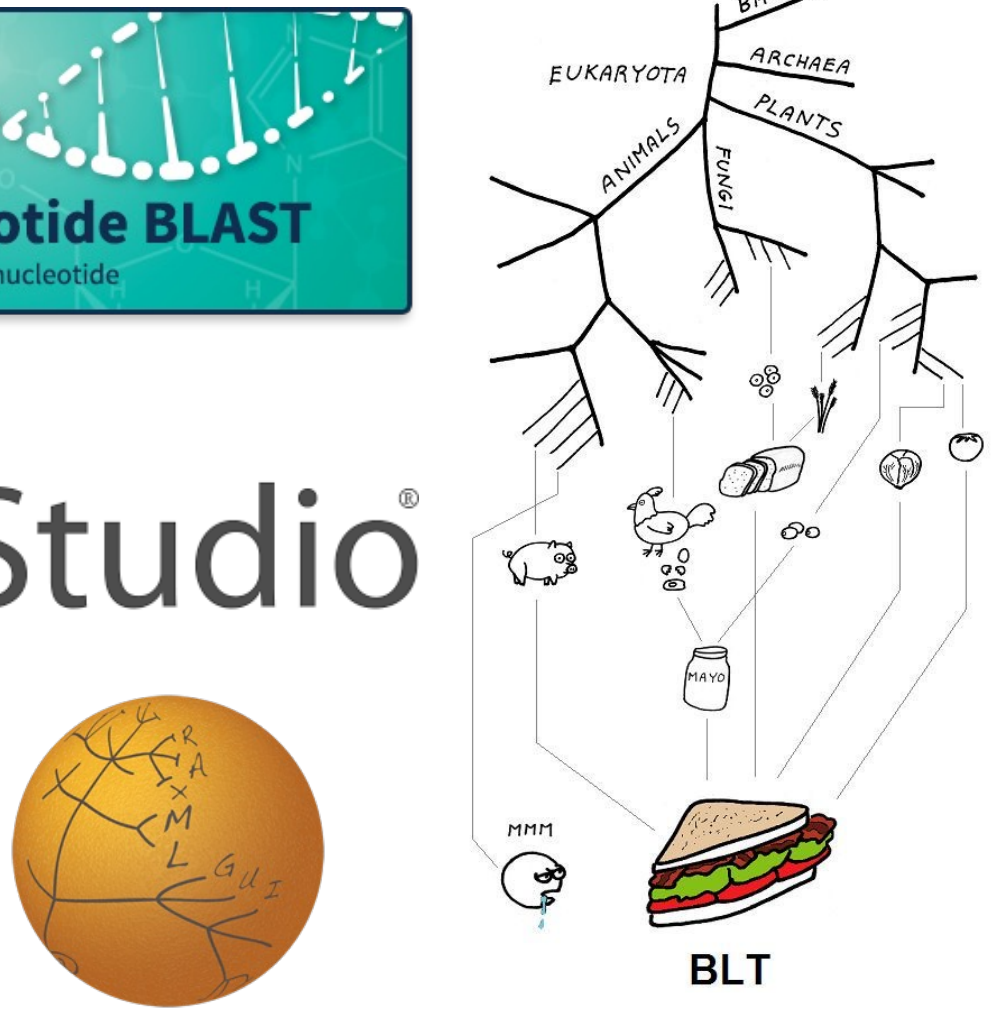

MEGA Molecular Evolutionary Genetics Analysis

Que pouvez-vous faire avec les phylogénies ?

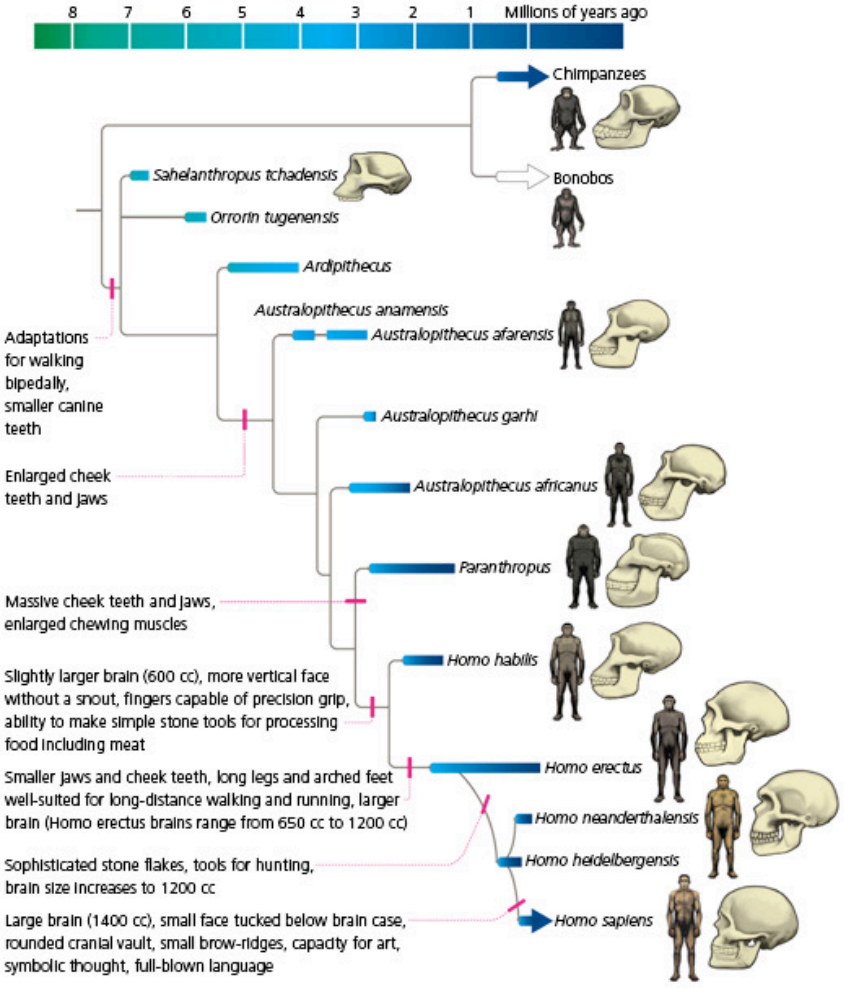

UC Museum of Paleontology

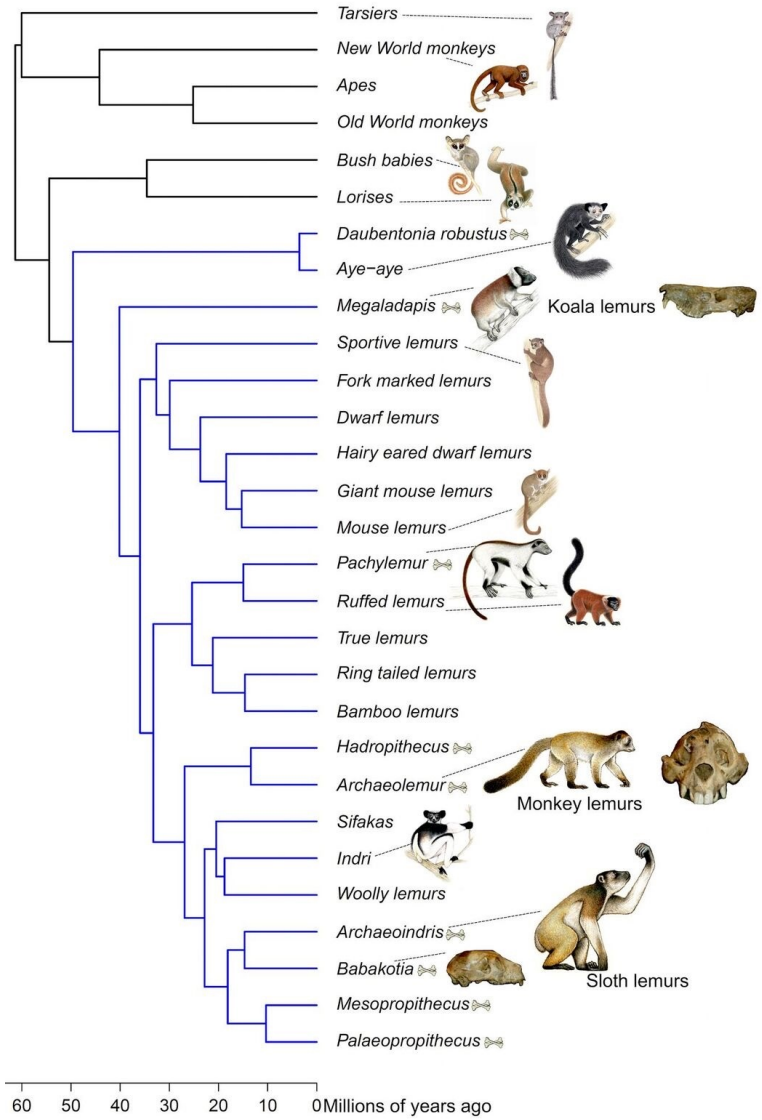

Herrera et al 2016

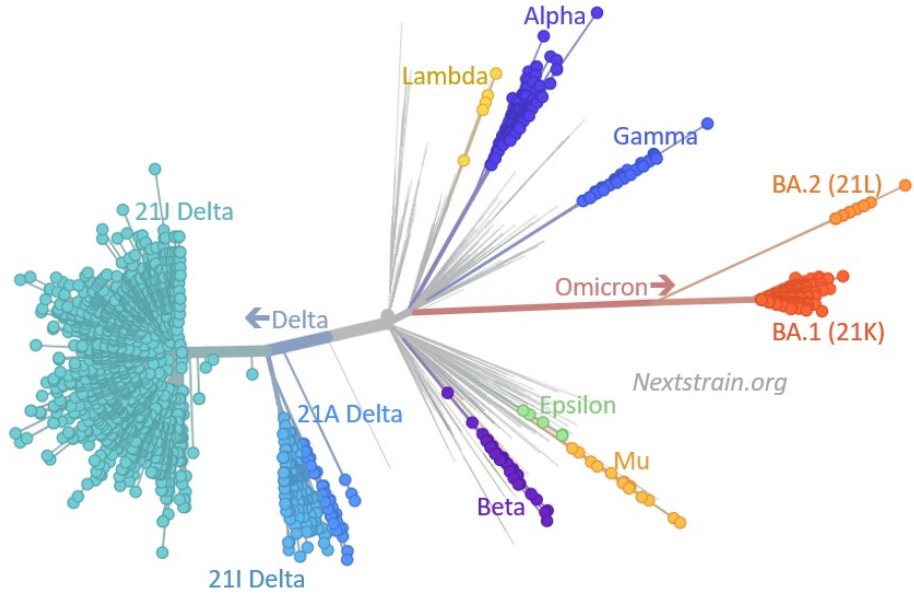

Lowe 2022

Que pouvez-vous faire avec les phylogénies ?

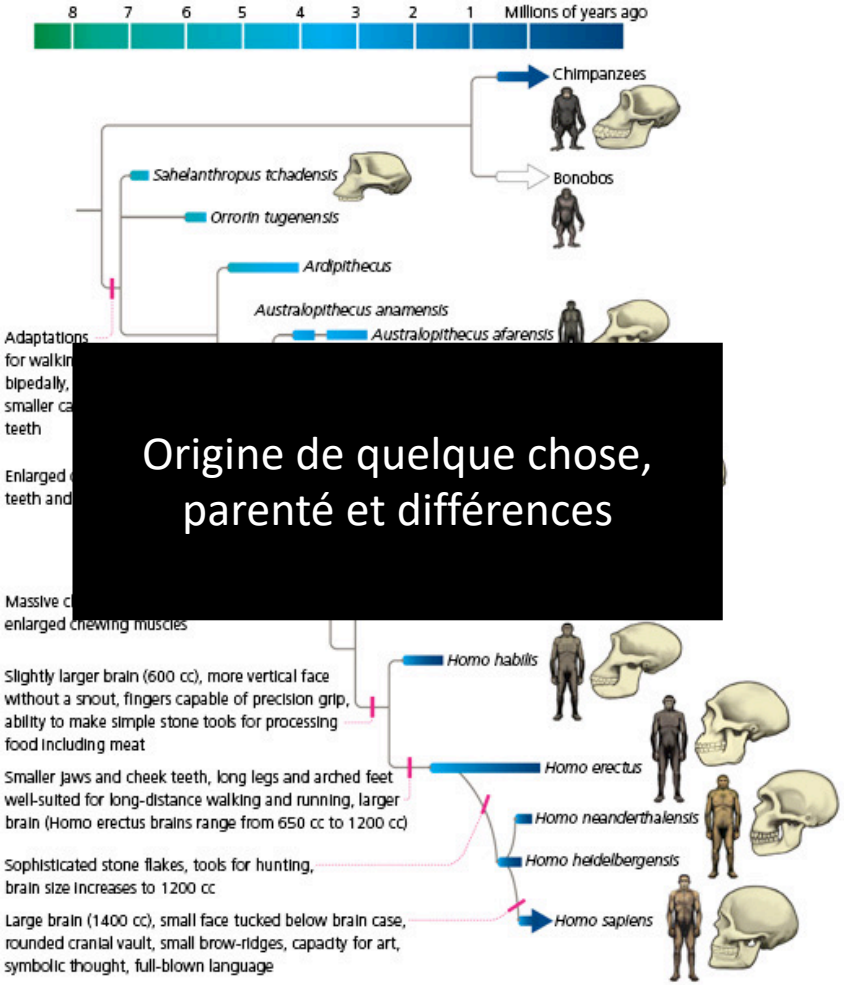

Origine de quelque chose, parenté et différences

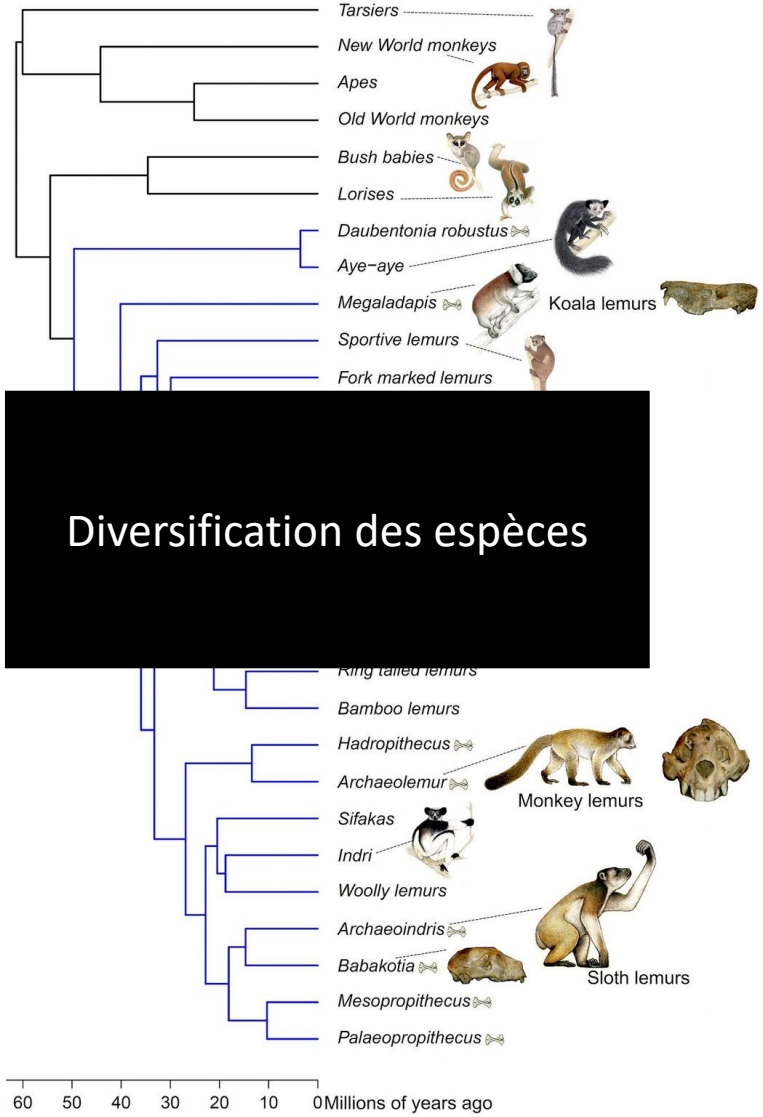

Diversification des espèces

Changements en temps réel

UC Museum of Paleontology

Herrera et al 2016

Lowe 2022

Phylodynamique

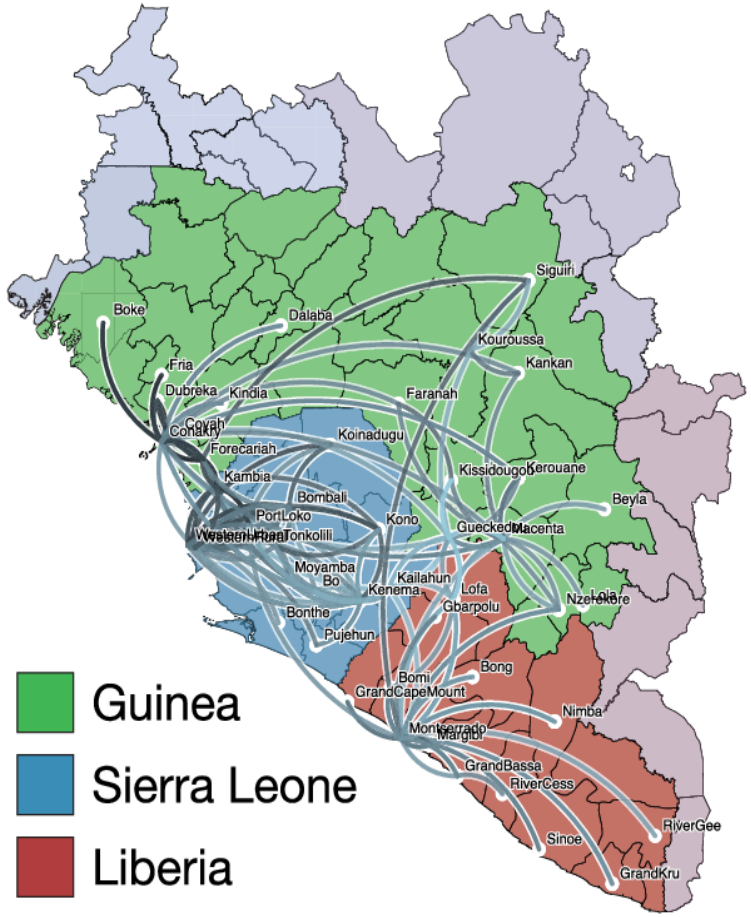

OÙ va-t-il ?

Arbres bayésiens

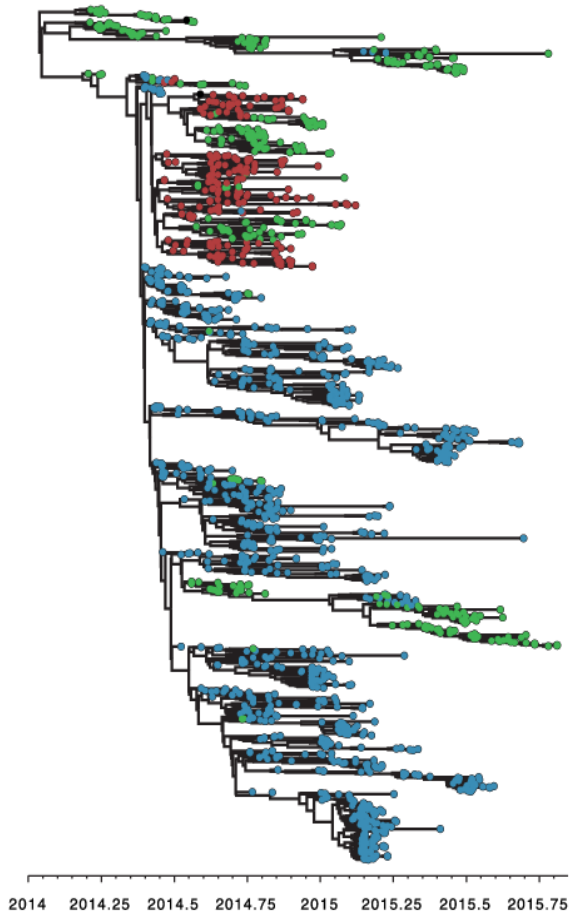

QUAND est l'ancêtre commun le plus récent ?

Maximum de vraisemblance

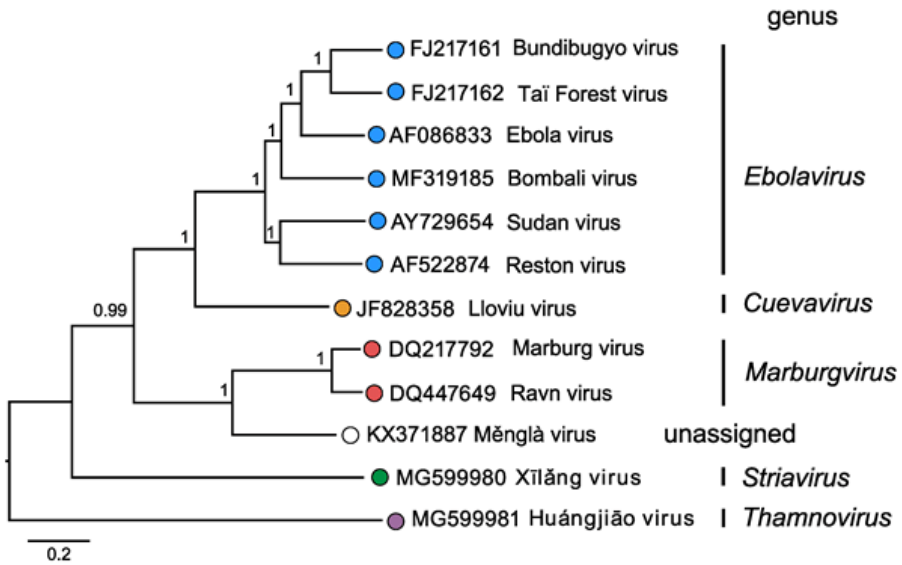

À quel point est-ce différent de ce que l'on connaît ?

Suchard et al. 2018
Kuhn et al. 2019

Phylodynamique

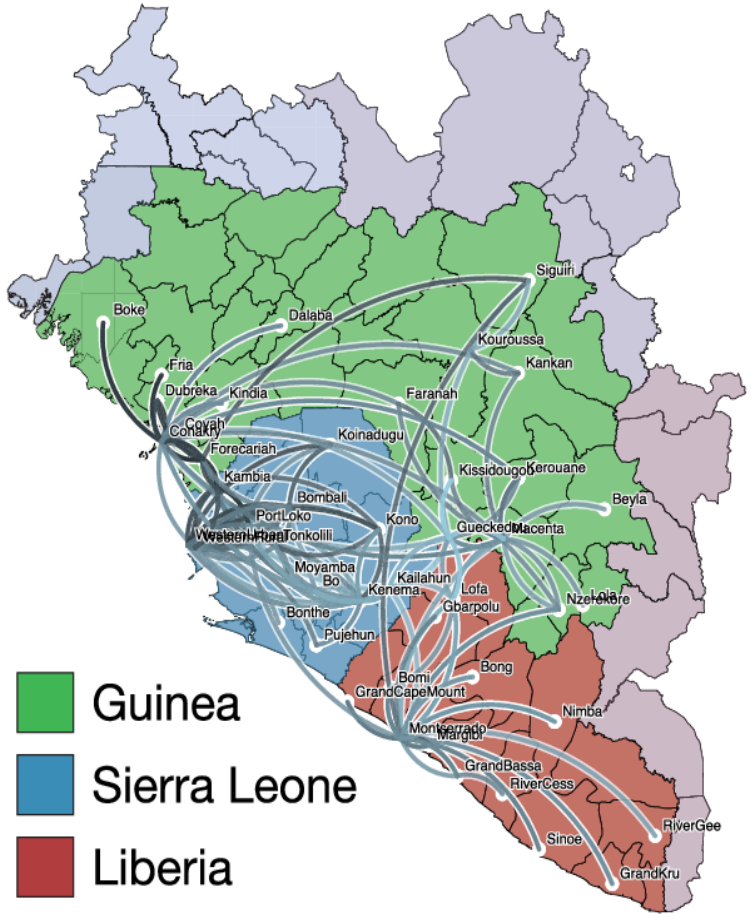

OÙ va-t-il ?

Arbres bayésiens

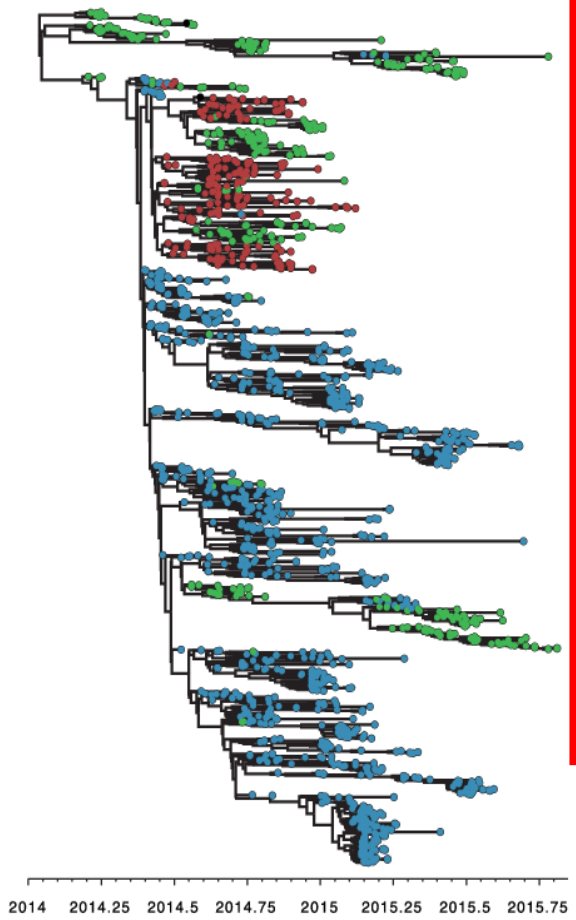

QUAND est l'ancêtre commun le plus récent ?

Maximum de vraisemblance

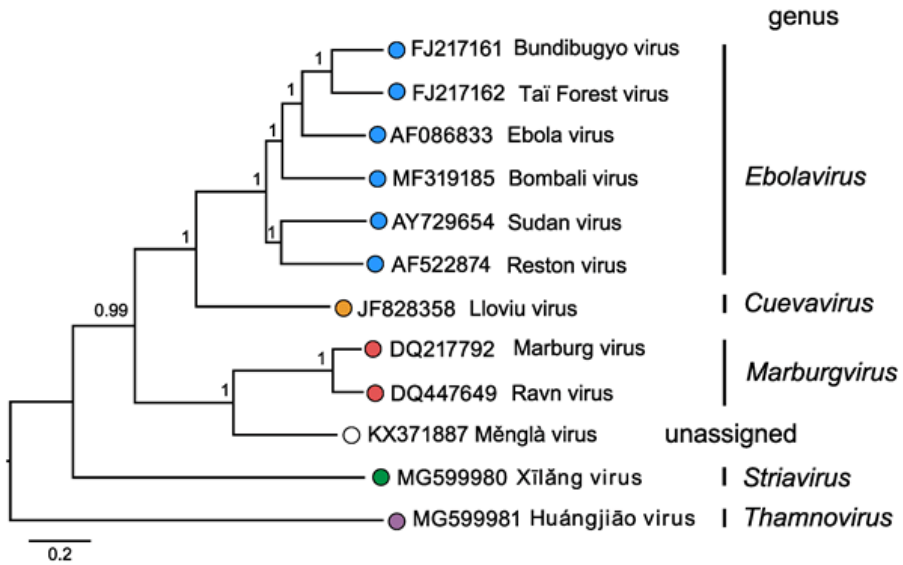

À quel point est-ce différent de ce que l'on connaît ?

Suchard et al. 2018
Kuhn et al. 2019

Point de contrôle!

- Qu’est-ce qu’une phylogénie ?
- Peut-on utiliser une analyse phylogénétique avec des données temporelles ?
- Pouvez-vous utiliser une analyse phylogénétique pour voir à quel point quelque chose est similaire à un autre ?

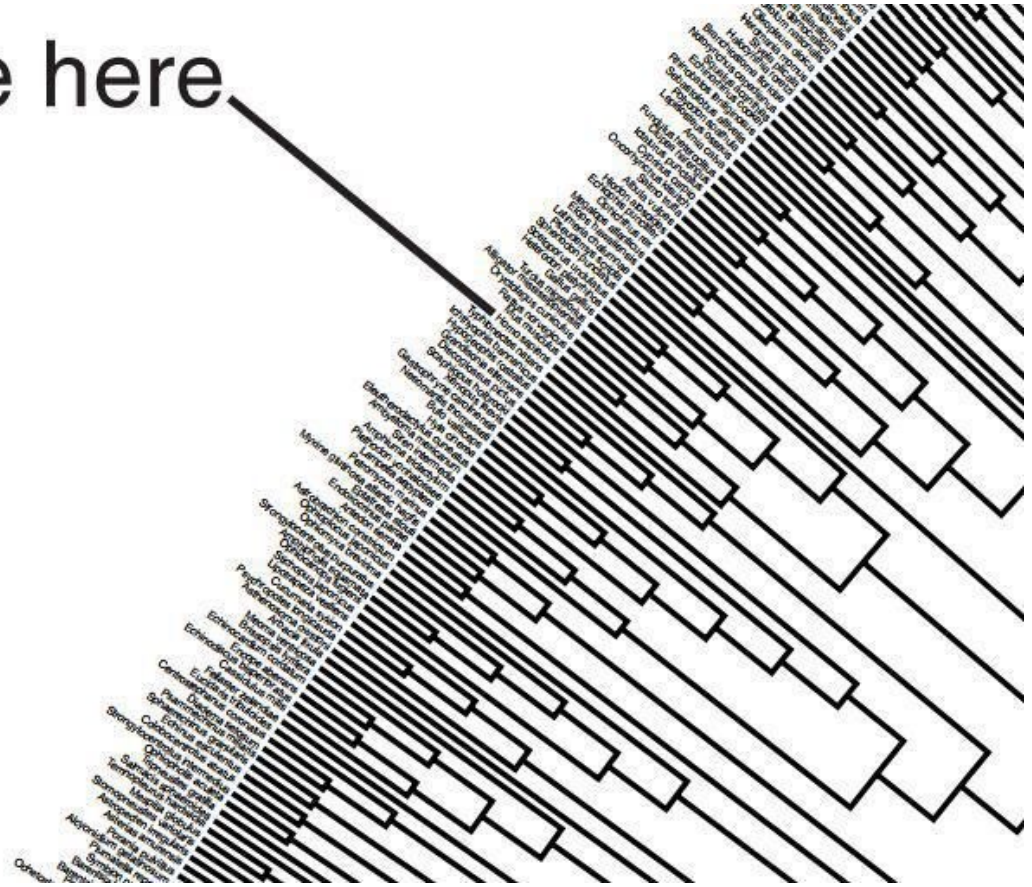

Anatomie d'une phylogénie

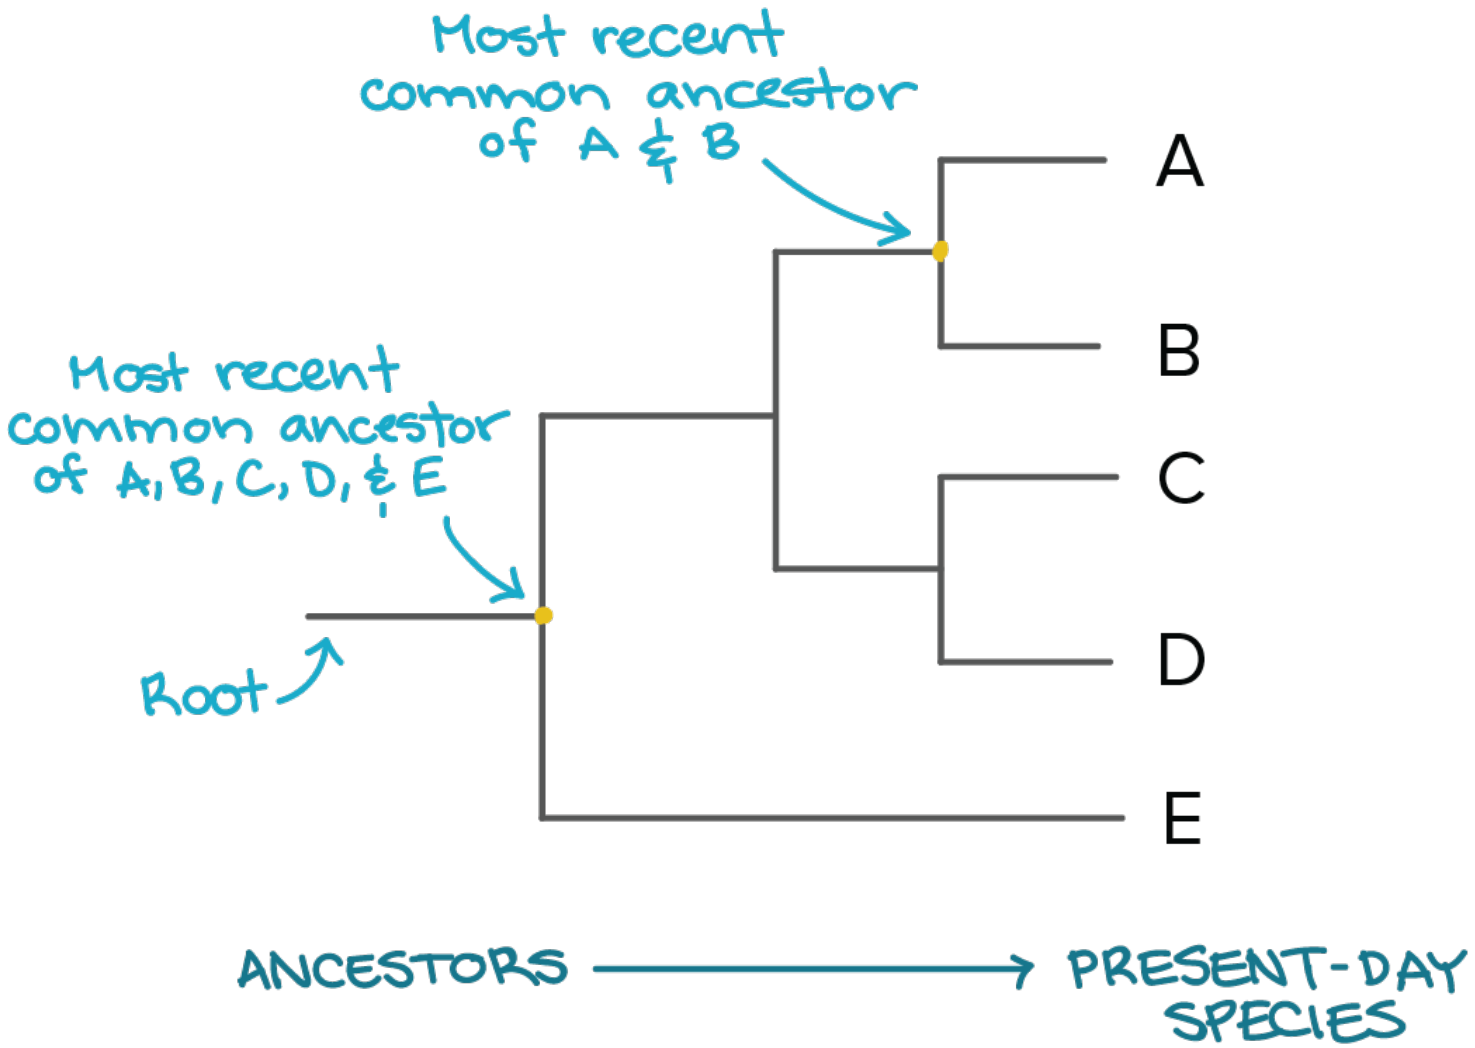

CONFIDENCE

BOOTSTRAP VALUE	
STRONGLY SUPPORTED	>90%
WELL SUPPORTED	70%-90%
WEAKLY SUPPORTED	50%-70%
NOT SUPPORTED	<50%

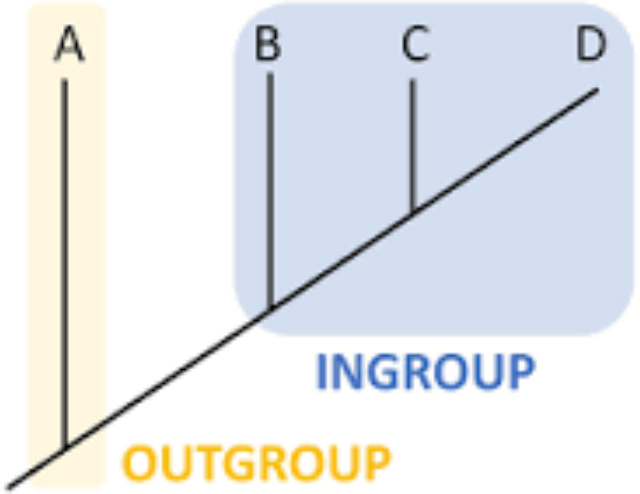

Cladogramme versus arbre phylogénétique

CLADOGRAM

– the relationships are ***hypothetical***

– you can easily make on your own

PHYLOGENETIC TREE

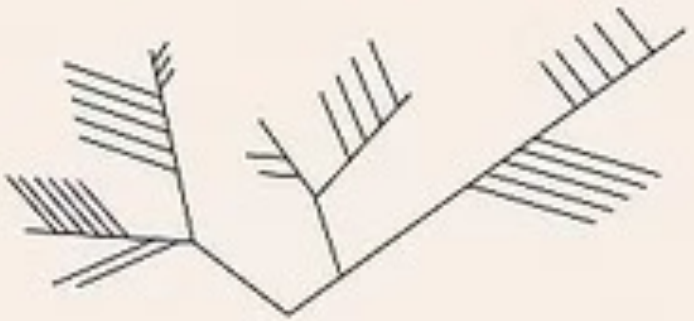

– the relationships are ***backed by molecular evidence***

– should have access to DNA or other molecular data

Wikipédia, 2022

Cladogram versus phylogenetic tree

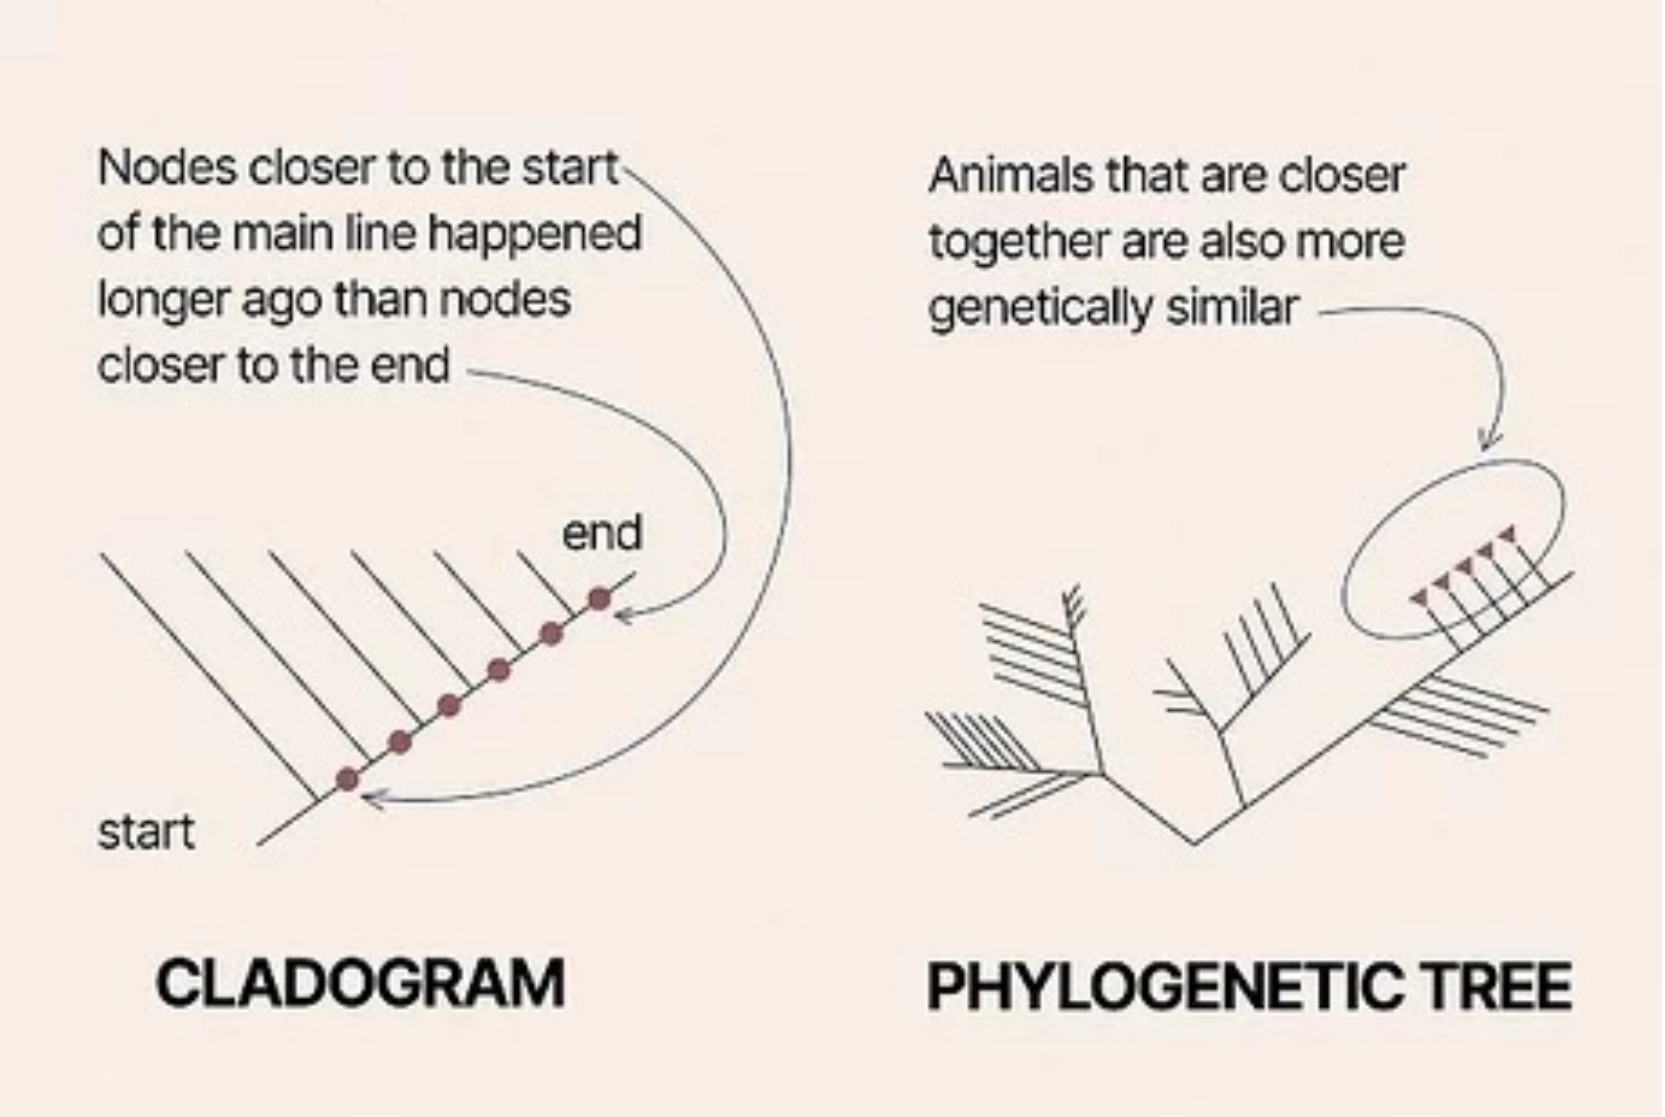

Utiliseriez-vous un cladogramme ou un arbre phylogénétique pour :

- **Hypothèses sur les ancêtres de l'homme**
- **Traquer un nouvel agent pathogène**

Wikipédia, 2022

Point de contrôle!

- Les cladogrammes sont bons pour générer des hypothèses, les phylogénies montrent des similitudes génétiques
- Que montrent les valeurs d'amorçage ?
- Qu'est-ce qu'une racine ?

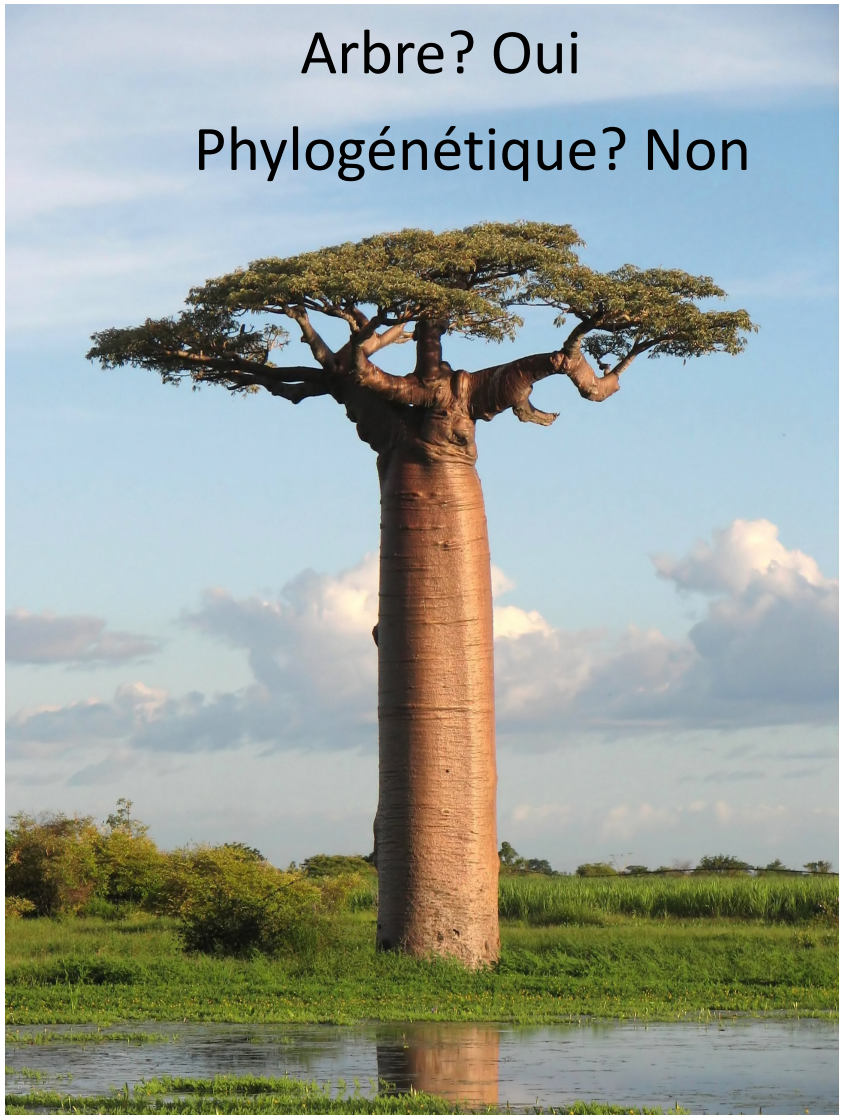

Parcimonie vs. Vraisemblance

- Parcimonie : nombre minimum de modifications
- Vraisemblance : probabilité maximale que les données aient évolué sur l'arbre

branch length can mean different things:

- minimum number of changes (parsimony)
- time; opportunity for change
- expected number of changes, given a model of evolution

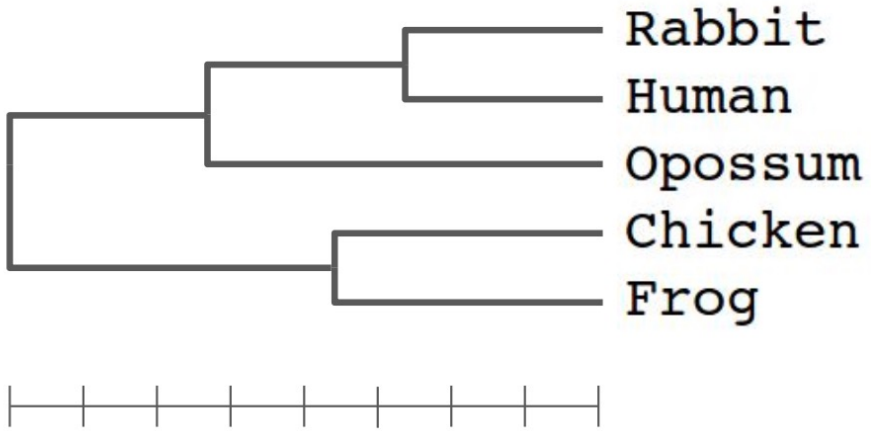

proposed tree has **branch lengths** in units of expected number of changes per site

Adapté de Ree et Hipp, UChicago, 2021

Parcimonie : nombre minimum de changements, quel que soit le moment ou l'opportunité.

Qu'est-ce qui est le moins parcimonieux ?

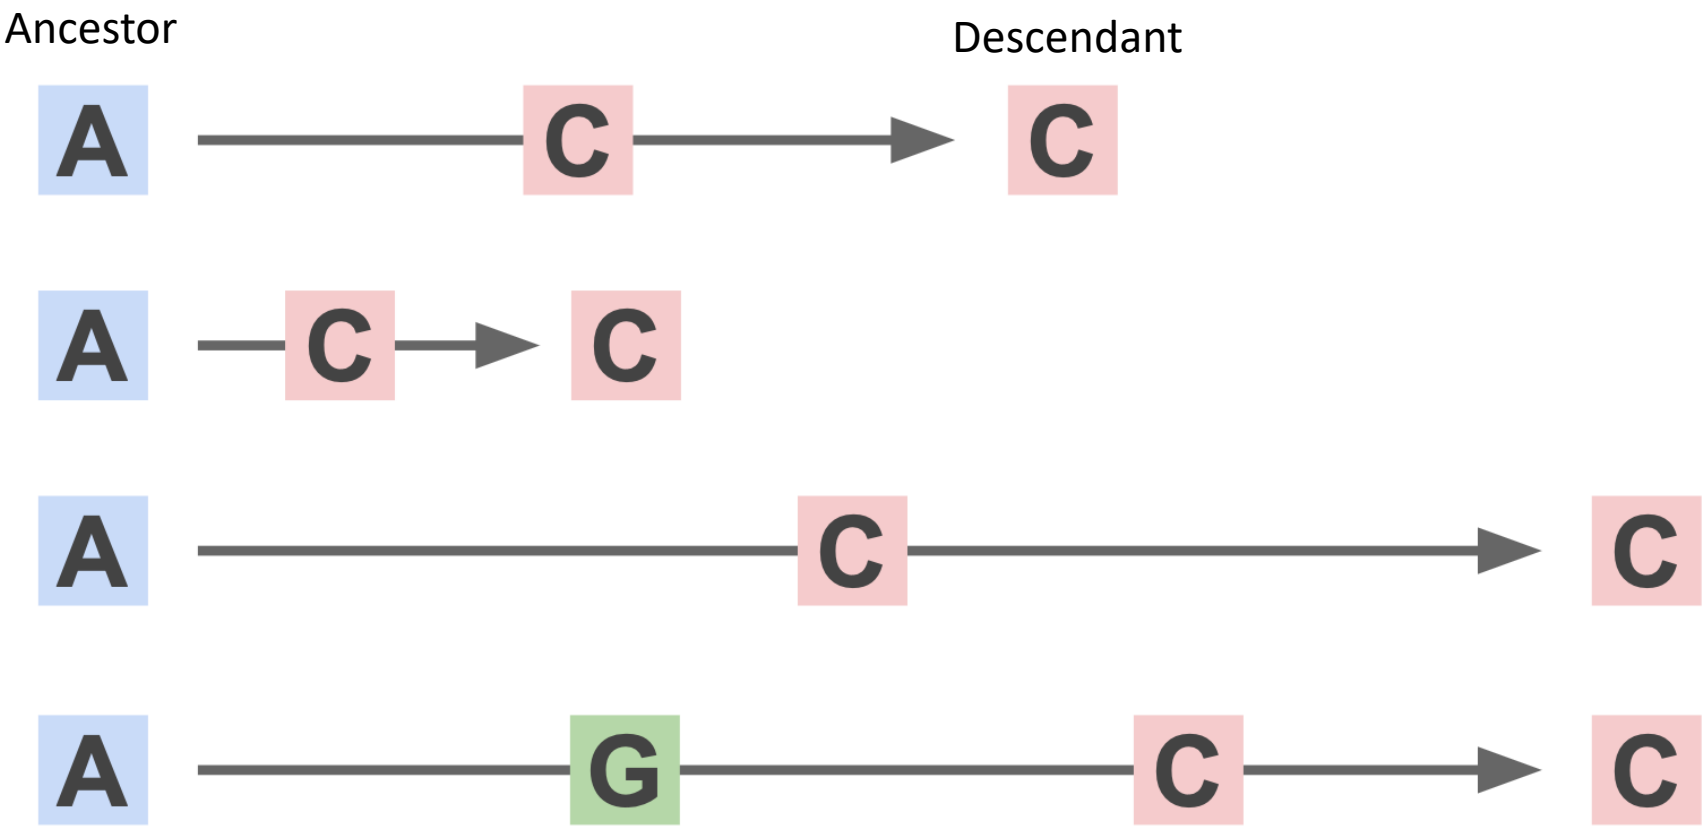

Adapté de Ree et Hipp, UChicago, 2021

Vraisemblance : la probabilité d'un statut d'ancêtre et de descendant est fonction du temps (longueur de la branche)

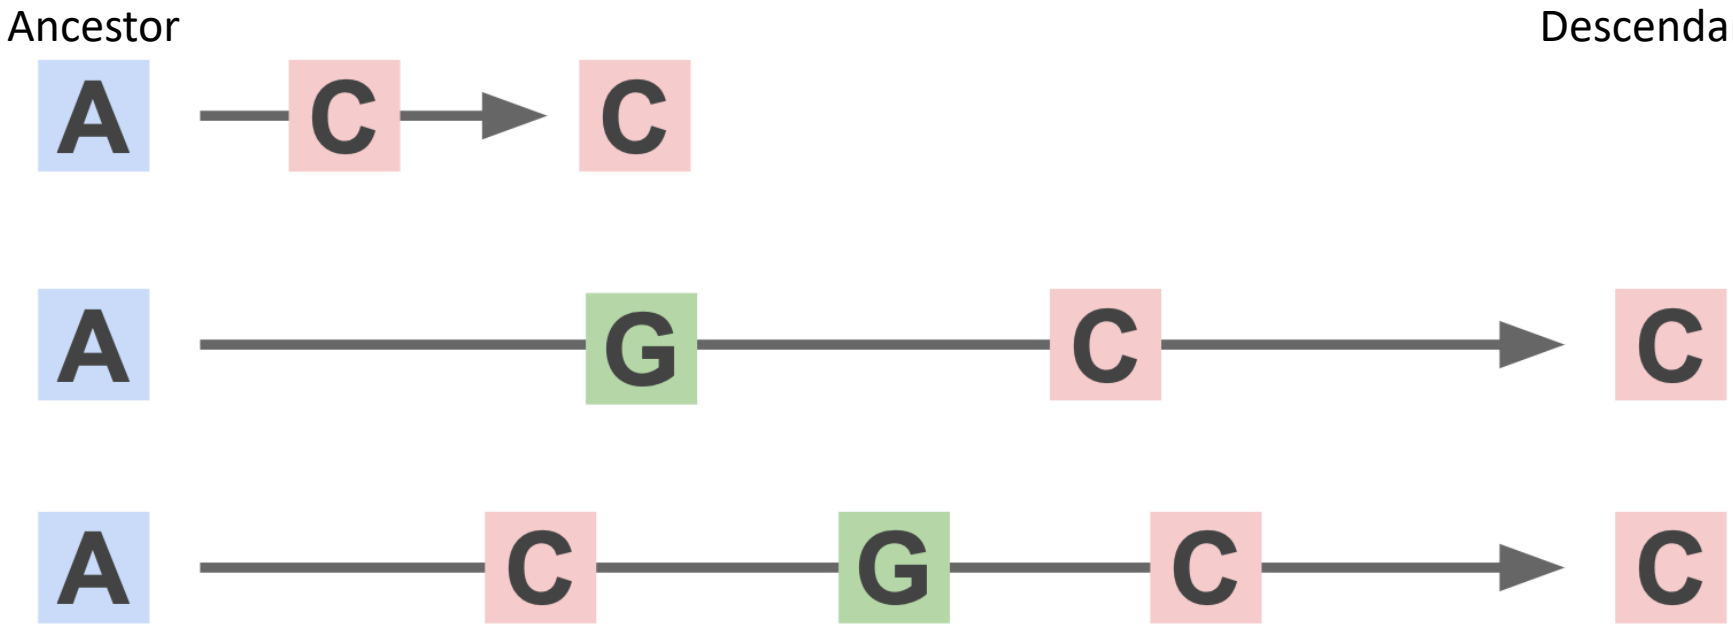

Nous ne savons pas quelle est l'histoire réelle du changement, alors utilisez un modèle d'évolution pour considérer toutes les histoires possibles (probabilité maximale)

Adapté de Ree et Hipp, UChicago, 2021

Vraisemblance (suite).

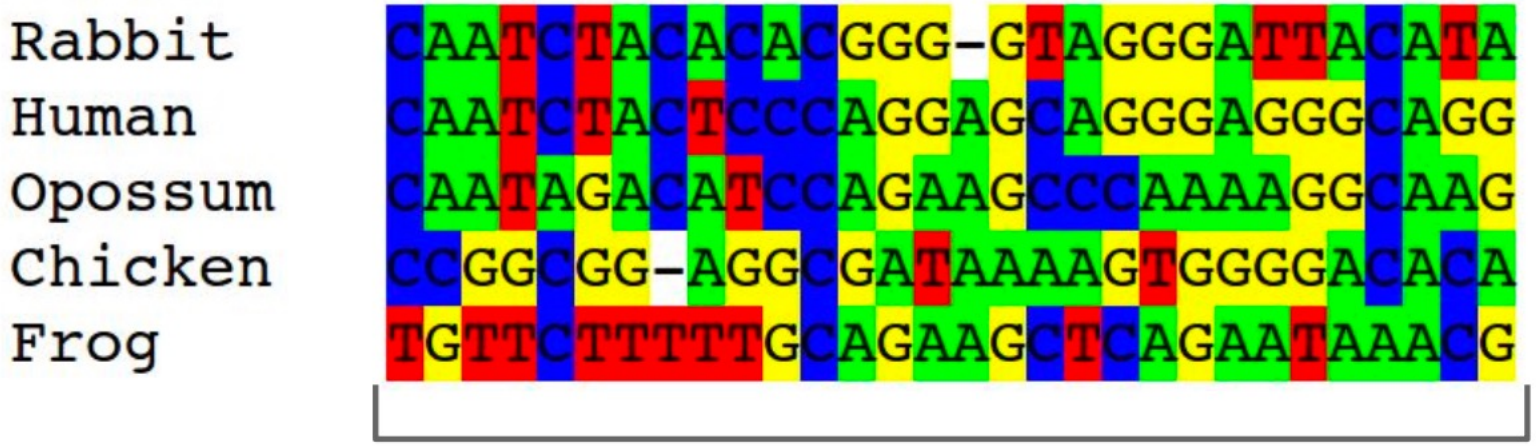

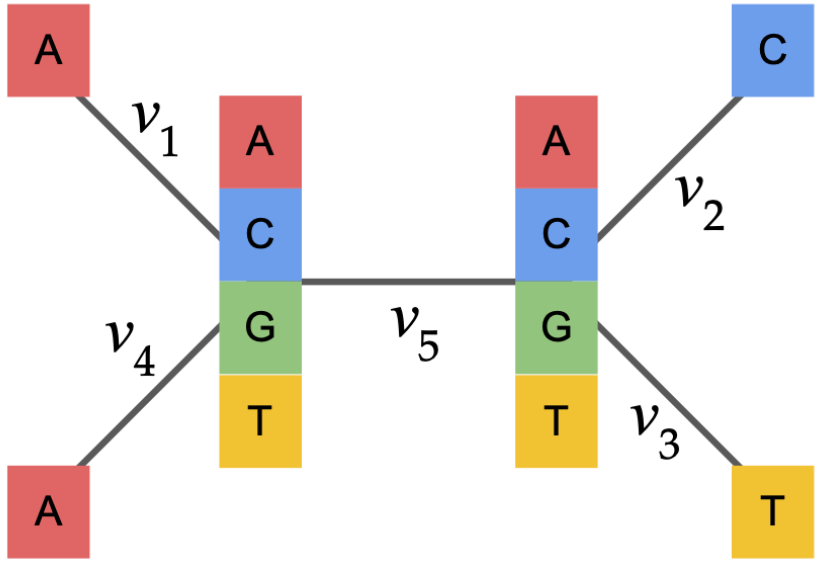

Paramètres : topologie arborescente, longueurs des branches, taux de substitution estimés pour maximiser la vraisemblance des données

Adapté de Ree et Hipp, UChicago, 2021

Jusqu’à présent…

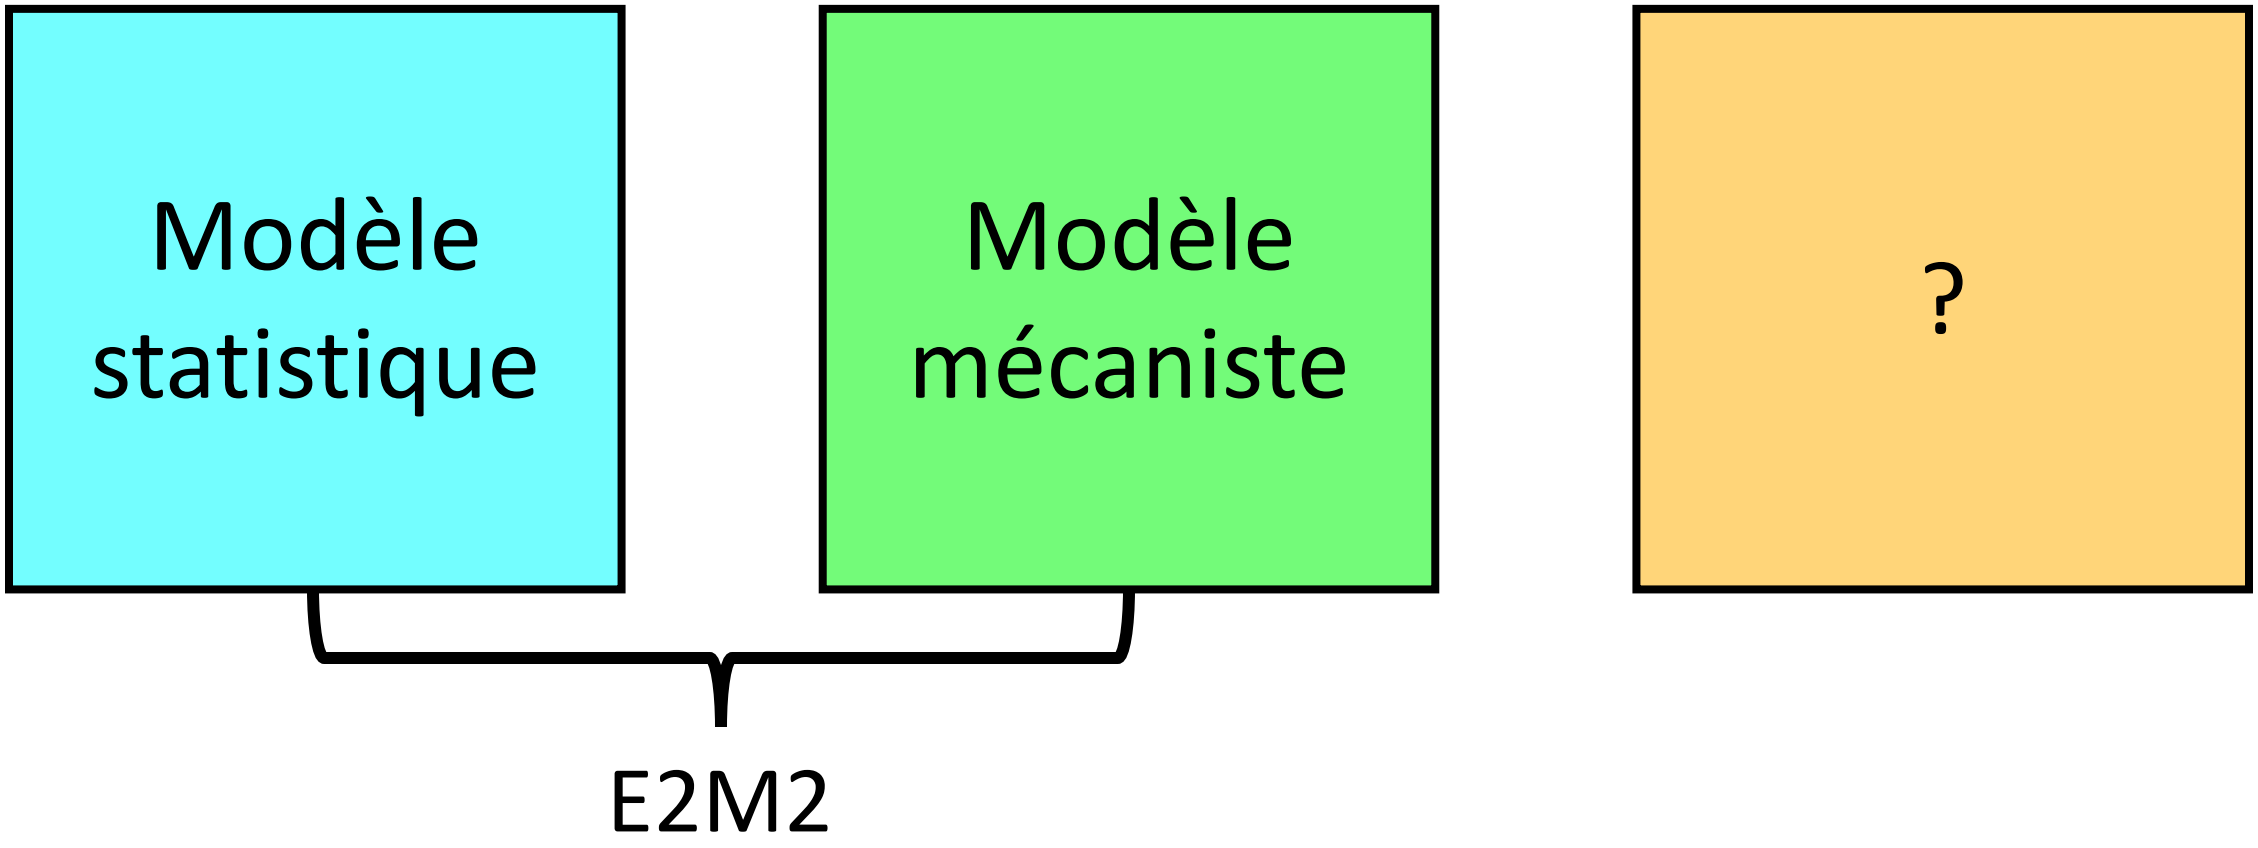

Aujourd’hui...

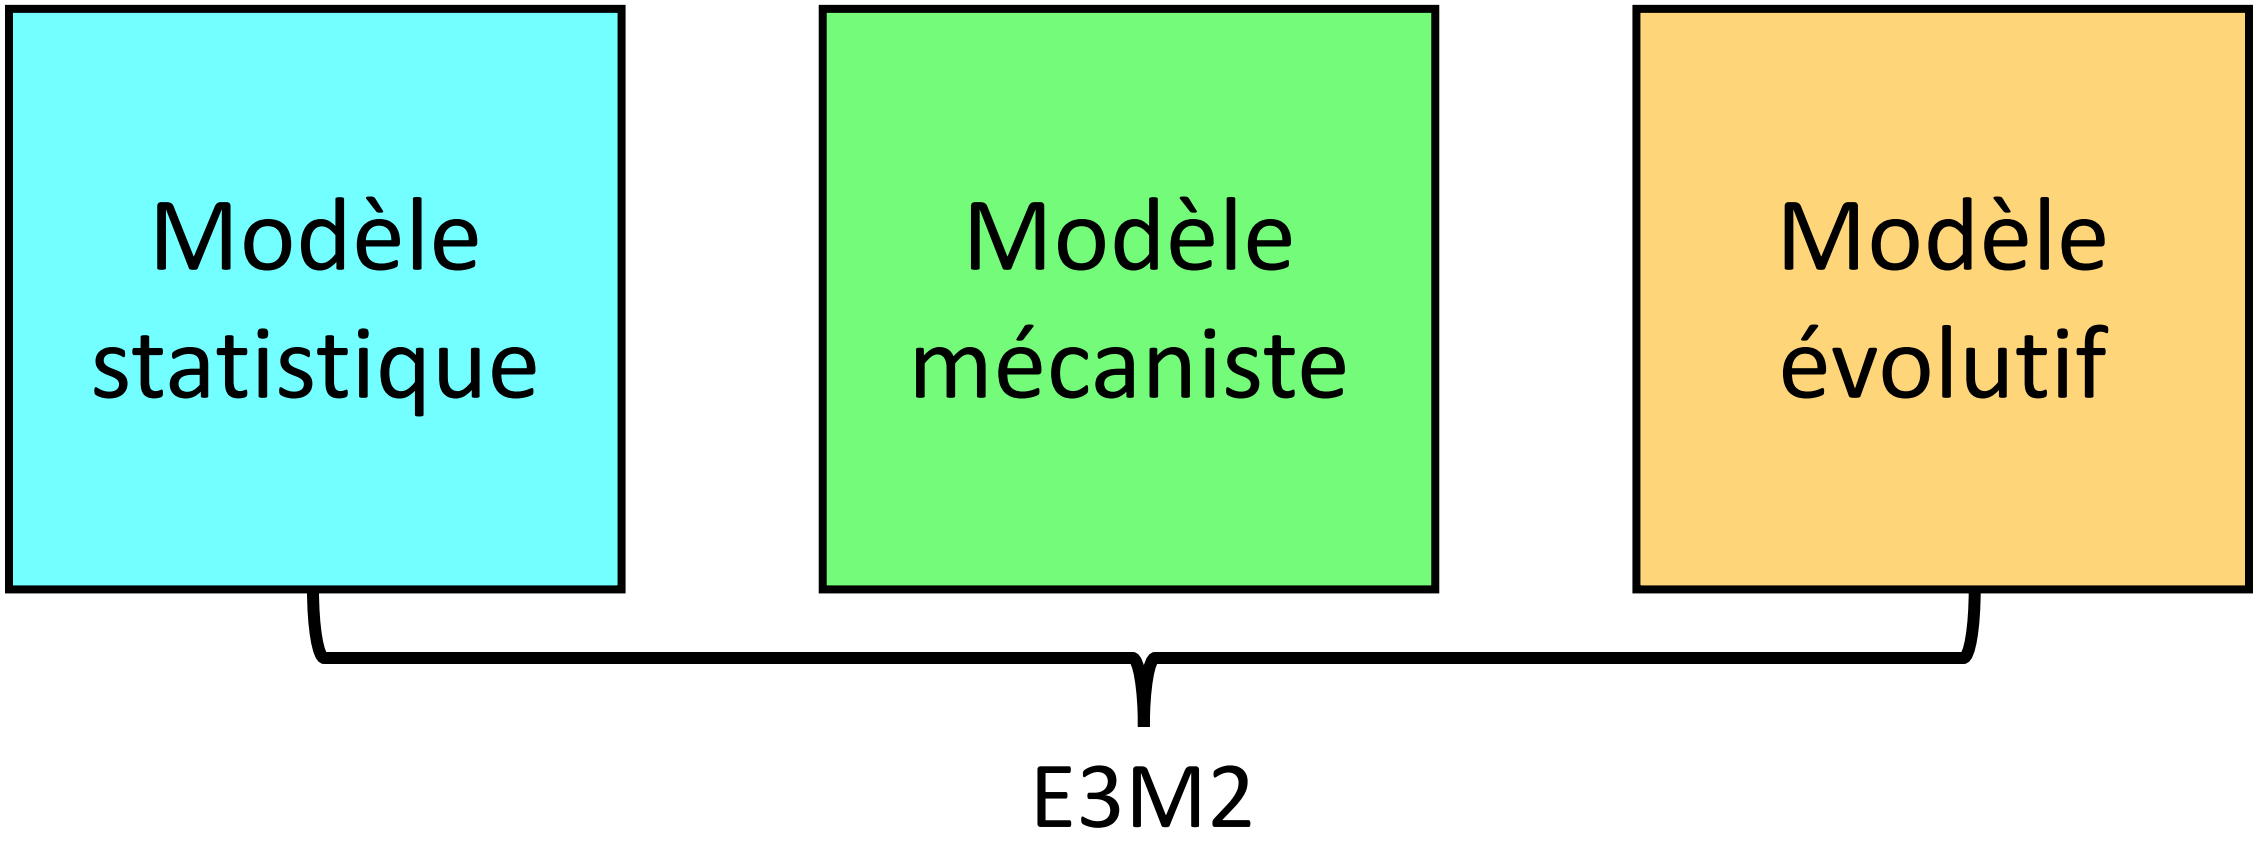
Modèle statistique
Modèle mécaniste
Modèle évolutif
E3M2

Modèles de l’évolution de l’ADN

- Modèles de Markov qui décrivent les taux relatifs de différents changements
  - JC69 (Jukes et Cantor 1969)
  - Modèle K80 (Kimura 1980)
  - Modèle K81 (Kimura 1981)
  - F81 (Felsenstein 1981)
  - Modèle HKY85 (Hasegawa, Kishino et Yano 1985)
  - Modèle T92 (Tamura 1992)
  - Modèle TN93 (Tamura et Nei, 1993)
  - Modèle GTR (Tavaré 1986)
  - Oui, il y en a beaucoup ! Comment puis-je savoir ce qui est le mieux pour mes données ?

Bonne nouvelle, la plupart des gens n'ont pas besoin de connaître les spécificités mathématiques de ces modèles

JC69 model (Jukes and Cantor 1969) [edit]

JC69, the Jukes and Cantor 1969 model,[2] is the simplest substitution model. There are several assumptions. It assumes equal base frequencies $\left(\pi_A = \pi_G = \pi_C = \pi_T = \frac{1}{4}\right)$ and equal mutation rates. The only parameter of this model is therefore μ, the overall substitution rate. As previously mentioned, this variable becomes a constant when we normalize the mean-rate to 1.

$$Q = \begin{pmatrix} * & \frac{\mu}{4} & \frac{\mu}{4} & \frac{\mu}{4} \\ \frac{\mu}{4} & * & \frac{\mu}{4} & \frac{\mu}{4} \\ \frac{\mu}{4} & \frac{\mu}{4} & * & \frac{\mu}{4} \\ \frac{\mu}{4} & \frac{\mu}{4} & \frac{\mu}{4} & * \end{pmatrix}$$

$$P = \begin{pmatrix} \frac{1}{4} + \frac{3}{4}e^{-t\mu} & \frac{1}{4} - \frac{1}{4}e^{-t\mu} & \frac{1}{4} - \frac{1}{4}e^{-t\mu} & \frac{1}{4} - \frac{1}{4}e^{-t\mu} \\ \frac{1}{4} - \frac{1}{4}e^{-t\mu} & \frac{1}{4} + \frac{3}{4}e^{-t\mu} & \frac{1}{4} - \frac{1}{4}e^{-t\mu} & \frac{1}{4} - \frac{1}{4}e^{-t\mu} \\ \frac{1}{4} - \frac{1}{4}e^{-t\mu} & \frac{1}{4} - \frac{1}{4}e^{-t\mu} & \frac{1}{4} + \frac{3}{4}e^{-t\mu} & \frac{1}{4} - \frac{1}{4}e^{-t\mu} \\ \frac{1}{4} - \frac{1}{4}e^{-t\mu} & \frac{1}{4} - \frac{1}{4}e^{-t\mu} & \frac{1}{4} - \frac{1}{4}e^{-t\mu} & \frac{1}{4} + \frac{3}{4}e^{-t\mu} \end{pmatrix}$$

When branch length, ν, is measured in the expected number of changes per site then:

$$P_{ij}(\nu) = \begin{cases} \frac{1}{4} + \frac{3}{4}e^{-4\nu/3} & \text{if } i = j \\ \frac{1}{4} - \frac{1}{4}e^{-4\nu/3} & \text{if } i \neq j \end{cases}$$

It is worth noticing that $\nu = \frac{3}{4}t\mu = (\frac{\mu}{4} + \frac{\mu}{4} + \frac{\mu}{4})t$ what stands for sum of any column (or row) of matrix Q multiplied by time and thus means expected number of substitutions in time t (branch duration) for each particular site (per site) when the rate of substitution equals μ.

Given the proportion p of sites that differ between the two sequences the Jukes-Cantor estimate of the evolutionary distance (in terms of the expected number of changes) between two sequences is given by

$$\hat{d} = -\frac{3}{4}\ln(1 - \frac{4}{3}p) = \hat{\nu}$$

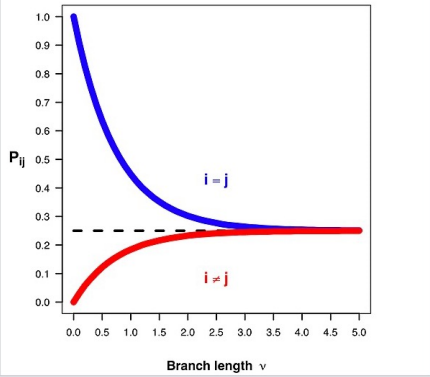

Probability P_{ij} of changing from initial state i to final state j as a function of the branch length (ν) for JC69. Red curve: nucleotide states i and j are different. Blue curve: initial and final states are the same. After a long time, probabilities tend to the nucleotide equilibrium frequencies (0.25: dashed line).

Sélection du modèle

Plus il y a de paramètres, plus la probabilité est élevée, mais l'augmentation de la probabilité est-elle nécessaire? Ajoute beaucoup plus de complexité

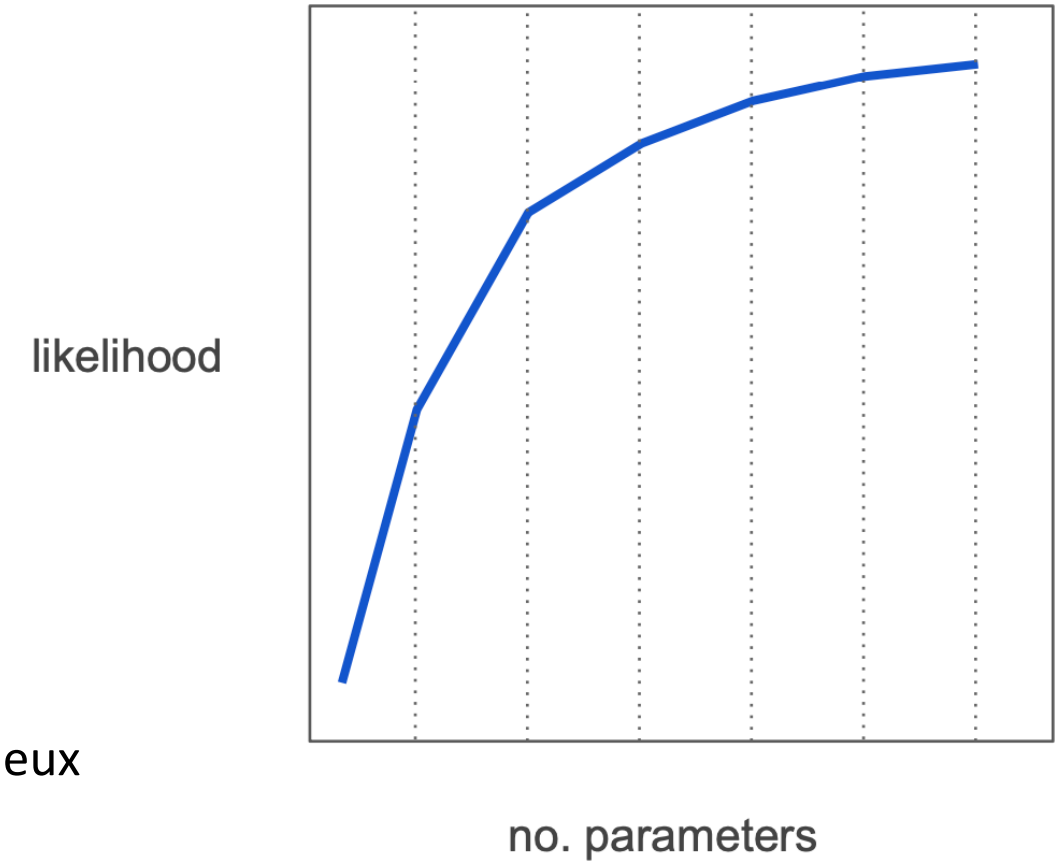

Les tests de modèle vous donneront deux scores

- Score AIC : tente de sélectionner le modèle qui décrit le mieux une réalité inconnue et de haute dimension.
- Score BIC : tente de trouver le modèle VRAI parmi l'ensemble des candidats

Adapté de Ree et Hipp, UChicago, 2021

DNA models

Base substitution rates

IQ-TREE includes all common DNA models (ordered by complexity):

Model	df	Explanation	Code
JC or JC69	0	Equal substitution rates and equal base frequencies (Jukes and Cantor, 1969).	000000
F81	3	Equal rates but unequal base freq. (Felsenstein, 1981).	000000
K80 or K2P	1	Unequal transition/transversion rates and equal base freq. (Kimura, 1980).	010010
HKY or HKY85	4	Unequal transition/transversion rates and unequal base freq. (Hasegawa, Kishino and Yano, 1985).	010010
TN or TN93	5	Like `HKY` but unequal purine/pyrimidine rates (Tamura and Nei, 1993).	010020
TNe	2	Like `TN` but equal base freq.	010020
K81 or K3P	2	Three substitution types model and equal base freq. (Kimura, 1981).	012210
K81u	5	Like `K81` but unequal base freq.	012210
TPM2	2	AC=AT, AG=CT, CG=GT and equal base freq.	010212
TPM2u	5	Like `TPM2` but unequal base freq.	010212
TPM3	2	AC=CG, AG=CT, AT=GT and equal base freq.	012012
TPM3u	5	Like `TPM3` but unequal base freq.	012012
TIM	6	Transition model, AC=GT, AT=CG and unequal base freq.	012230
TIMe	3	Like `TIM` but equal base freq.	012230
TIM2	6	AC=AT, CG=GT and unequal base freq.	010232
TIM2e	3	Like `TIM2` but equal base freq.	010232
TIM3	6	AC=CG, AT=GT and unequal base freq.	012032
TIM3e	3	Like `TIM3` but equal base freq.	012032
TVM	7	Transversion model, AG=CT and unequal base freq.	012314
TVMe	4	Like `TVM` but equal base freq.	012314
SYM	5	Symmetric model with unequal rates but equal base freq. (Zharkikh, 1994).	012345
GTR	8	General time reversible model with unequal rates and unequal base freq. (Tavare, 1986).	012345

Évaluer l’hétérogénéité entre les sites

- Évolution de l’hétérogénéité des taux :
- Positions des codons
- Exons (régions codantes) et introns (régions non codantes)
- Gènes d’entretien ménager et gènes non fonctionnels
- Structure de l’ARN (tiges et boucles)

Nous pouvons faire des déductions sur la sélection à partir de ces valeurs, mais cela rend les choses beaucoup plus compliquées

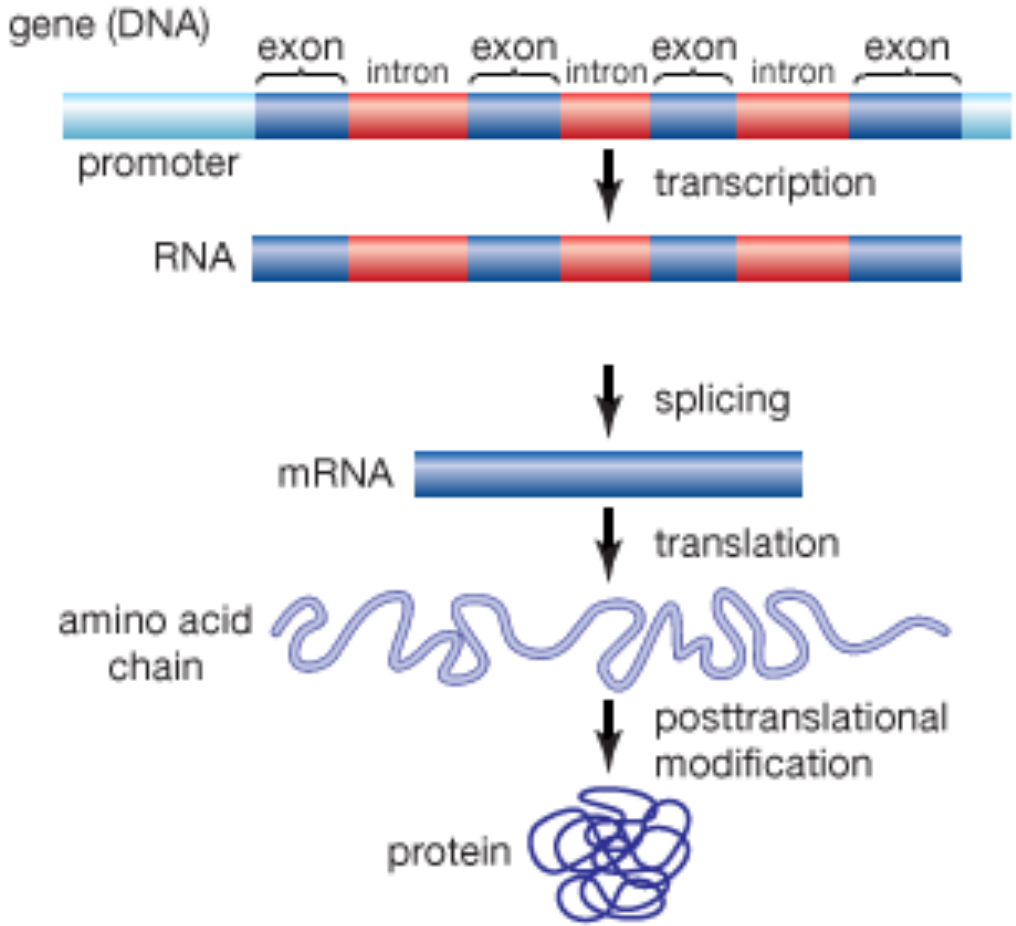

Adapté de Ree et Hipp, UChicago, 2021

Évaluer l'hétérogénéité entre les sites

AVEC hétérogénéité de taux

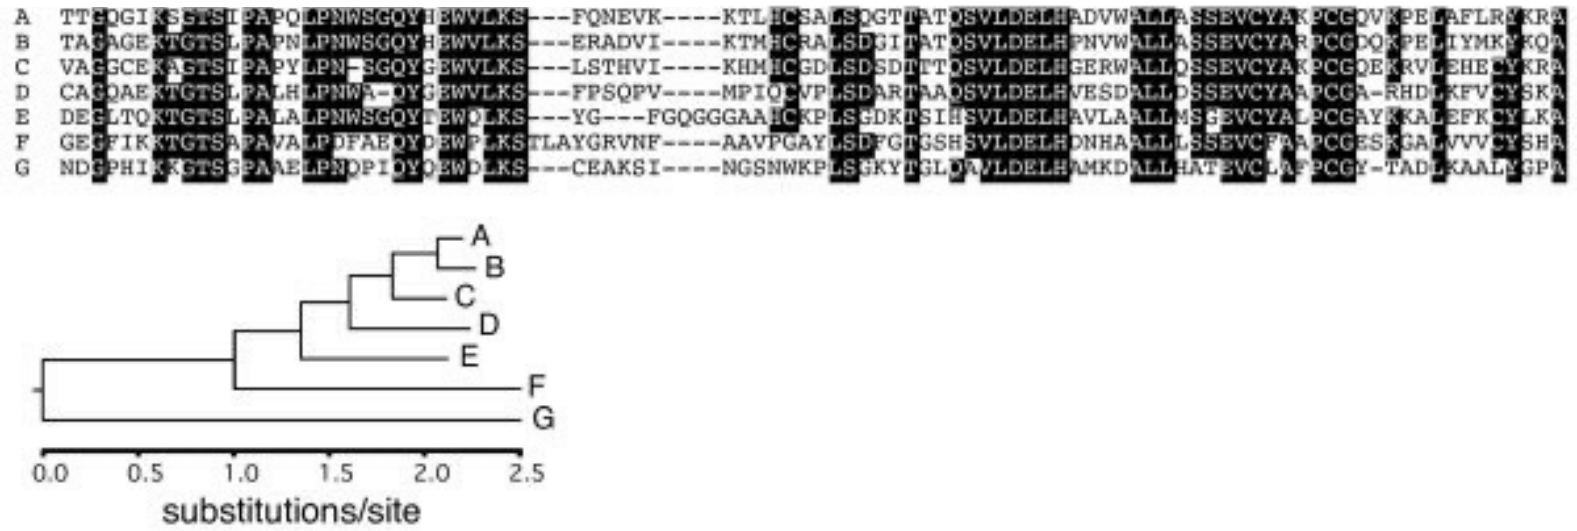

SANS hétérogénéité de taux

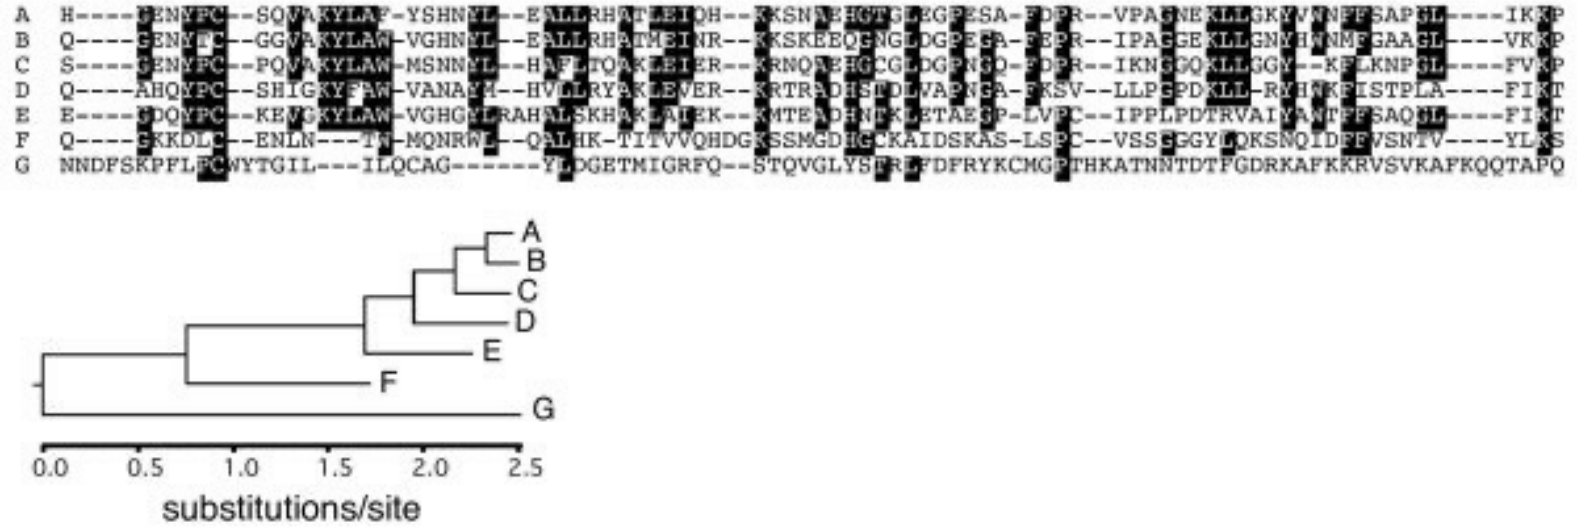

Rate heterogeneity across sites

IQ-TREE supports all common rate heterogeneity across sites models:

RateType	Explanation
+I	allowing for a proportion of invariable sites.
+G	discrete Gamma model (Yang, 1994) with default 4 rate categories. The number of categories can be changed with e.g. `+G8` .
+GC	continuous Gamma model (Yang, 1994) (for AliSim only).
+I+G	invariable site plus discrete Gamma model (Gu et al., 1995).
+R	FreeRate model (Yang, 1995; Soubrier et al., 2012) that generalizes the `+G` model by relaxing the assumption of Gamma-distributed rates. The number of categories can be specified with e.g. `+R6` (default 4 categories if not specified). The FreeRate model typically fits data better than the `+G` model and is recommended for analysis of large data sets.
+I+R	invariable site plus FreeRate model.

IQ-TREE, 2022

Zone de Felsenstein

- Les longueurs de branche pour lesquelles la parcimonie déduit avec certitude une topologie incorrecte, celles-ci peuvent affecter les valeurs d'amorçage

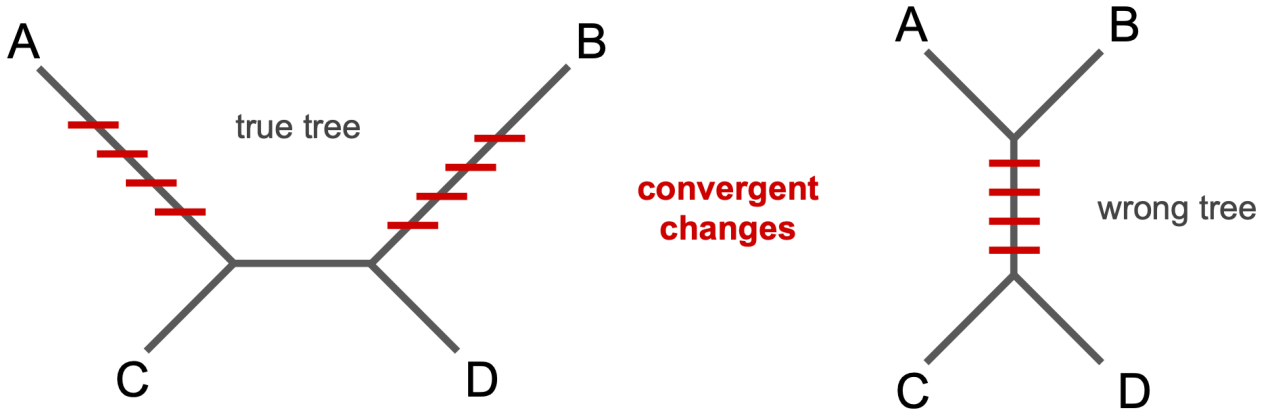

likelihood is a **consistent estimator** of tree topology because it converges on the correct value with increasing data

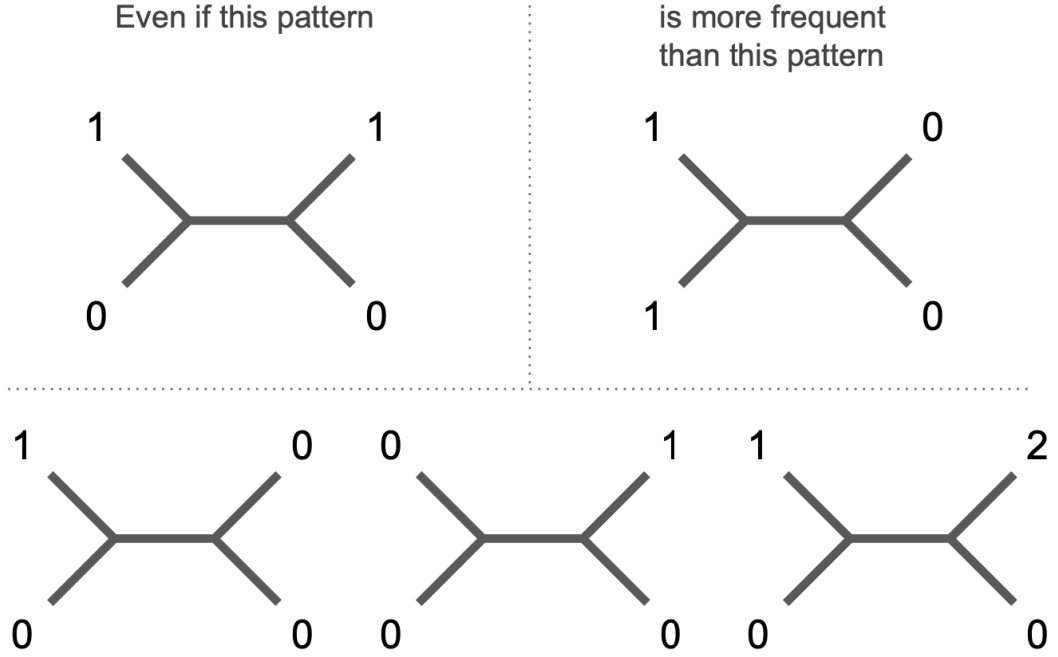

likelihood will correctly infer the true tree if these patterns are sufficiently frequent to allow accurate branch length estimation

Adapté de Ree et Hipp, UChicago, 2021

Bootstrapping

- Spécifier le nombre de répétitions : combien de fois le test réplique-t-il l'alignement de la séquence d'origine?

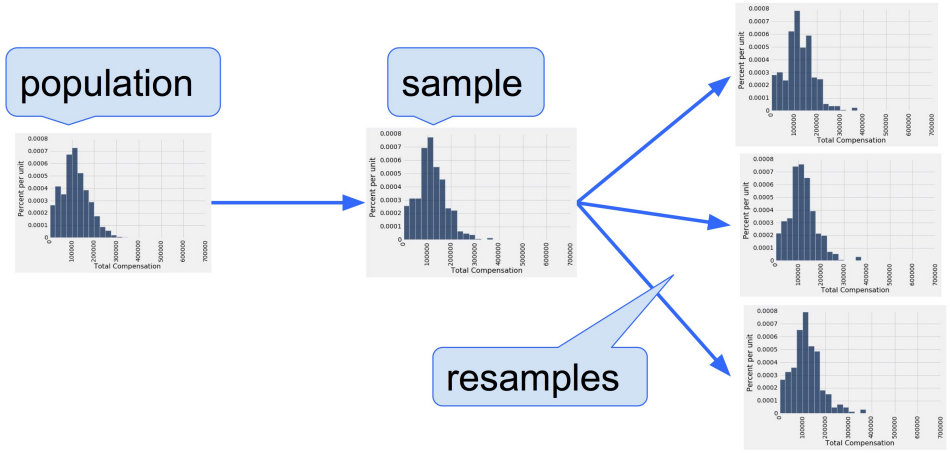

Original
sequence alignment

Site number

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
Species A	A	A	T	G	C	T	A	G	T	G	G	T	G	A	T
Species B	A	A	G	C	T	A	T	G	G	T	G	A	T	C	G
Species C	A	G	C	C	T	A	T	G	T	G	G	A	A	C	G
Species D	A	A	C	C	C	A	T	T	G	G	G	T	G	A	T

Original alignment tree

Bootstrap
pseudo-replicate #1

	5	3	3	1	12	9	2	4	11	13	10	14	8	11	13
Species A	C	T	T	A	T	T	A	G	G	G	G	A	G	G	G
Species B	T	G	G	A	A	G	A	C	G	T	T	C	G	G	T
Species C	T	C	C	A	A	T	G	C	G	A	G	C	G	G	A
Species D	C	C	C	A	T	T	A	C	G	G	G	A	T	G	G

Bootstrap tree #1

Bootstrap
pseudo-replicate #2

	9	7	12	5	2	4	2	6	14	9	4	9	7	2	1
Species A	T	A	T	C	A	G	A	T	A	T	G	T	A	A	A
Species B	G	T	A	T	A	C	A	A	C	G	C	G	T	A	A
Species C	T	T	A	T	G	C	G	A	C	T	C	T	T	G	A
Species D	T	T	T	C	A	C	A	A	A	T	C	T	T	A	A

Bootstrap tree #2

Point de contrôle!

- Plus de paramètres = plus ou moins de probabilité?
- Des valeurs d'amorçage faibles signifient une faible confiance dans la topologie de l'arborescence
- Toutes les séquences ne subissent pas l'évolution de la même manière, les modèles rendent compte de ce changement

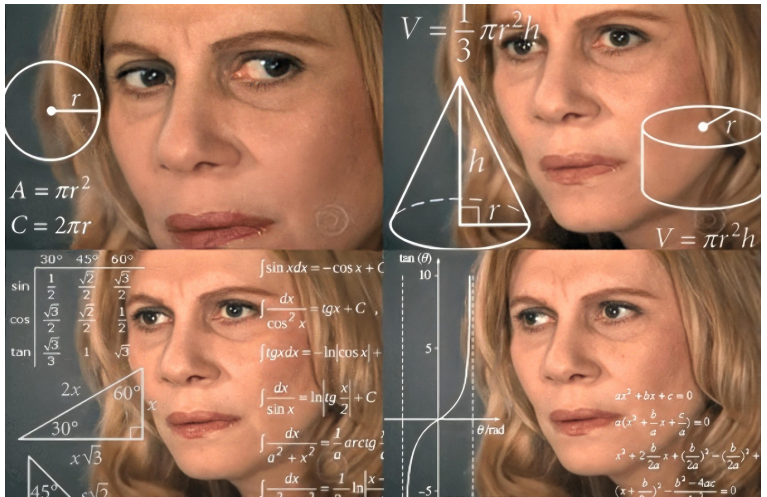

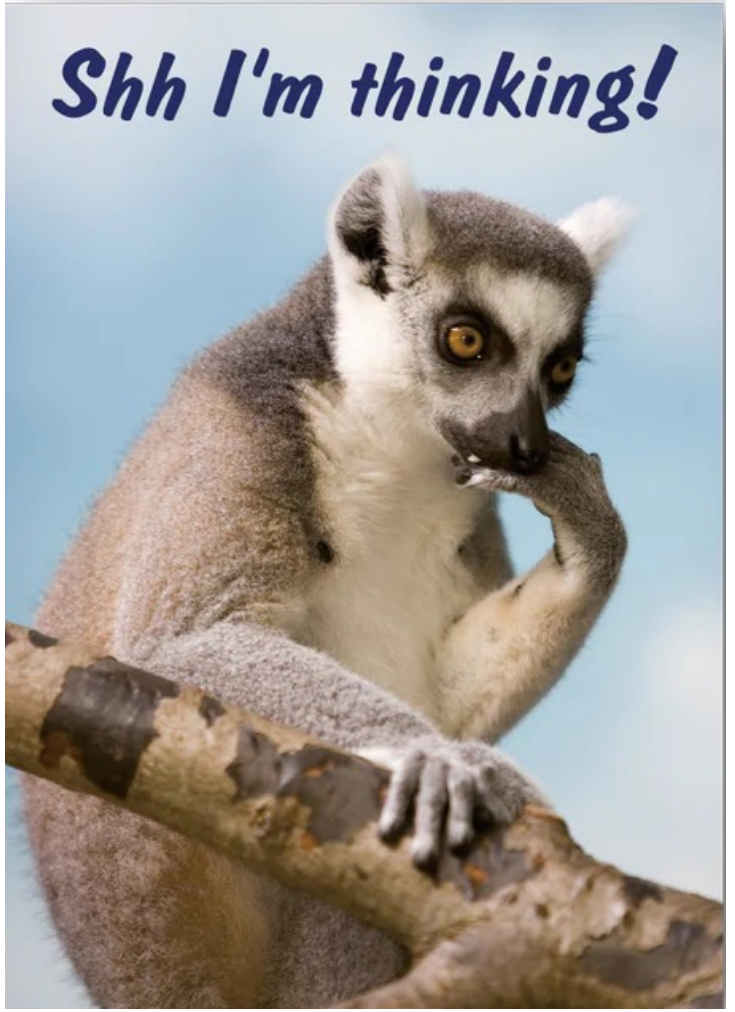

Avertissements et limitations

- La construction de phylogénies prend beaucoup de temps, les plus grandes peuvent prendre jusqu'à une semaine pour s'exécuter et les phylogénies bayésiennes peuvent fonctionner pendant des mois, donc un cluster de calcul est presque nécessaire pour cela
- En l'absence d'un exogroupe ou d'une racine appropriée, une phylogénie ne vous dit pas grand-chose sur l'ordre de descendance

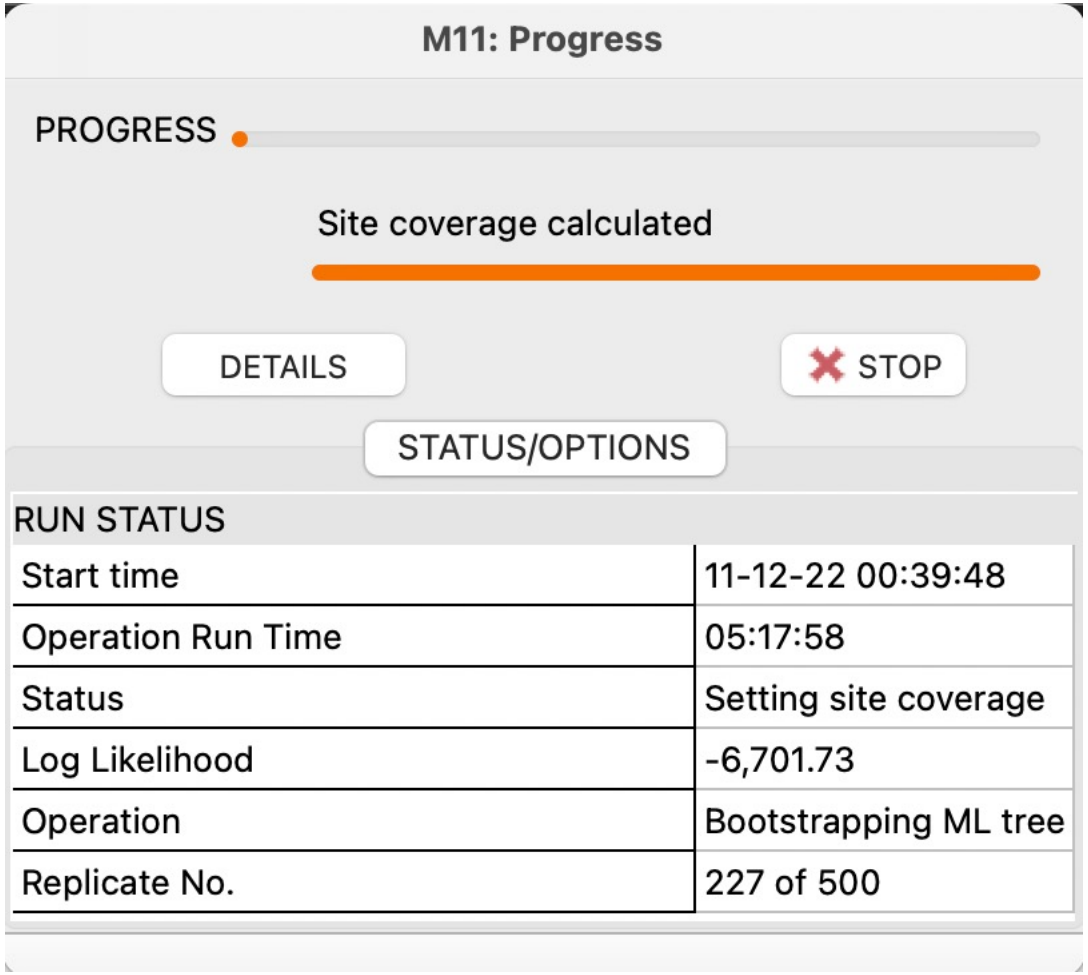

JOURNAL ARTICLE

Assessing Uncertainty in the Rooting of the SARS-CoV-2 Phylogeny

Lenore Pipes, Hongru Wang, John P Huelsenbeck ✉, Rasmus Nielsen ✉

Molecular Biology and Evolution, Volume 38, Issue 4, April 2021, Pages 1537–1543,
https://doi.org/10.1093/molbev/msaa316
Published: 09 December 2020

PDF Split View Cite Permissions Share ▾

Abstract

The rooting of the SARS-CoV-2 phylogeny is important for understanding the origin and early spread of the virus. Previously published phylogenies have used different rootings that do not always provide consistent results. We investigate several different strategies for rooting the SARS-CoV-2 tree and provide measures of statistical uncertainty for all methods. We show that methods based on the molecular clock tend to place the root in the B clade, whereas methods based on outgroup rooting tend to place the root in the A clade. The results from the two approaches are statistically incompatible, possibly as a consequence of deviations from a molecular clock or excess back-mutations. We also show that none of the methods provide strong statistical support for the placement of the root in any particular edge of the tree. These results suggest that phylogenetic evidence alone is unlikely to identify the origin of the SARS-CoV-2 virus and we caution against strong inferences regarding the early spread of the virus based solely on such evidence.

Il est important de replacer votre arbre dans son contexte, sans contrôle, pouvez-vous vraiment en déduire quoi que ce soit?

Étude de cas : grippe – décalage et dérive antigéniques

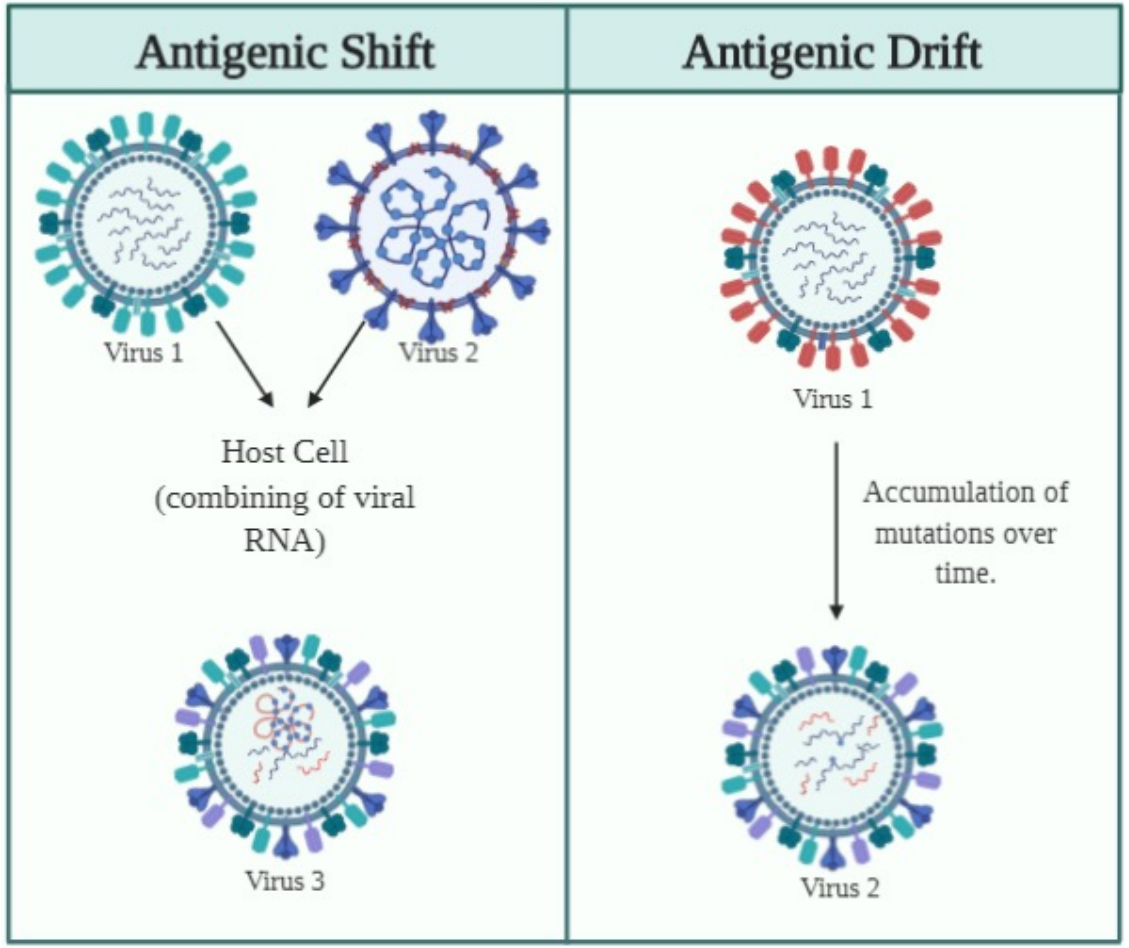

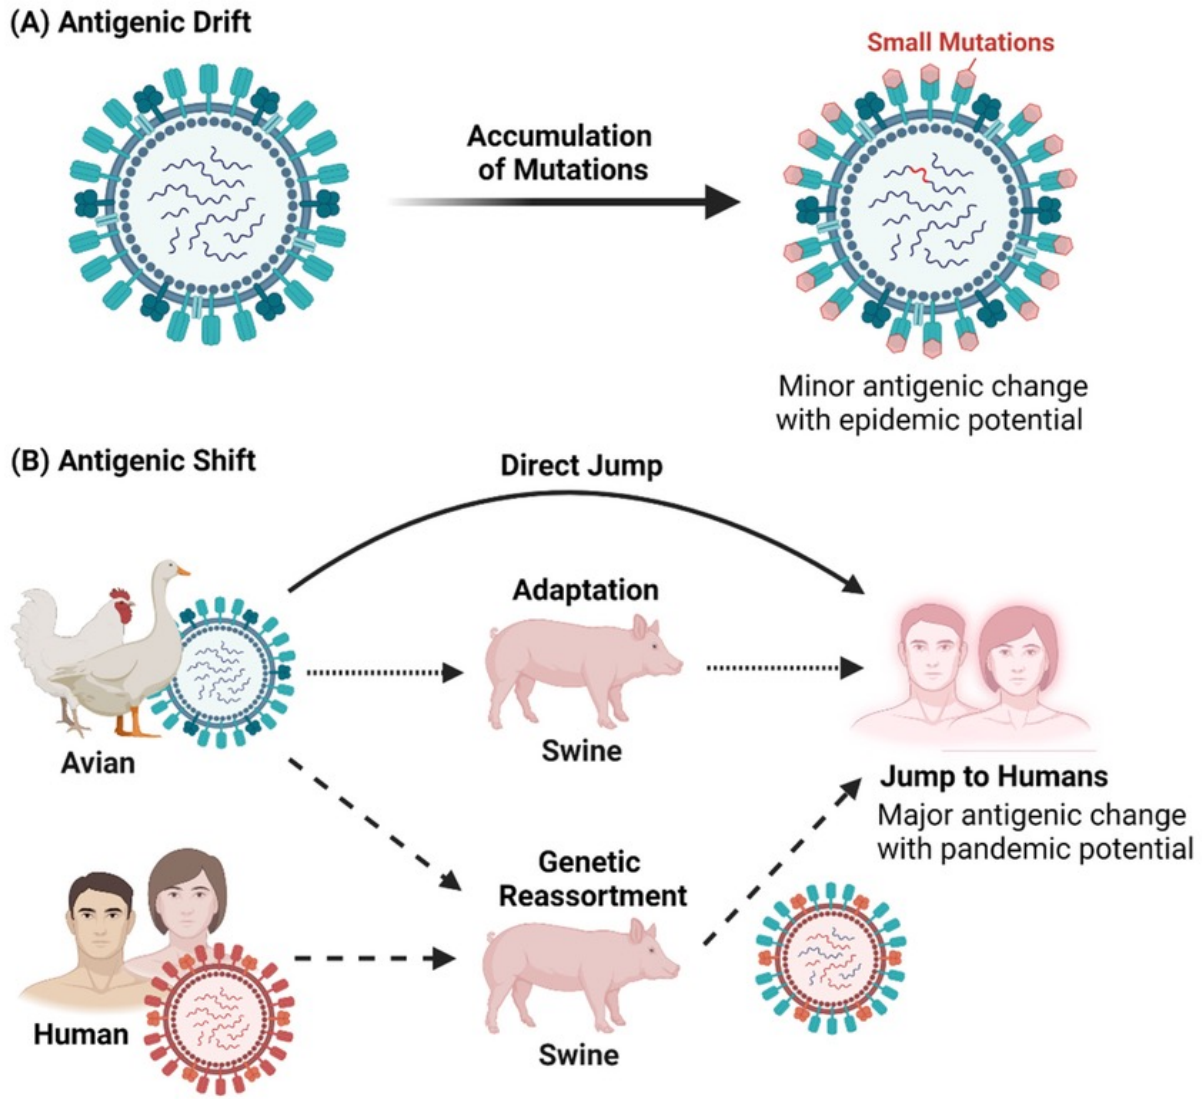

Yeo et al. 2021

Étude de cas : grippe – décalage et dérive antigéniques

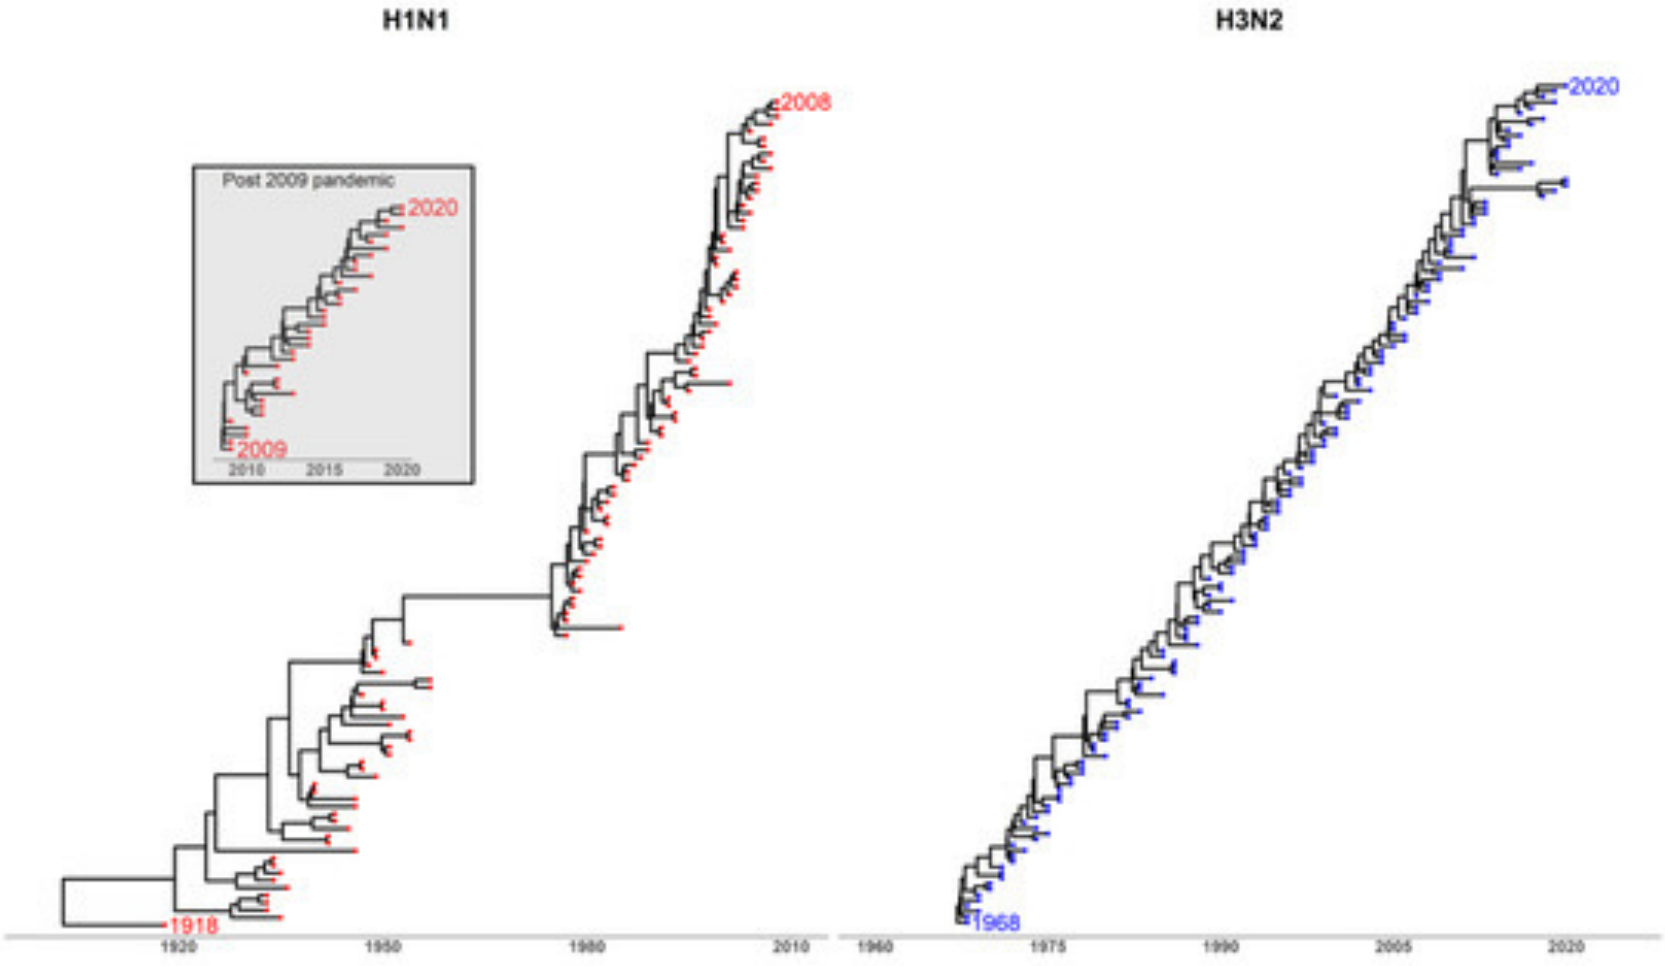

Y a-t-il une dérive ou un décalage ici ? Quel impact cela a-t-il sur la conception des vaccins ?

Bolton et al. 2021

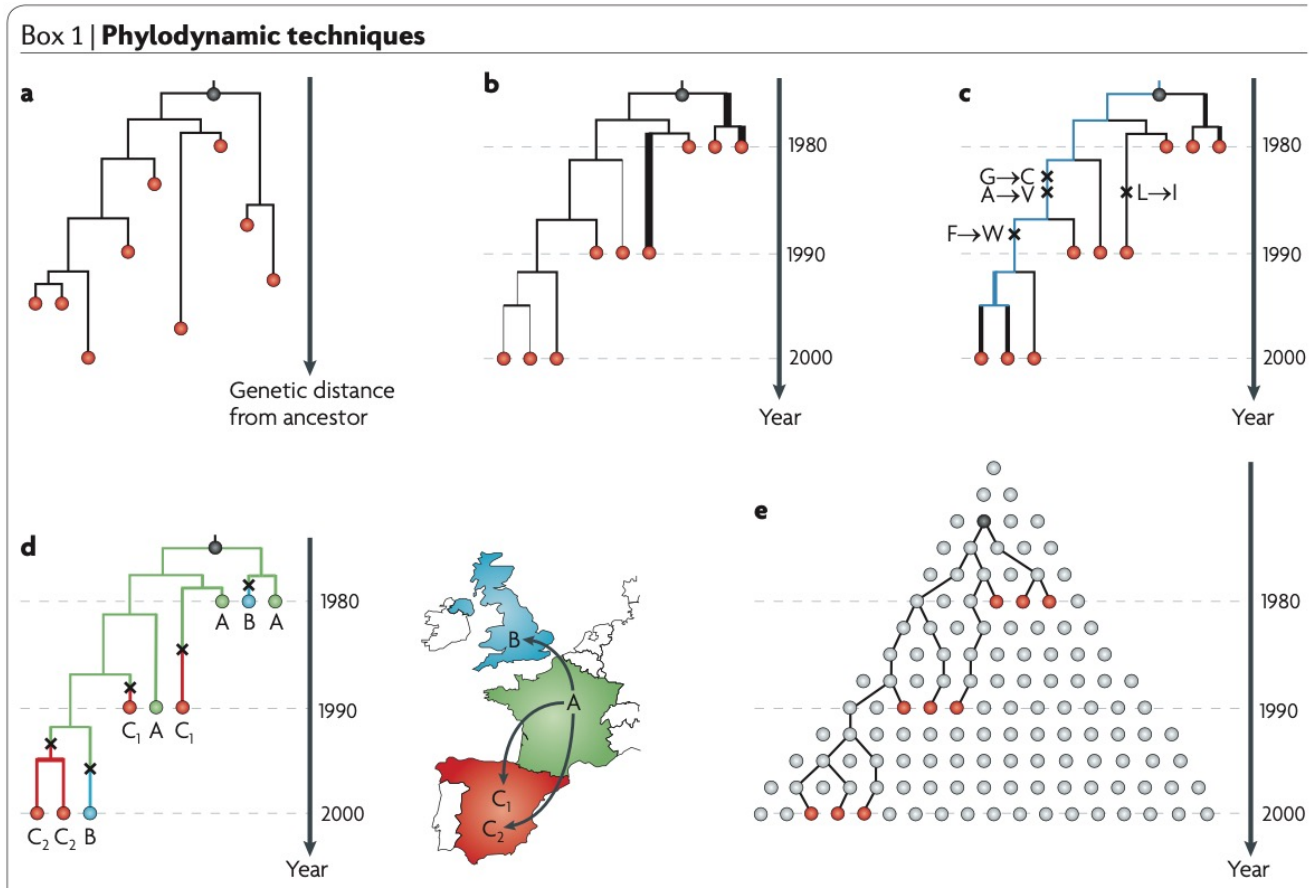

L'importance des unités

L'importance des formes

	Continual Immune Selection	Weak or Absent Immune Selection Tree shape controlled by non-selective population dynamic processes	
		Population size dynamics	Spatial dynamics
Idealized Phylogeny Shapes	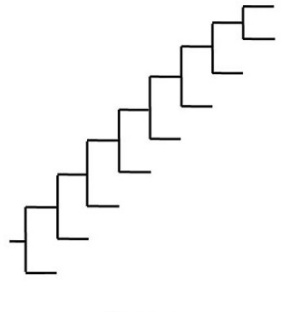	**Exponential growth** 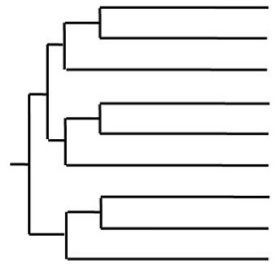 **Constant size** 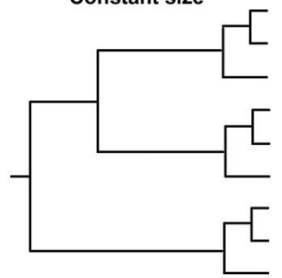	**Strong spatial structure** 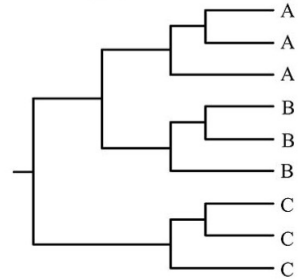 **Weak spatial structure** 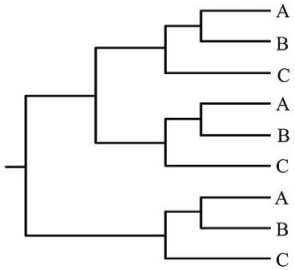
Examples	Human influenza A virus intra-host HIV	inter-host HIV inter-host HCV	Measles, rabies inter-host HIV
Tree Inferences	Detection of antigenic escape mutations	Estimation of population growth rates	Estimation of population migration rates

Grenfell et al. 2004
Pybus and Rambaut 2009

On peut faire beaucoup de choses avec les phylogénies...

- Phylodynamique
- Peut examiner la phylogénie dans le contexte d'autres facteurs
  - Temps (depuis combien de temps ce virus a-t-il divergé)
  - Emplacement (comment un virus a-t-il changé au fur et à mesure qu'il se propage ?)
  - Hôte (comment un virus a-t-il changé dans différents hôtes ?)
- Les phylogénies du maximum de vraisemblance sont bonnes pour :
  - À quel point une chose est différente/similaire par rapport aux choses connues

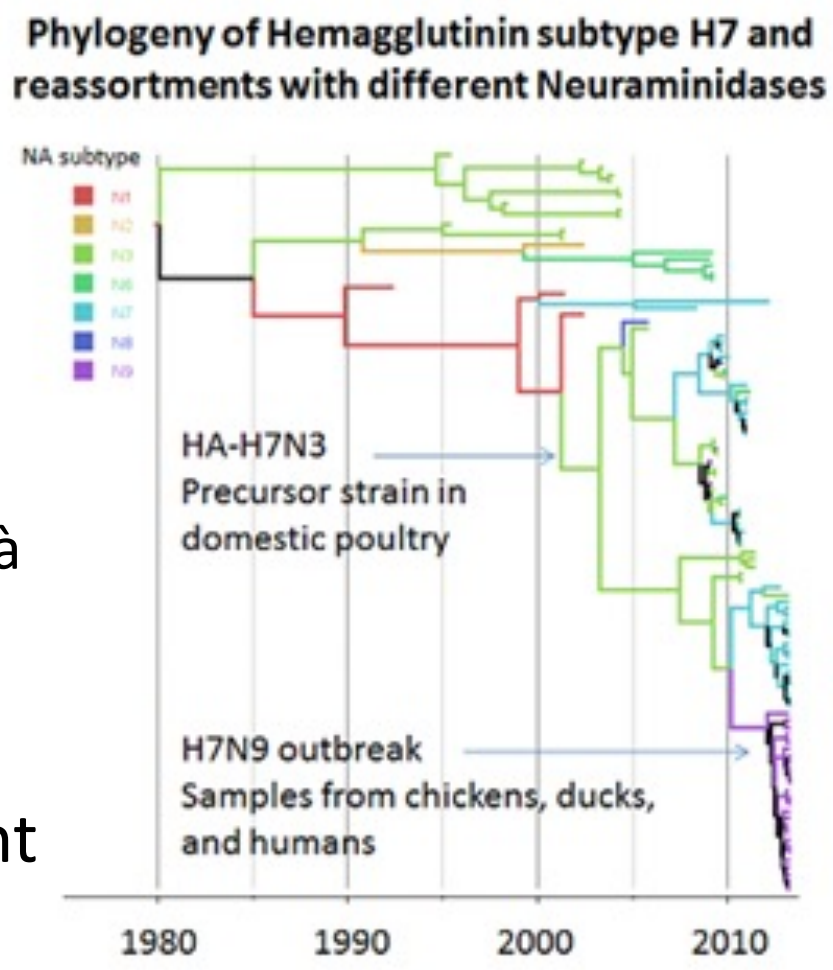

BEAST

Bayesian Evolutionary Analysis Sampling Trees

Point de contrôle!

- La phylogénétique est utile, mais elle demande beaucoup de calculs
- Pourquoi avons-nous besoin d'une racine dans les arbres phylogénétiques ?
- La forme d'une phylogénie peut-elle nous dire quelque chose sur le sujet ?

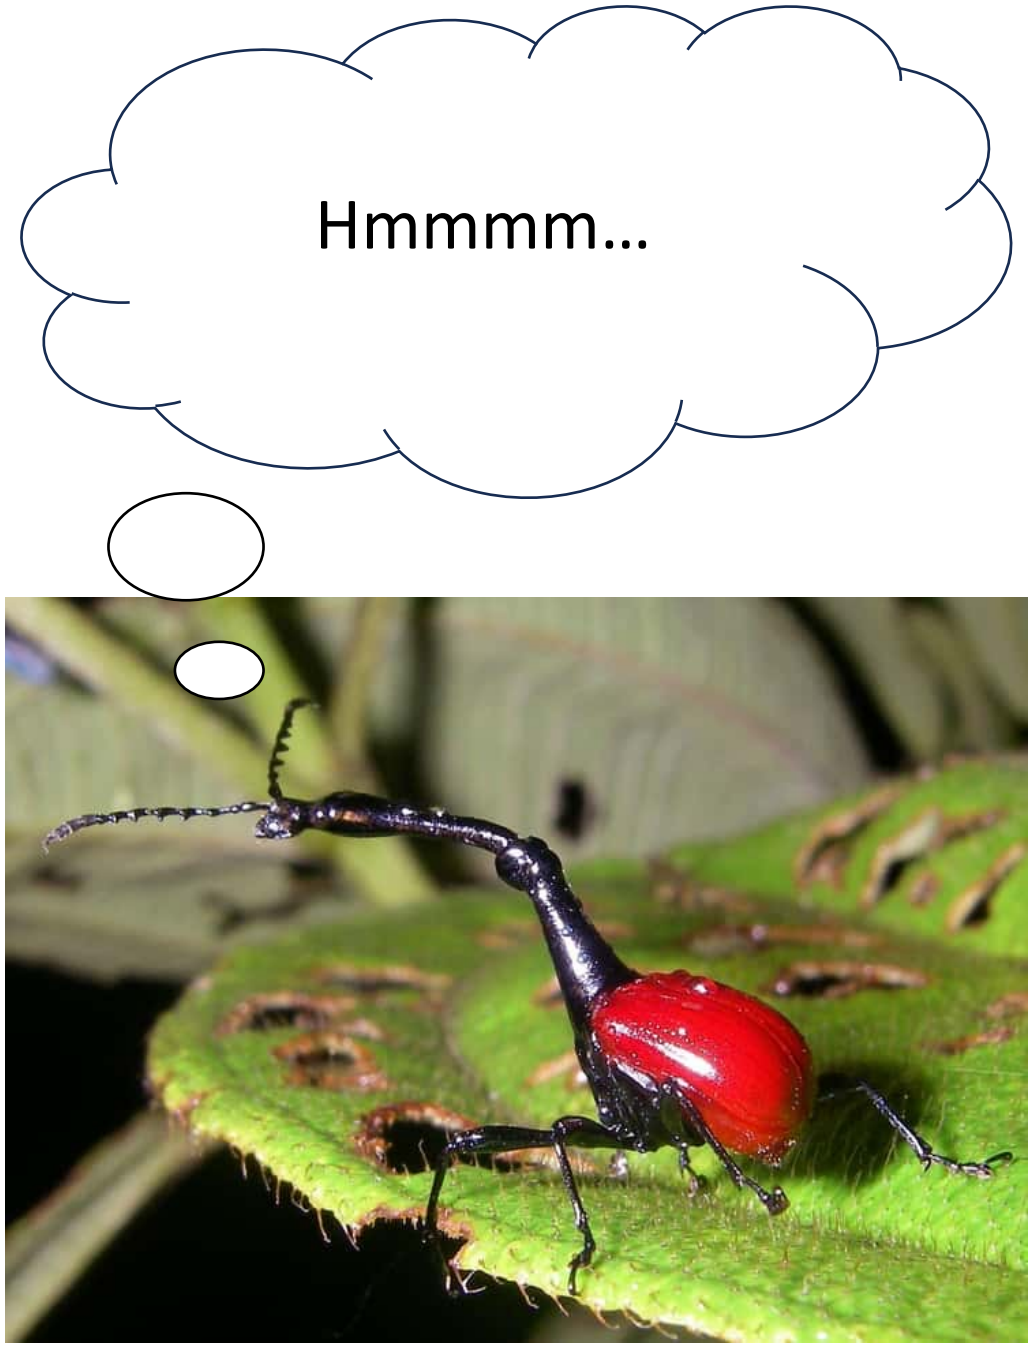

Vous avez donc vos séquences, et maintenant?

- Obtenir des séquences de référence du NCBI
- Obtenir un groupe externe de NCBI
- Alignez-les (utilisez un logiciel comme MEGA ou en ligne, vous avez donc vos séquences, et maintenant ? comme MAFFT)
- Choisissez le meilleur modèle (utilisez un logiciel comme MEGA ou ModelTest-NG)
- Exécutez la phylogénie en utilisant les séquences alignées et le modèle choisi (utilisez un logiciel comme MEGA ou RAxML)
- Visualiser/modifier l'arborescence dans R ou MEGA

Tout ce qui est répertorié est gratuit à utiliser

Potentiel pour de jolies figurines

ggtree: an R package for visualization of tree and annotation data

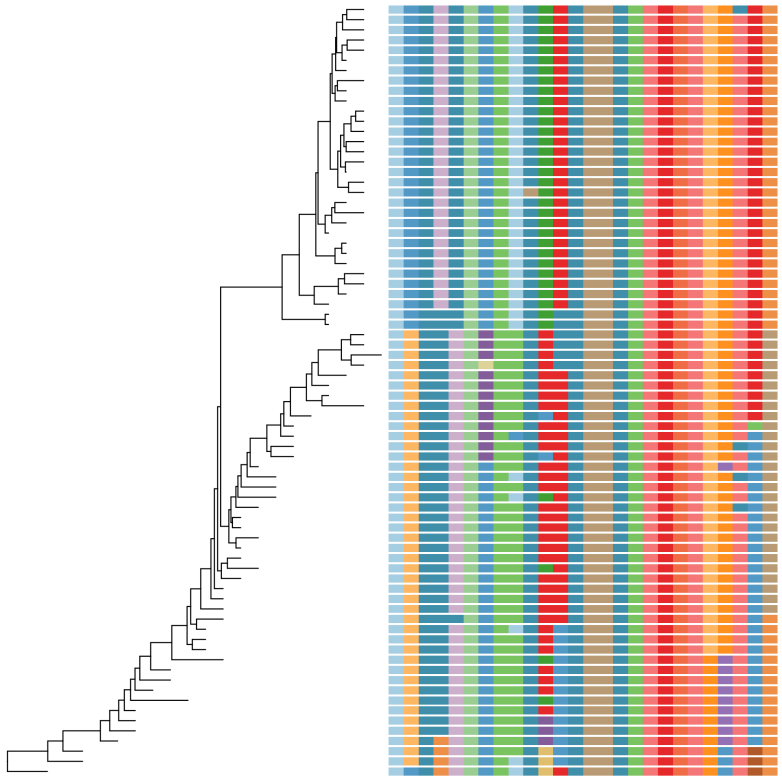

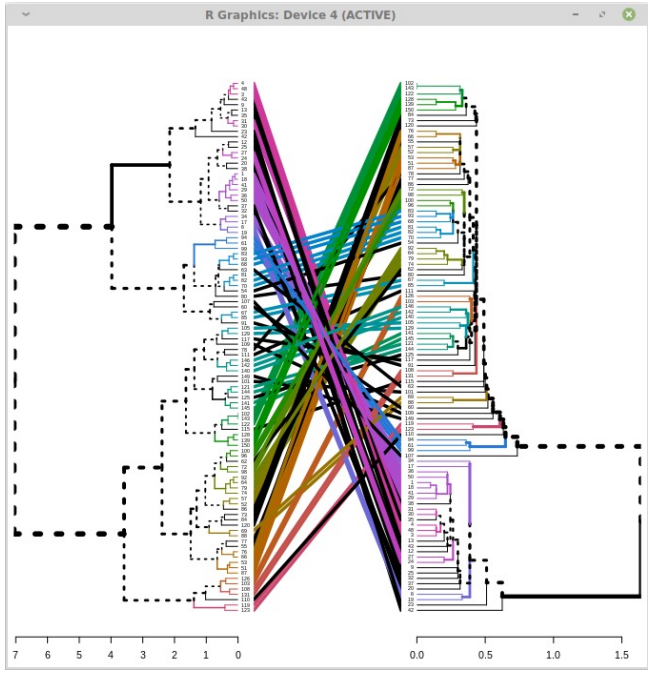

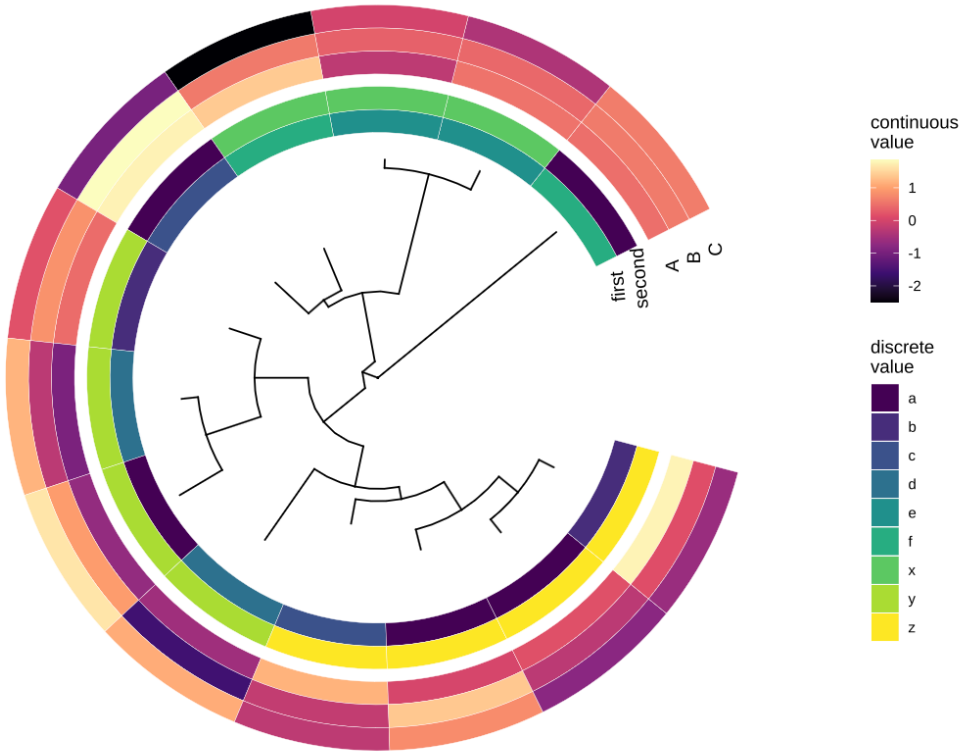

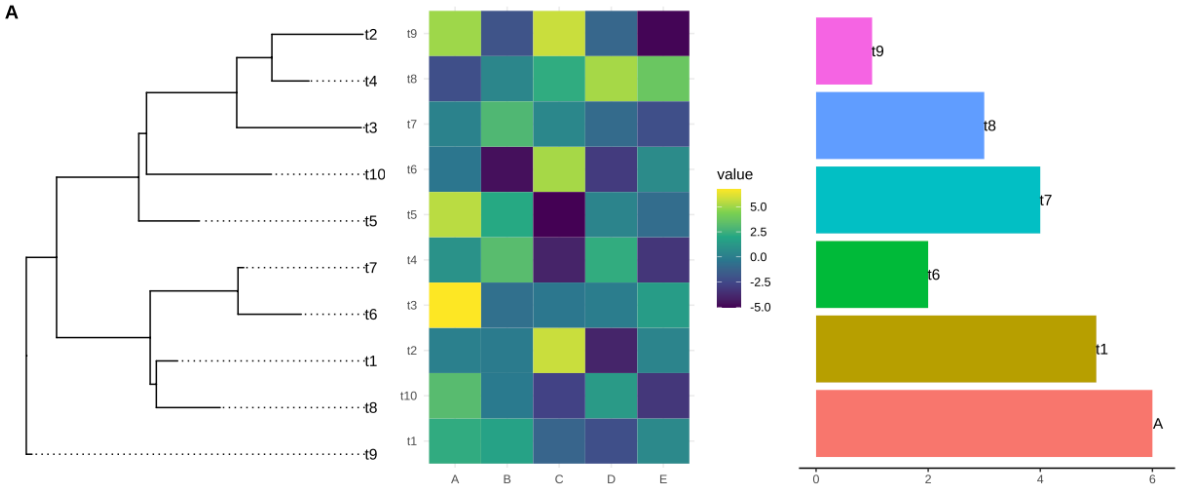

Point de contrôle final!

- Les arbres phylogénétiques ont un large éventail d'applications à de nombreux sujets de recherche!
- Utilise la modélisation et les statistiques "en coulisses"
- **Quelqu'un peut-il donner un exemple de la façon dont il pourrait utiliser une phylogénie pour ses propres recherches?** ☺

Lémuriens du parc national de Ranomafana

- Cytochrome B
  - Utilisé beaucoup dans l'identification des espèces, variabilité limitée à l'intérieur et variation beaucoup plus grande entre les espèces
- Question : à quel point les lémuriens que l'on peut trouver dans le parc national de Ranomafana sont-ils similaires les uns aux autres ?

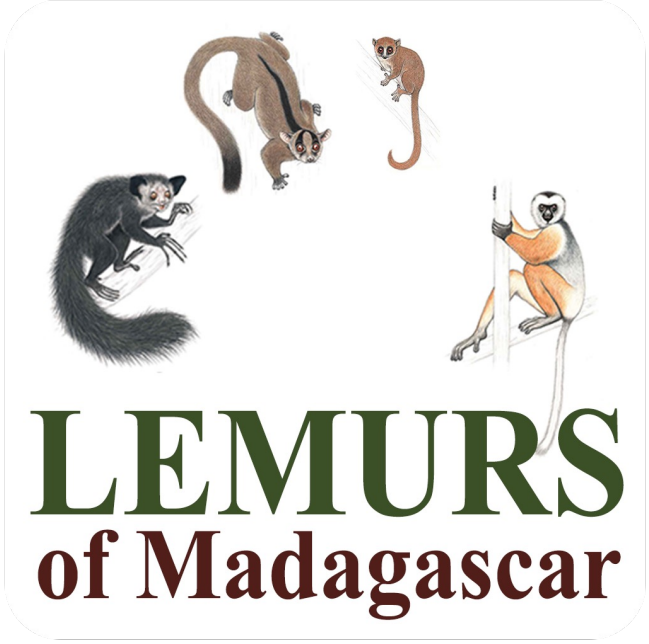

DIAPOSITIVES À REVOIR À VOTRE RYTHME

Étapes à revoir plus tard

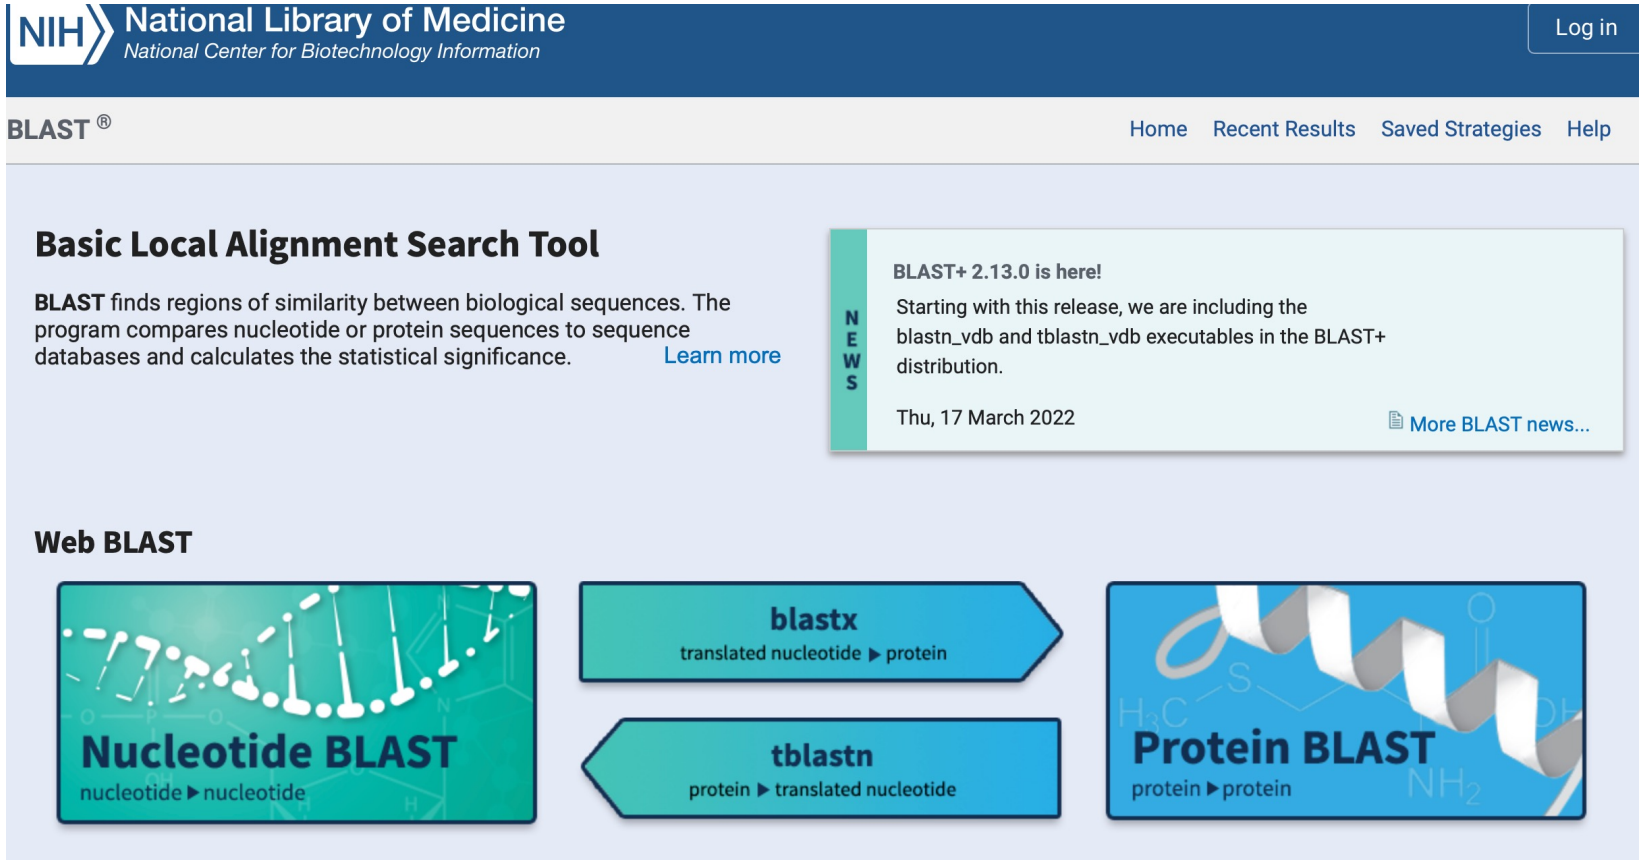

Vérifiez à quel type de séquence vous avez affaire en effectuant une recherche BLAST

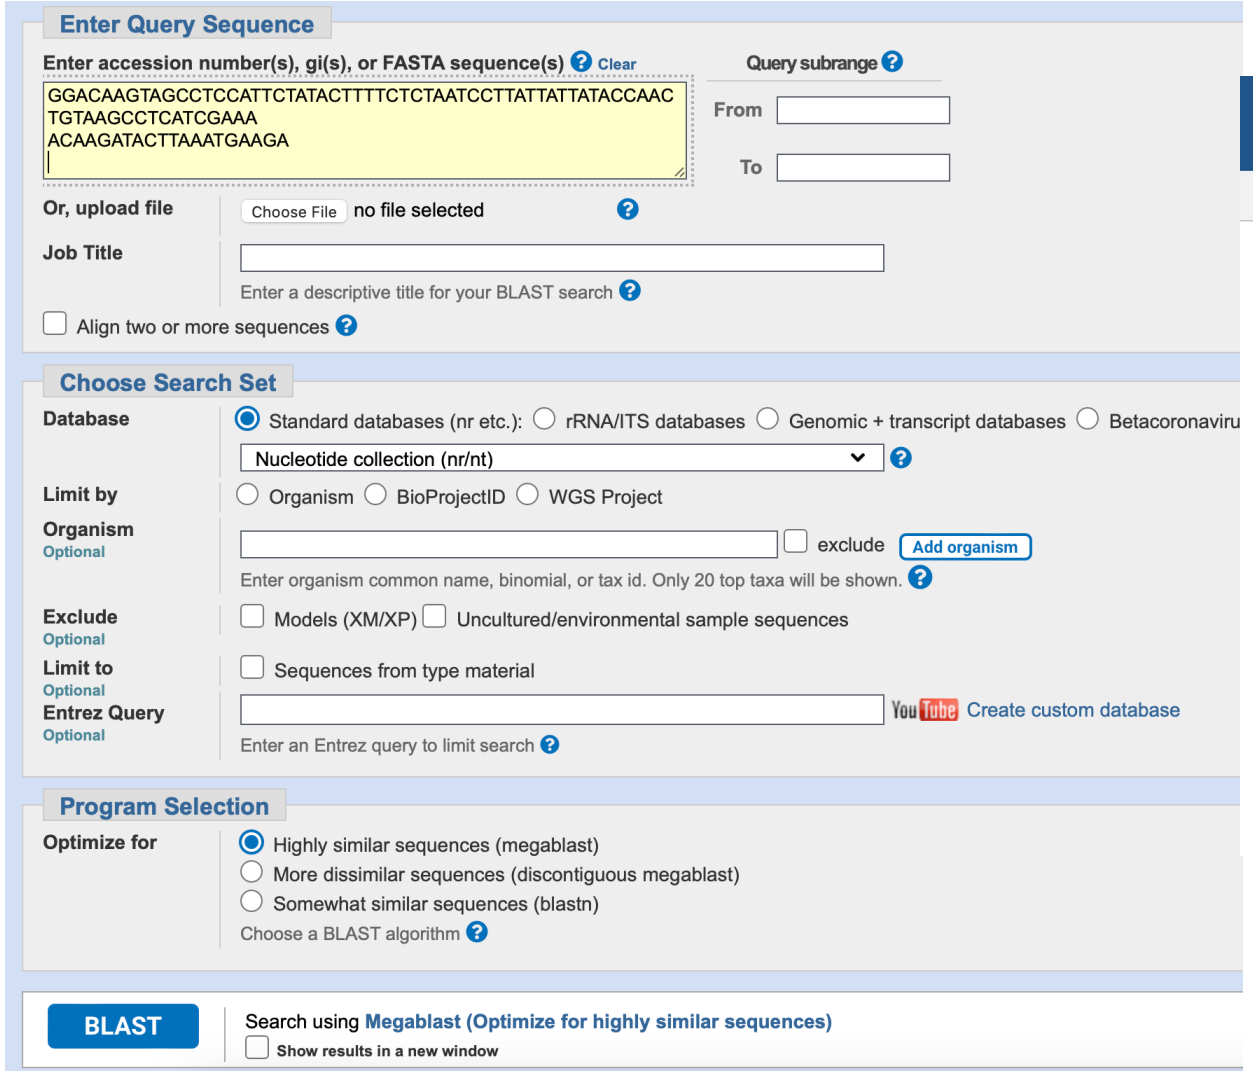
Enter Query Sequence
Enter accession number(s), gi(s), or FASTA sequence(s) Clear
GGACAAGTAGCCTCCATTCTATACTTTTCTCTAATCCTTATTATTATACCAAC
TGTAAGCCTCATCGAAA
ACAAGATACTTAAATGAAGA
Query subrange
From
To
Or, upload file
Choose File no file selected
Job Title
Enter a descriptive title for your BLAST search
Align two or more sequences
Choose Search Set
Database
Standard databases (nr etc.): rRNA/ITS databases Genomic + transcript databases Betacoronaviru
Nucleotide collection (nr/nt)
Limit by
Organism BioProjectID WGS Project
Organism
Optional
exclude
Add organism
Enter organism common name, binomial, or tax id. Only 20 top taxa will be shown.
Exclude
Optional
Models (XM/XP) Uncultured/environmental sample sequences
Limit to
Optional
Sequences from type material
Entrez Query
Optional
Create custom database
Enter an Entrez query to limit search
Program Selection
Optimize for
Highly similar sequences (megablast)
More dissimilar sequences (discontiguous megablast)
Somewhat similar sequences (blastn)
Choose a BLAST algorithm
BLAST
Search using Megablast (Optimize for highly similar sequences)
Show results in a new window

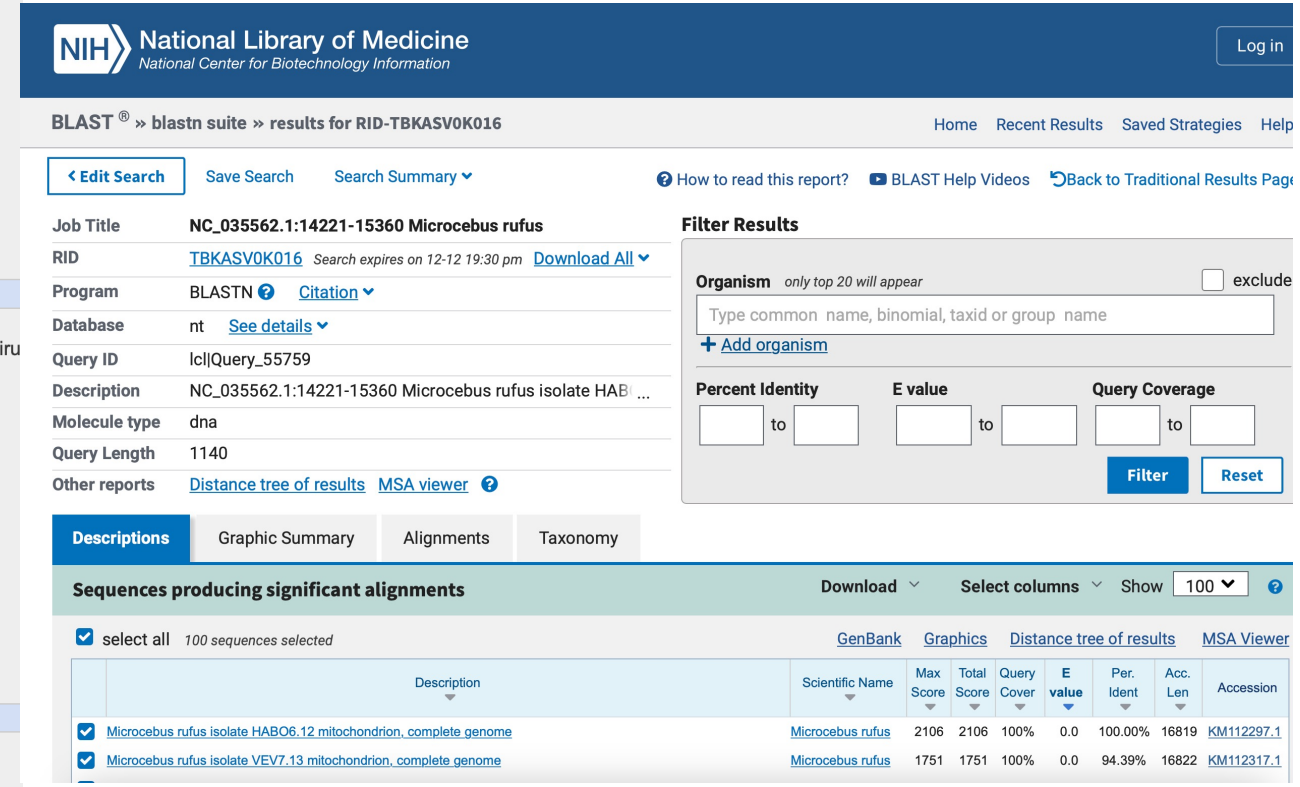
National Library of Medicine
National Center for Biotechnology Information
Log in
BLAST ® » blastn suite » results for RID-TBKASV0K016
Home Recent Results Saved Strategies Help
Edit Search
Save Search
Search Summary
How to read this report?
BLAST Help Videos
Back to Traditional Results Page
Job Title NC_035562.1:14221-15360 Microcebus rufus
RID TBKASV0K016 Search expires on 12-12 19:30 pm Download All
Program BLASTN Citation
Database nt See details
Query ID lcl|Query_55759
Description NC_035562.1:14221-15360 Microcebus rufus isolate HAB ...
Molecule type dna
Query Length 1140
Other reports Distance tree of results MSA viewer
Filter Results
Organism only top 20 will appear
exclude
Type common name, binomial, taxid or group name
Add organism
Percent Identity
E value
Query Coverage
to
Filter
Reset
Descriptions
Graphic Summary
Alignments
Taxonomy
Sequences producing significant alignments
Download
Select columns
Show 100
select all 100 sequences selected
GenBank Graphics Distance tree of results MSA Viewer
Description
Scientific Name
Max Score
Total Score
Query Cover
E value
Per. Ident
Acc. Len
Accession
Microcebus rufus isolate HABO6.12 mitochondrion, complete genome
Microcebus rufus
2106 2106 100% 0.0 100.00% 16819 KM112297.1
Microcebus rufus isolate VEV7.13 mitochondrion, complete genome
Microcebus rufus
1751 1751 100% 0.0 94.39% 16822 KM112317.1

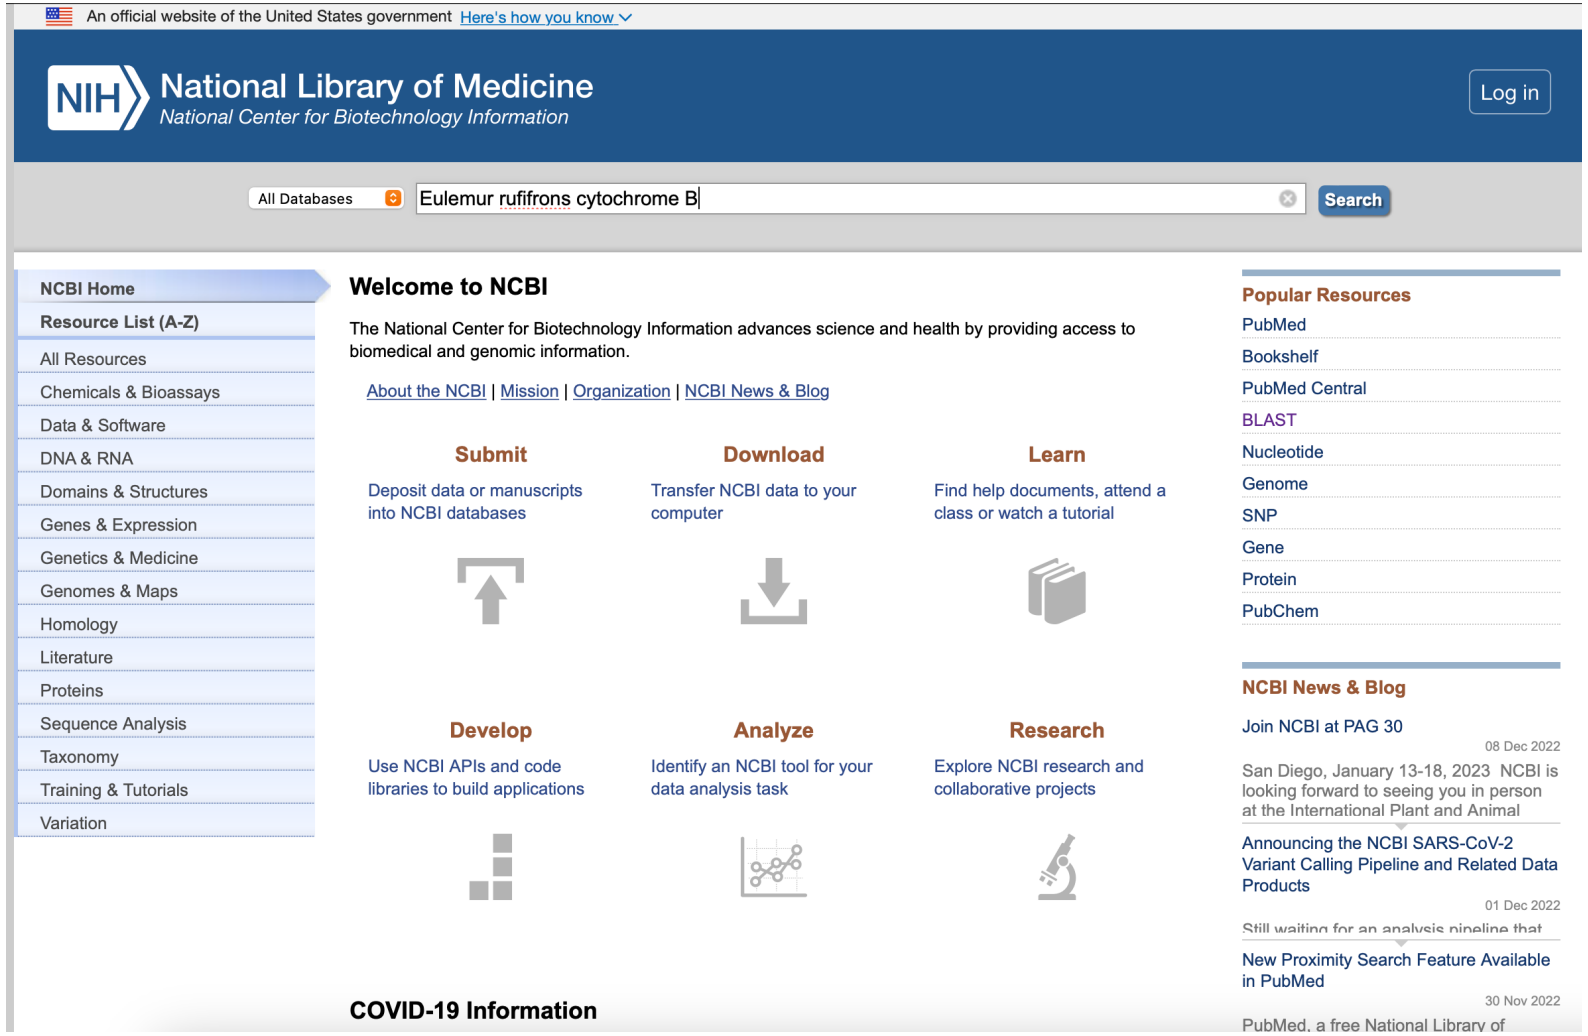

Allez au NCBI, et recherchez la chose pour laquelle vous voulez construire une phylogénie, dans notre cas le cytochrome B des lémuriens dans le parc national de Ranomafana

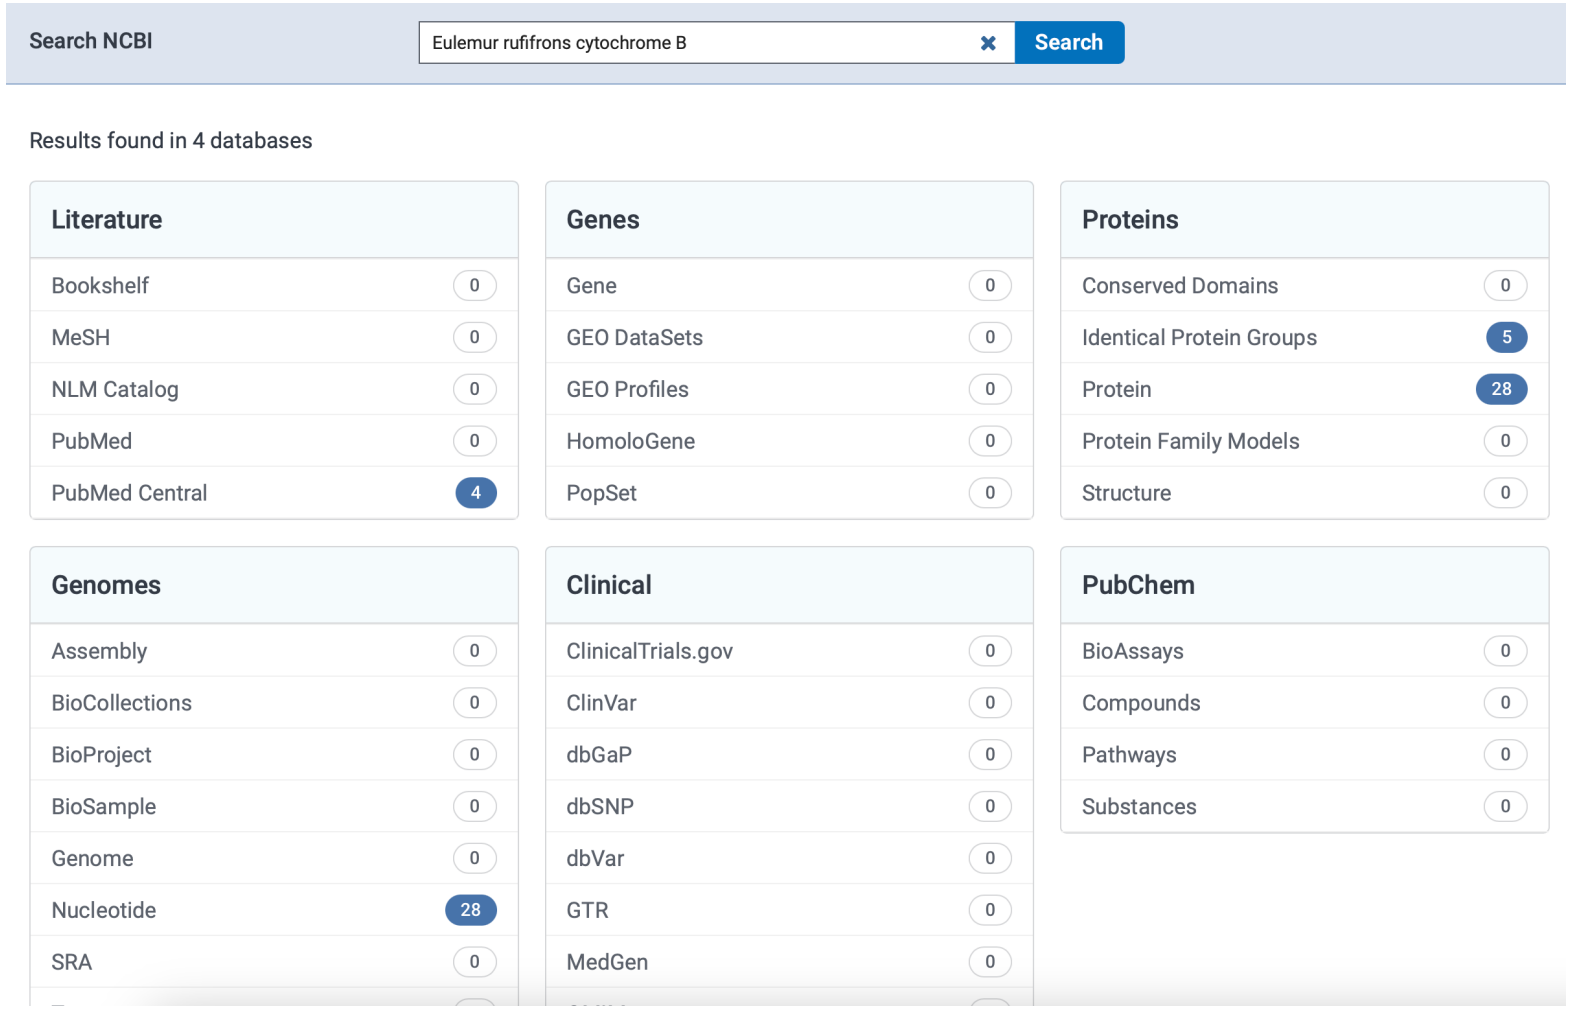

Voici à quoi cela ressemblera, vous pouvez aller à Nucléotide dans la catégorie génome et cliquer dessus

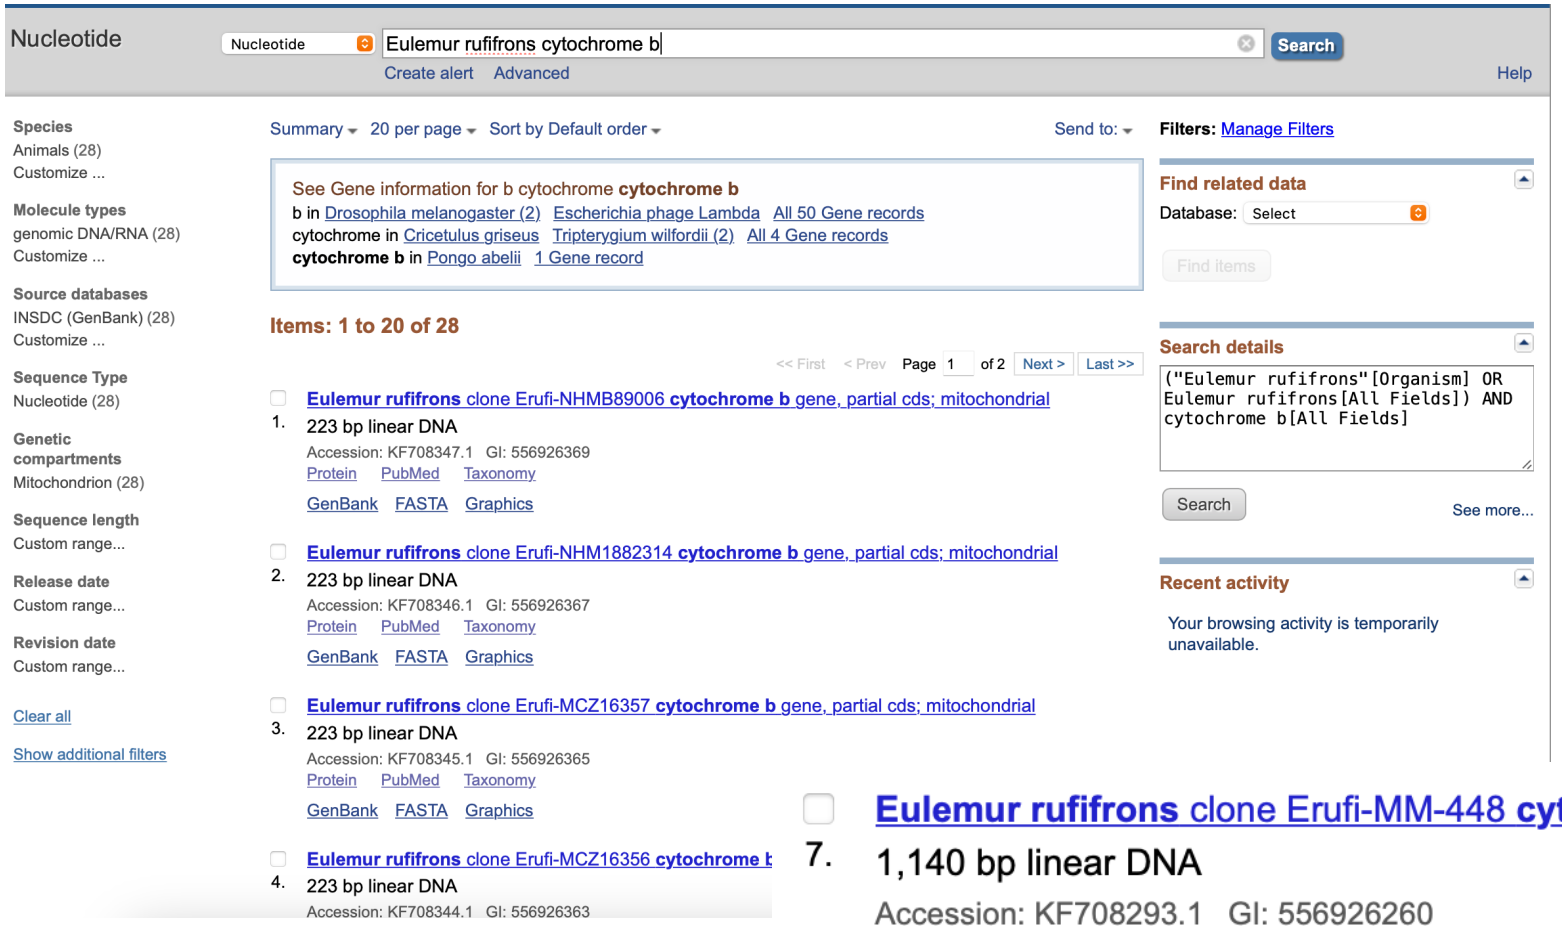

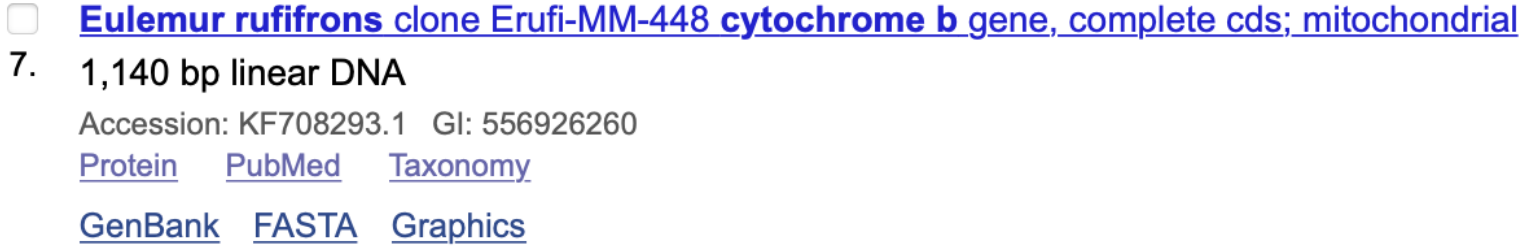

Choisissez la séquence de ce qui vous intéresse, dans notre cas nous voulons un cds complet

Nous pourrions vouloir des cds partiels si nous avons une séquence partielle d'intérêt, mais pour l'instant, nous construisons simplement un arbre avec des données connues, donc les cds complets sont les meilleurs

Cds : séquence codante pour la protéine

Ensuite, téléchargez le fastas

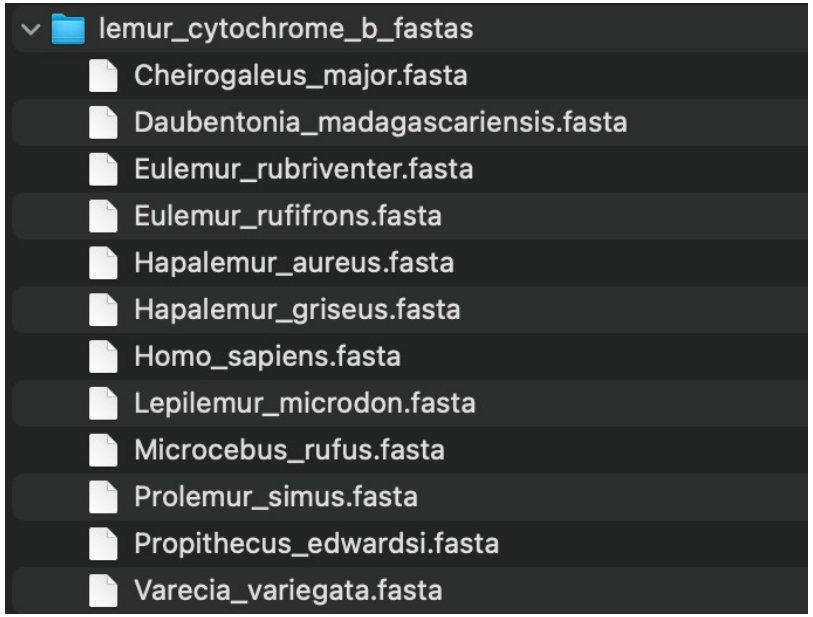

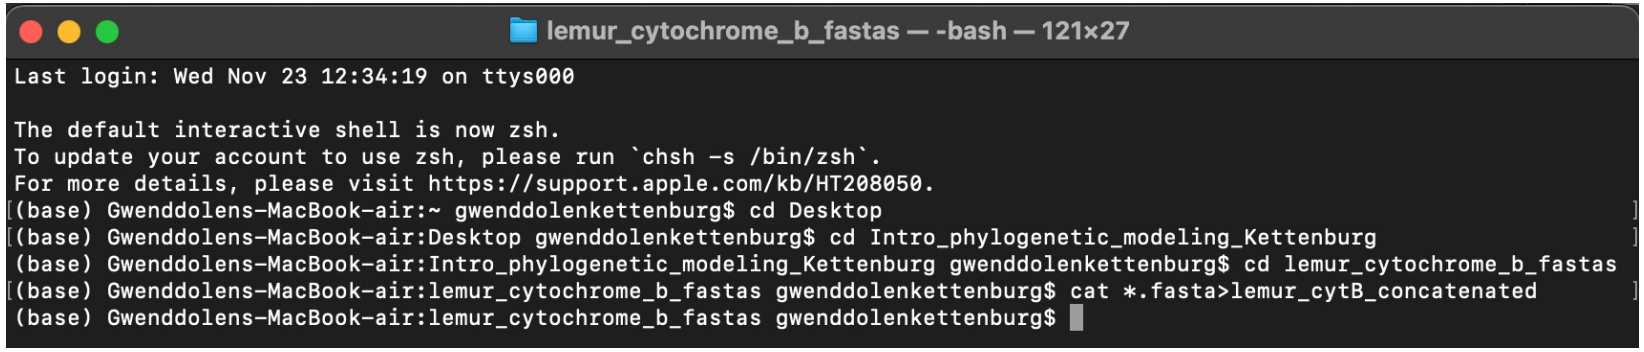

Lorsque vous avez toutes vos séquences d'intérêt et votre exogroupe, vous devez concaténer les séquences en un seul fichier, vous pouvez le faire en créant un fichier texte/édition et en collant chaque séquence, sinon suivez les instructions sur la ligne de commande (mac) ou powershell (windows) pour le faire

Example 1: Merge with file names (This will merge file1.csv & file2.csv to create concat.csv)

```
type file1.csv file2.csv > concat.csv
```

Example 2: Merge files with pattern (This will merge all files with csv extension and create concat.csv)

When using asterisk(*) to concatenate all files. Please DON'T use same extension for target file(Eg. .csv). There should be some difference in pattern else target file will also be considered in concatenation

```
type  *.csv > concat_csv.txt
```

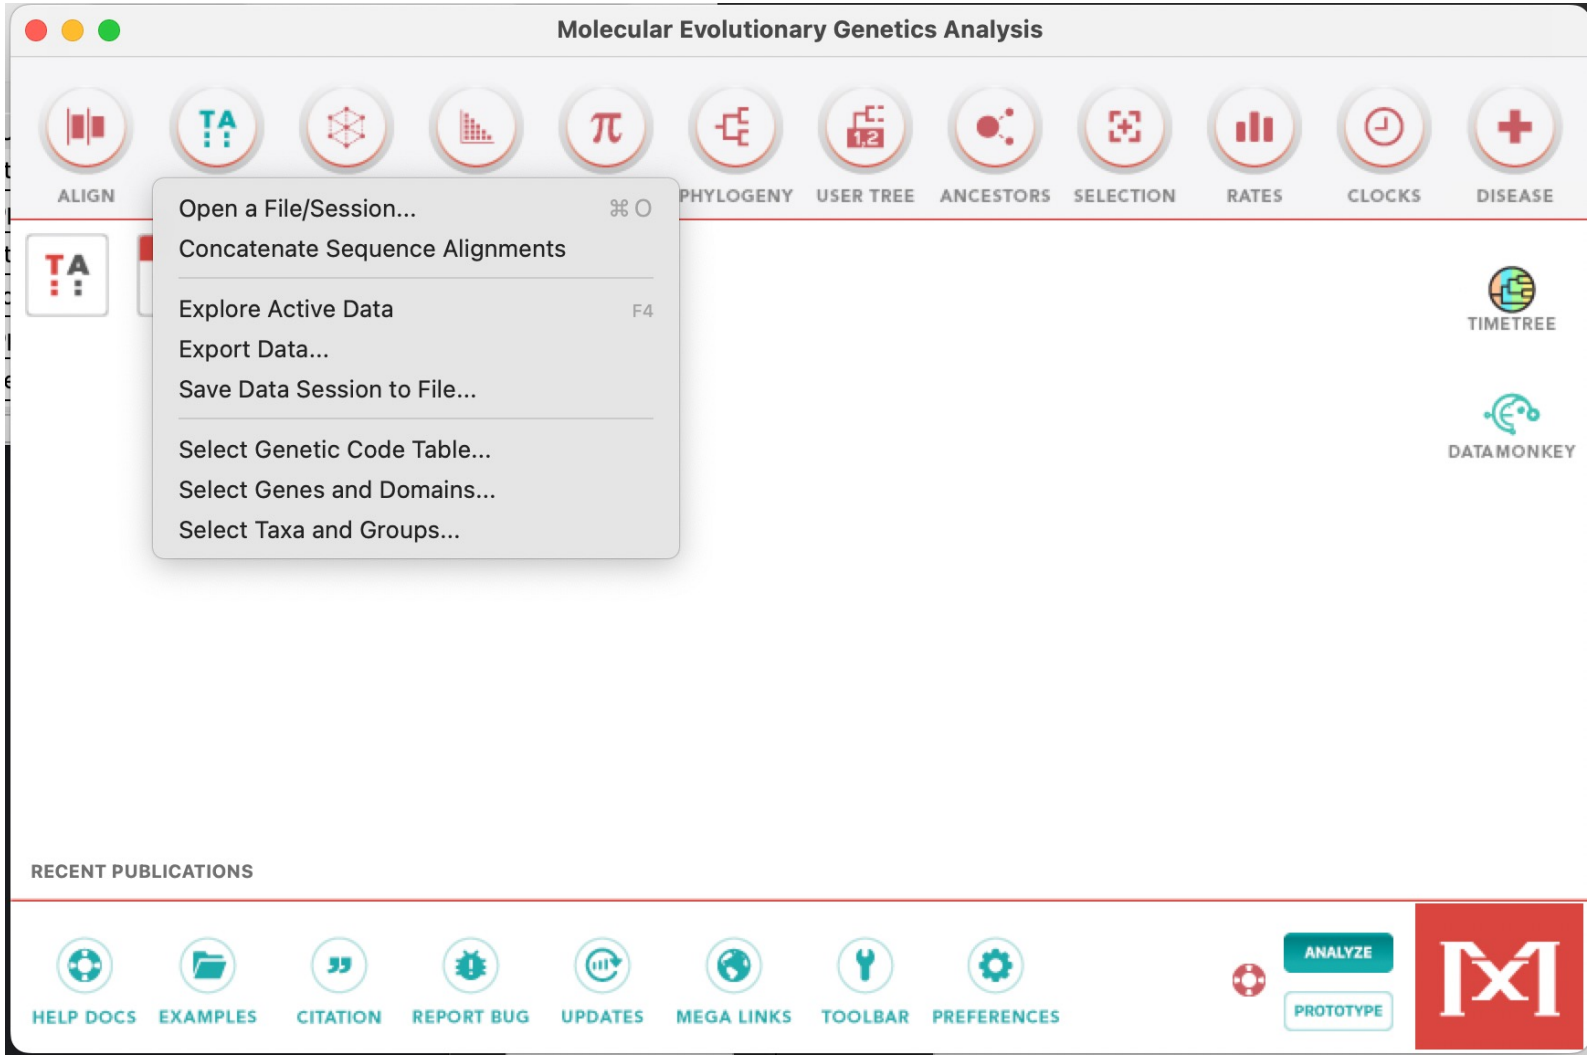

Ouvrez MEGA, et ouvrez un fichier/session, sélectionnez votre fichier fasta concaténé MEGA vous demandera si vous souhaitez aligner ou analyser, cliquez sur aligner

Les séquences sont donc chargées dans MEGA comme ceci :

Cliquez sur le bras musculaire pour l'aligner sur le programme MUSCLE

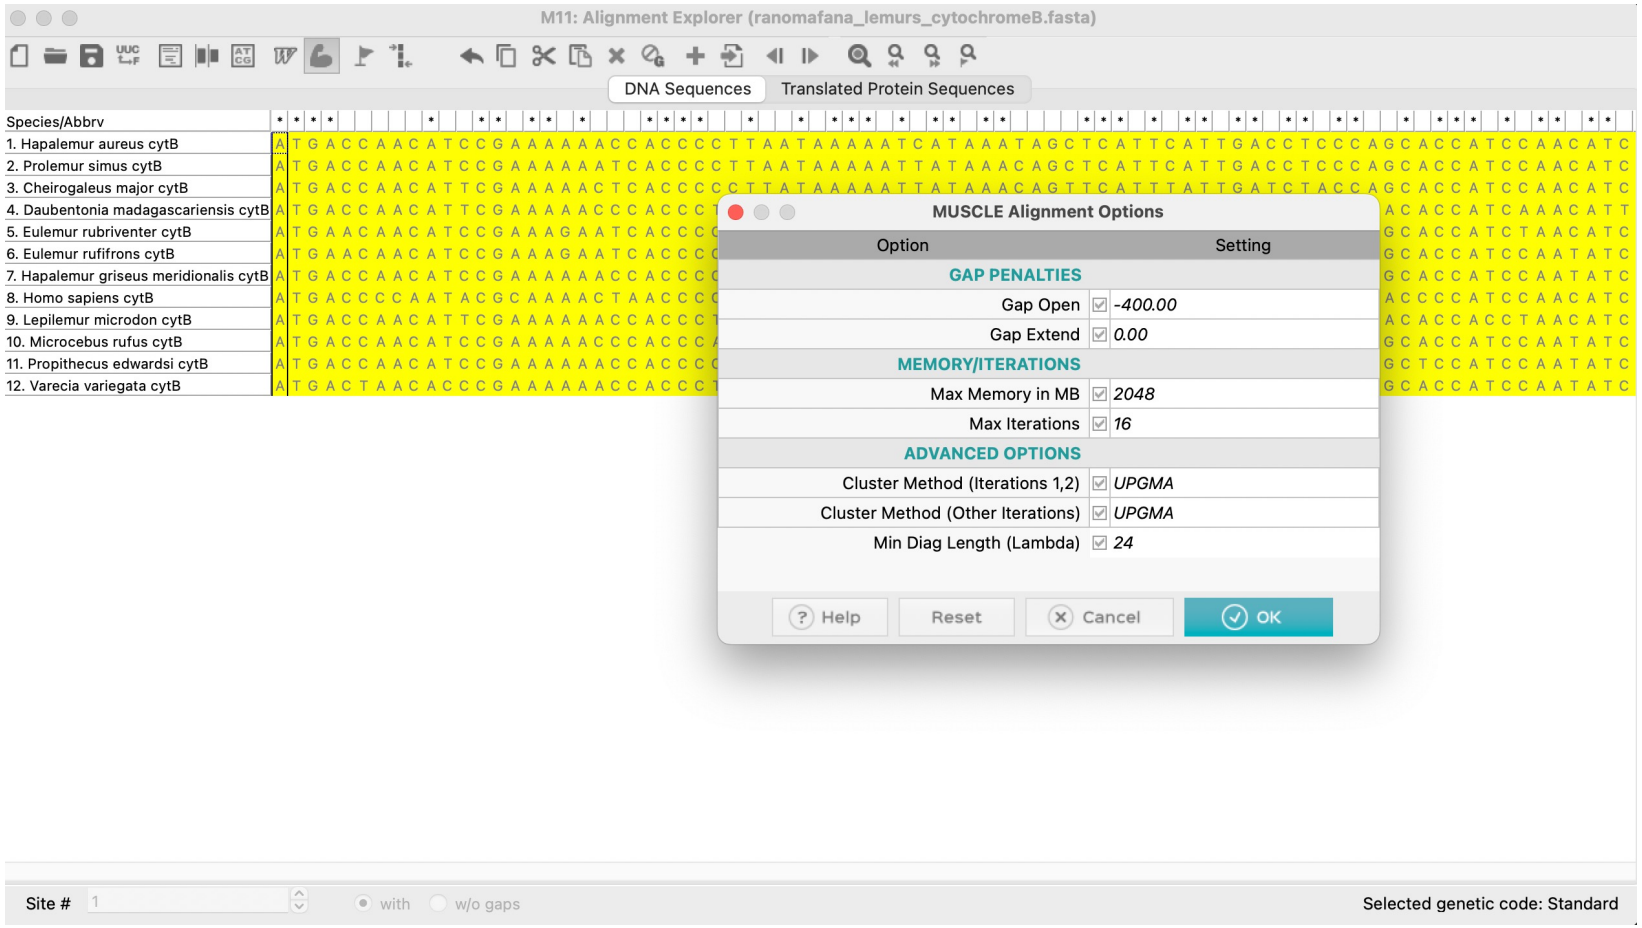

Suivez les options suggérées, puis appuyez sur OK

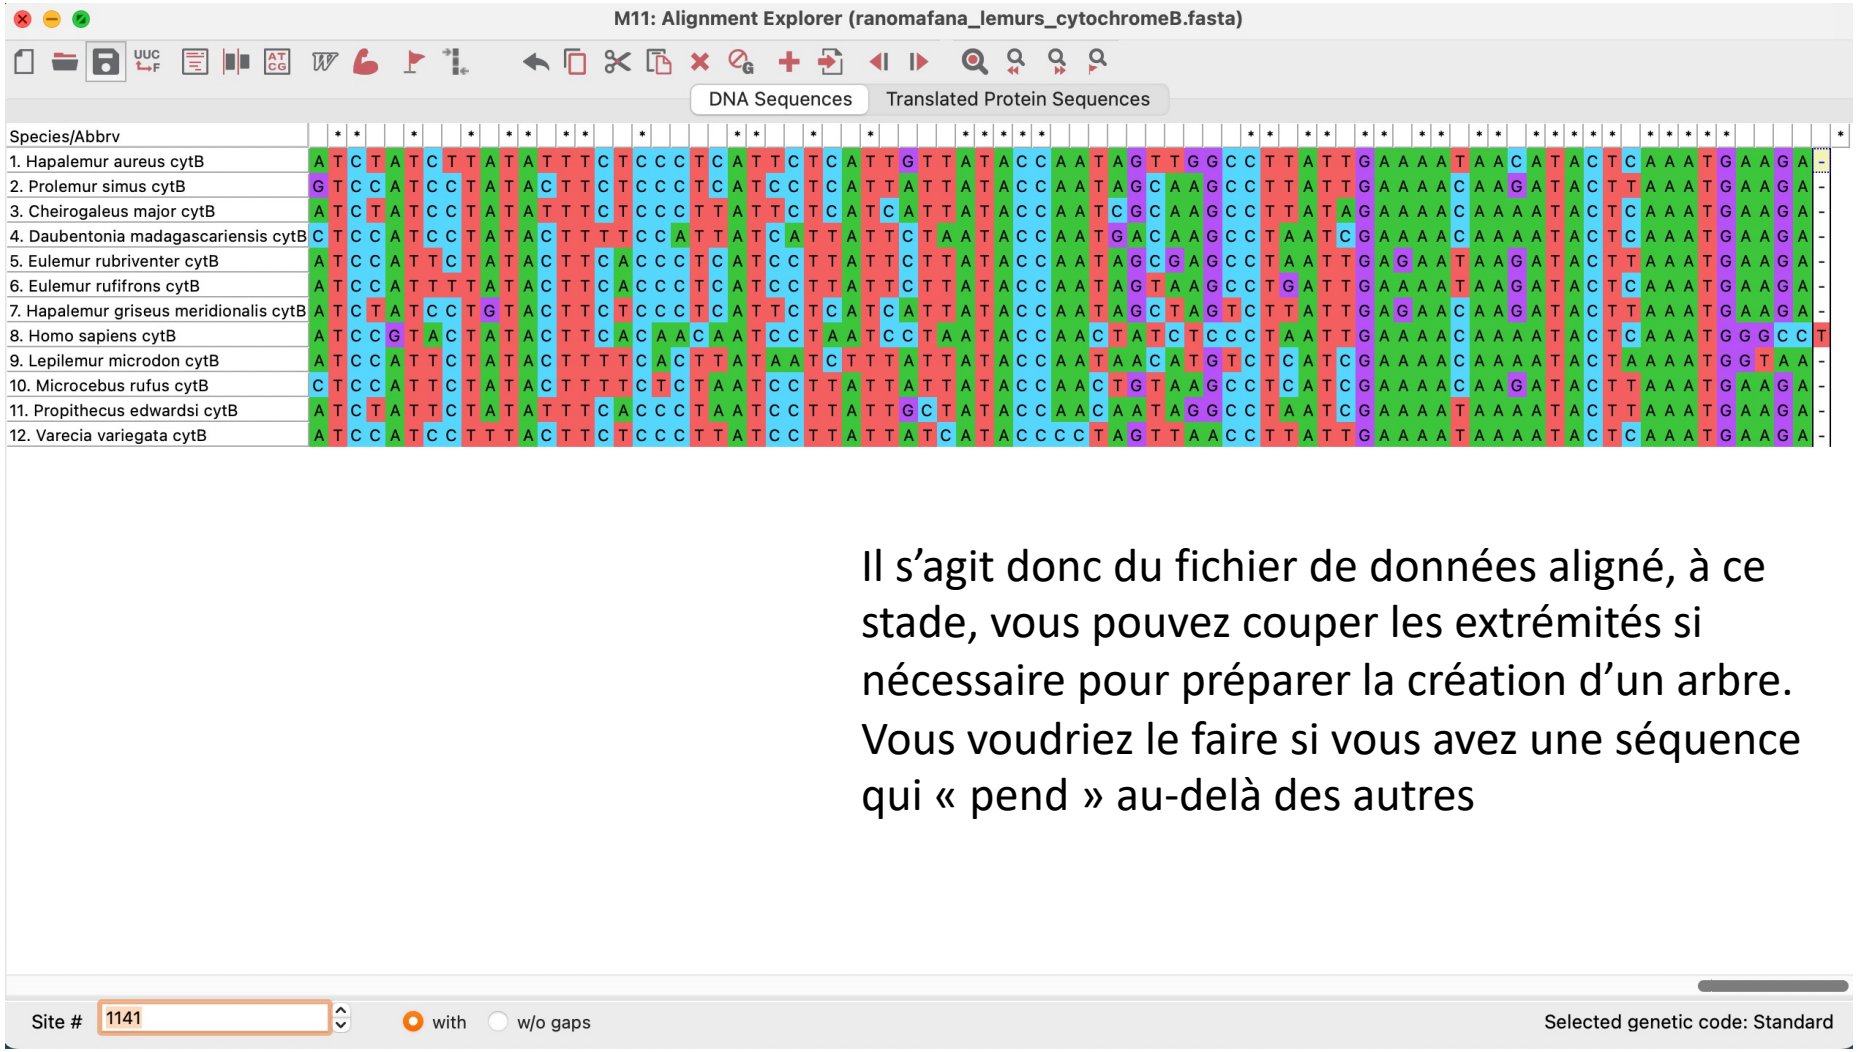

Il s'agit donc du fichier de données aligné, à ce stade, vous pouvez couper les extrémités si nécessaire pour préparer la création d'un arbre. Vous voudriez le faire si vous avez une séquence qui « pend » au-delà des autres

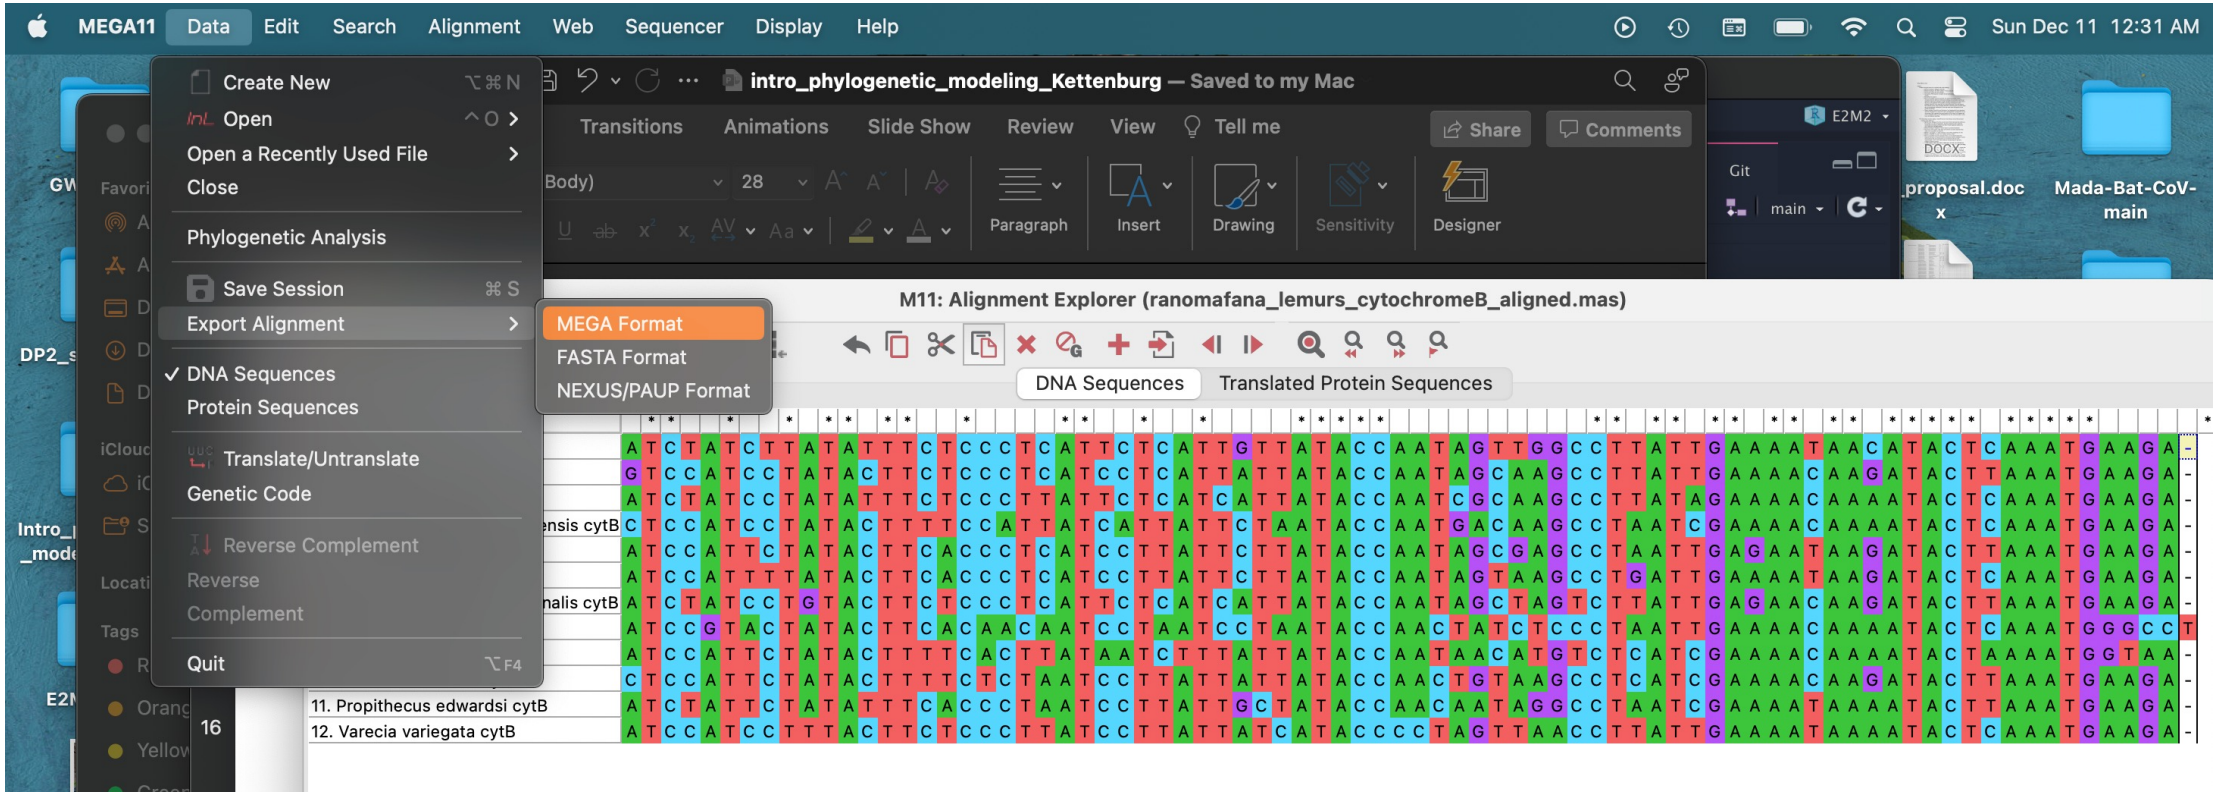

Enregistrez le fichier aligné, puis nous procéderons à la sélection du modèle

Ouvrir l’interface graphique RAxML

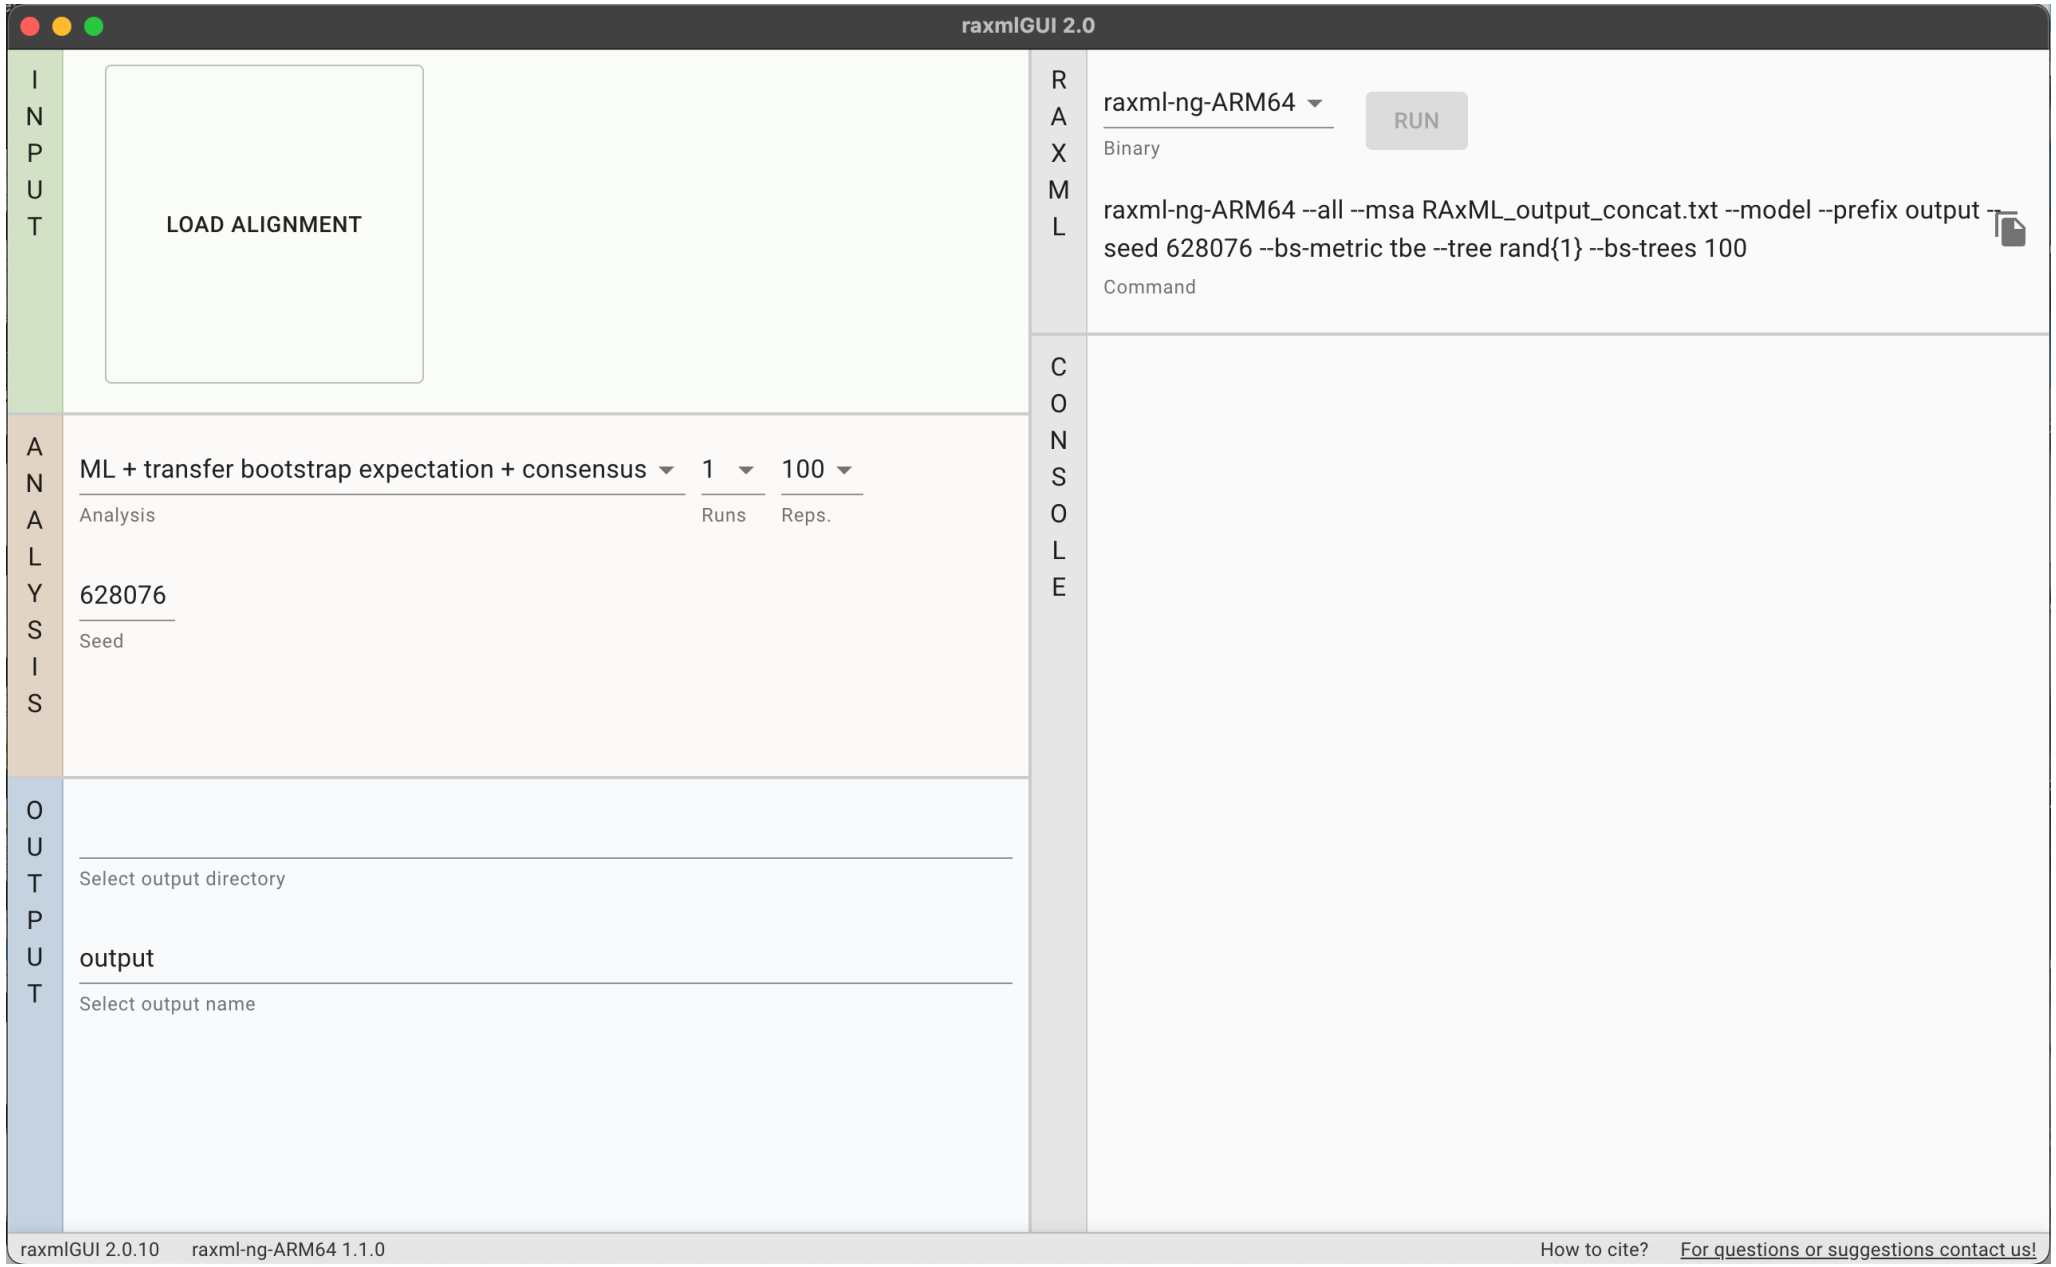

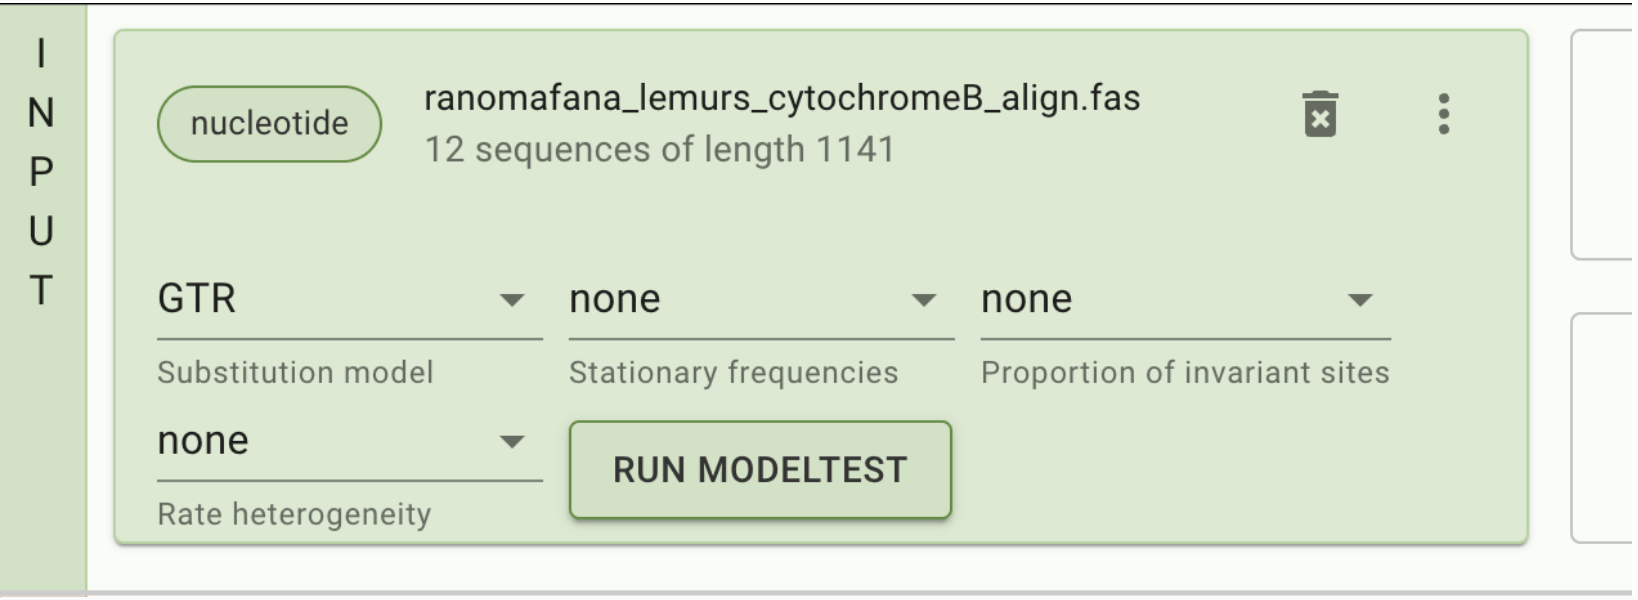

Partition 1/1:

	Model	Score	Weight
BIC	TIM2+I+G4	13908.7732	0.9990
AIC	TIM2+I+G4	13762.6230	0.8741
AICc	TIM2+I+G4	13763.6230	0.8741

Chargez le fichier aligné et effectuez modeltest, pour la sélection du modèle, utilisez le score BIC, il crachera un rapport qui s'enregistrera dans vos fichiers

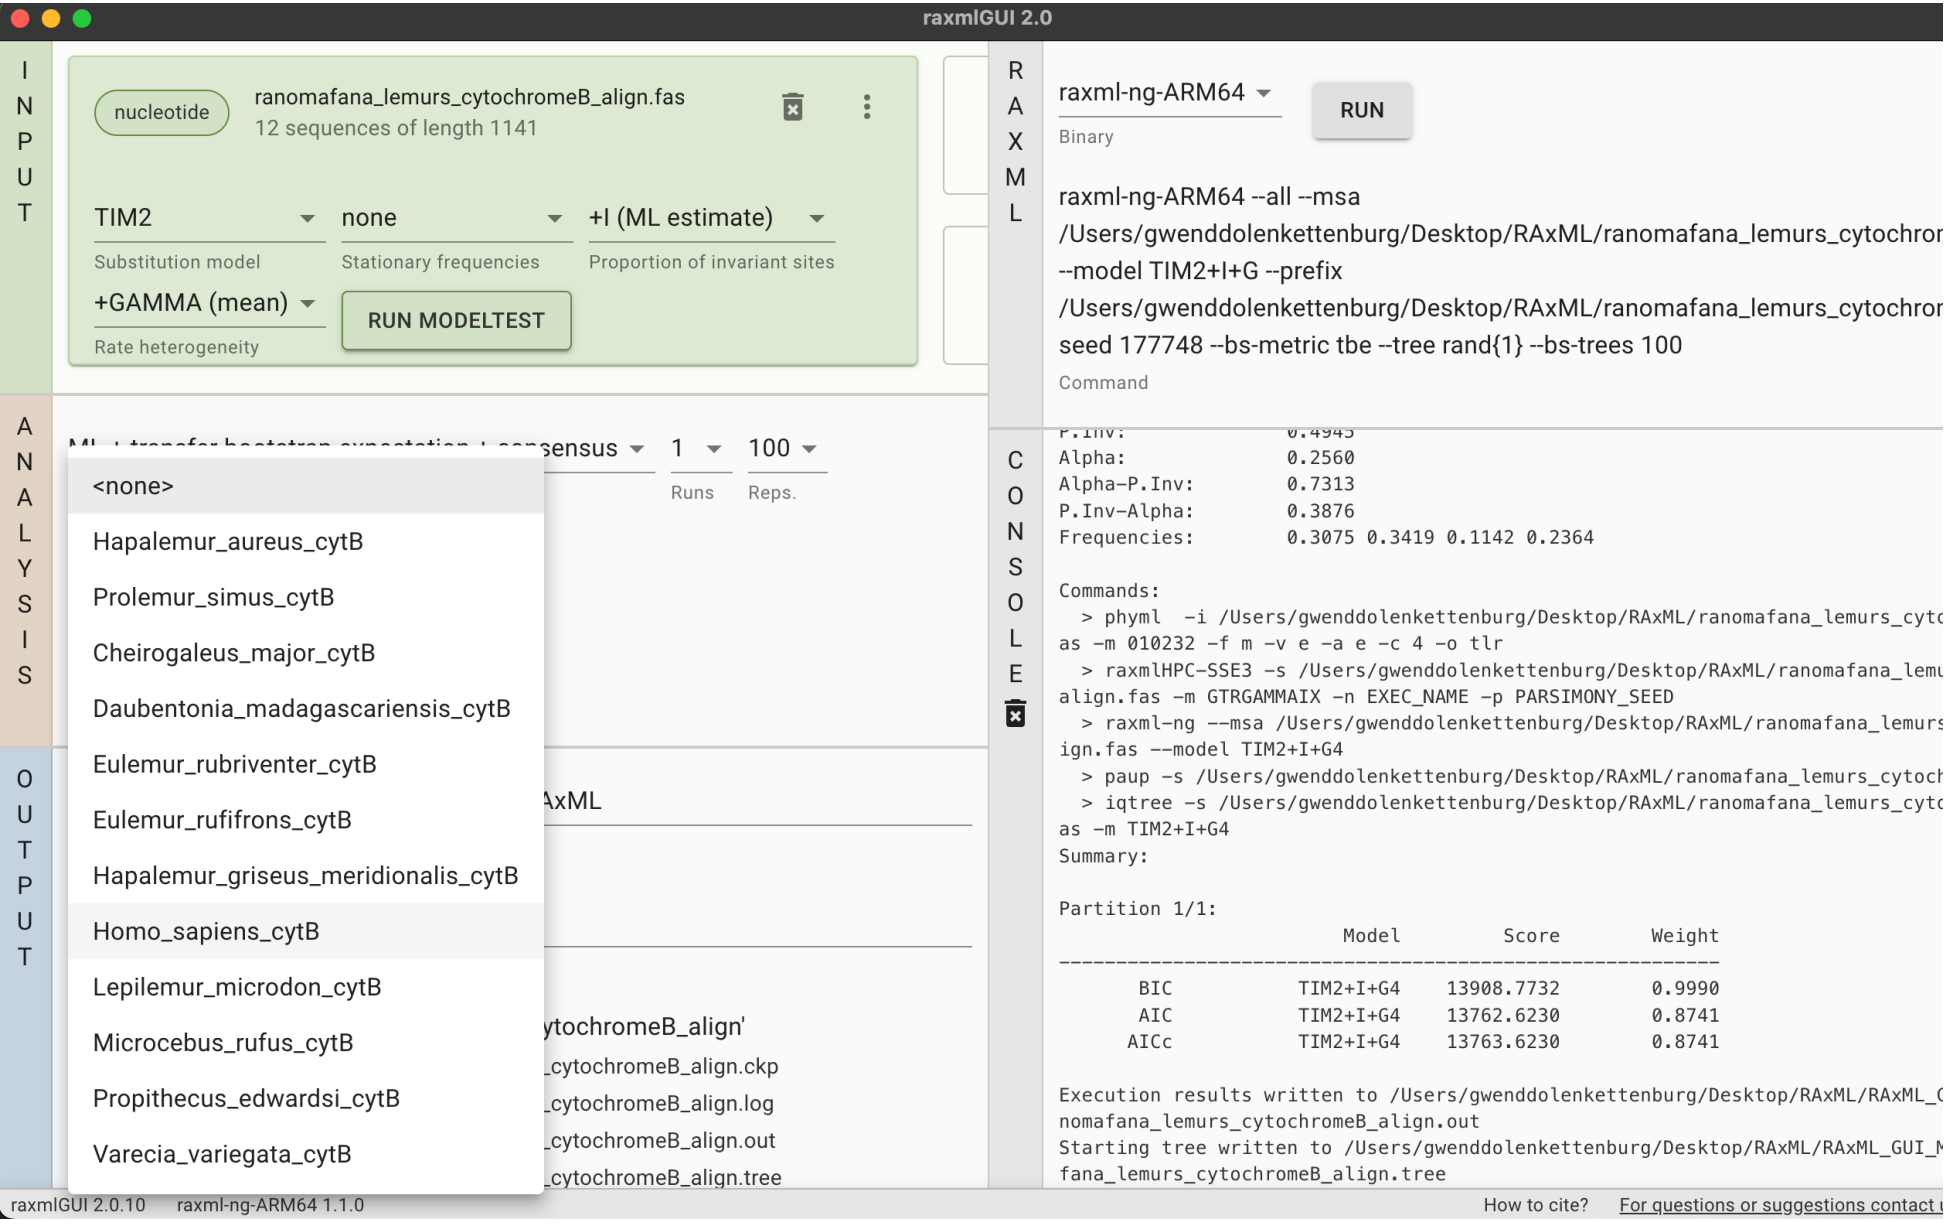

À l'aide du modèle de modeltest, modifiez selon vos besoins dans la zone de saisie, puis dans l'analyse, définissez l'outgroup, puis appuyez sur exécuter dans la section RAxML

Il va aussi recracher quelques fichiers...

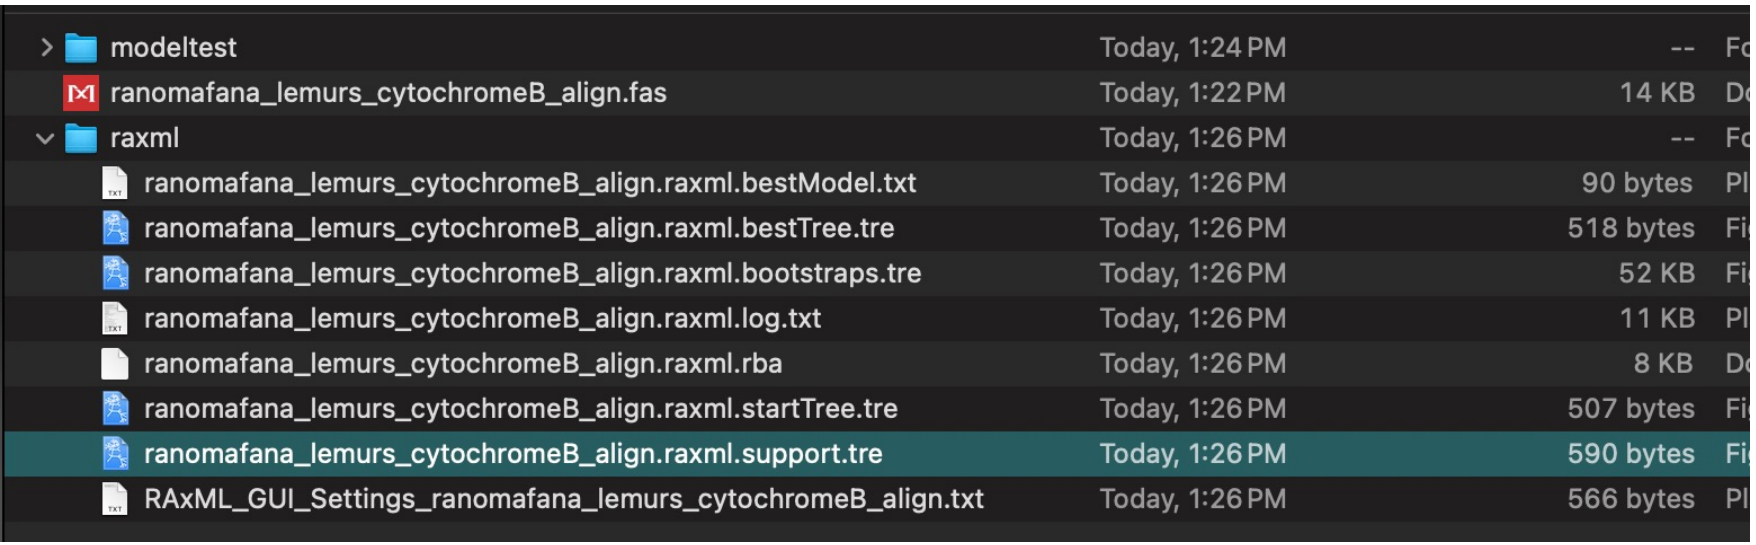

Nous sommes intéressés par le fichier .support.tre

Cela inclura la topologie de l'arborescence et les valeurs de prise en charge des amorçages, ouvertes dans MEGA

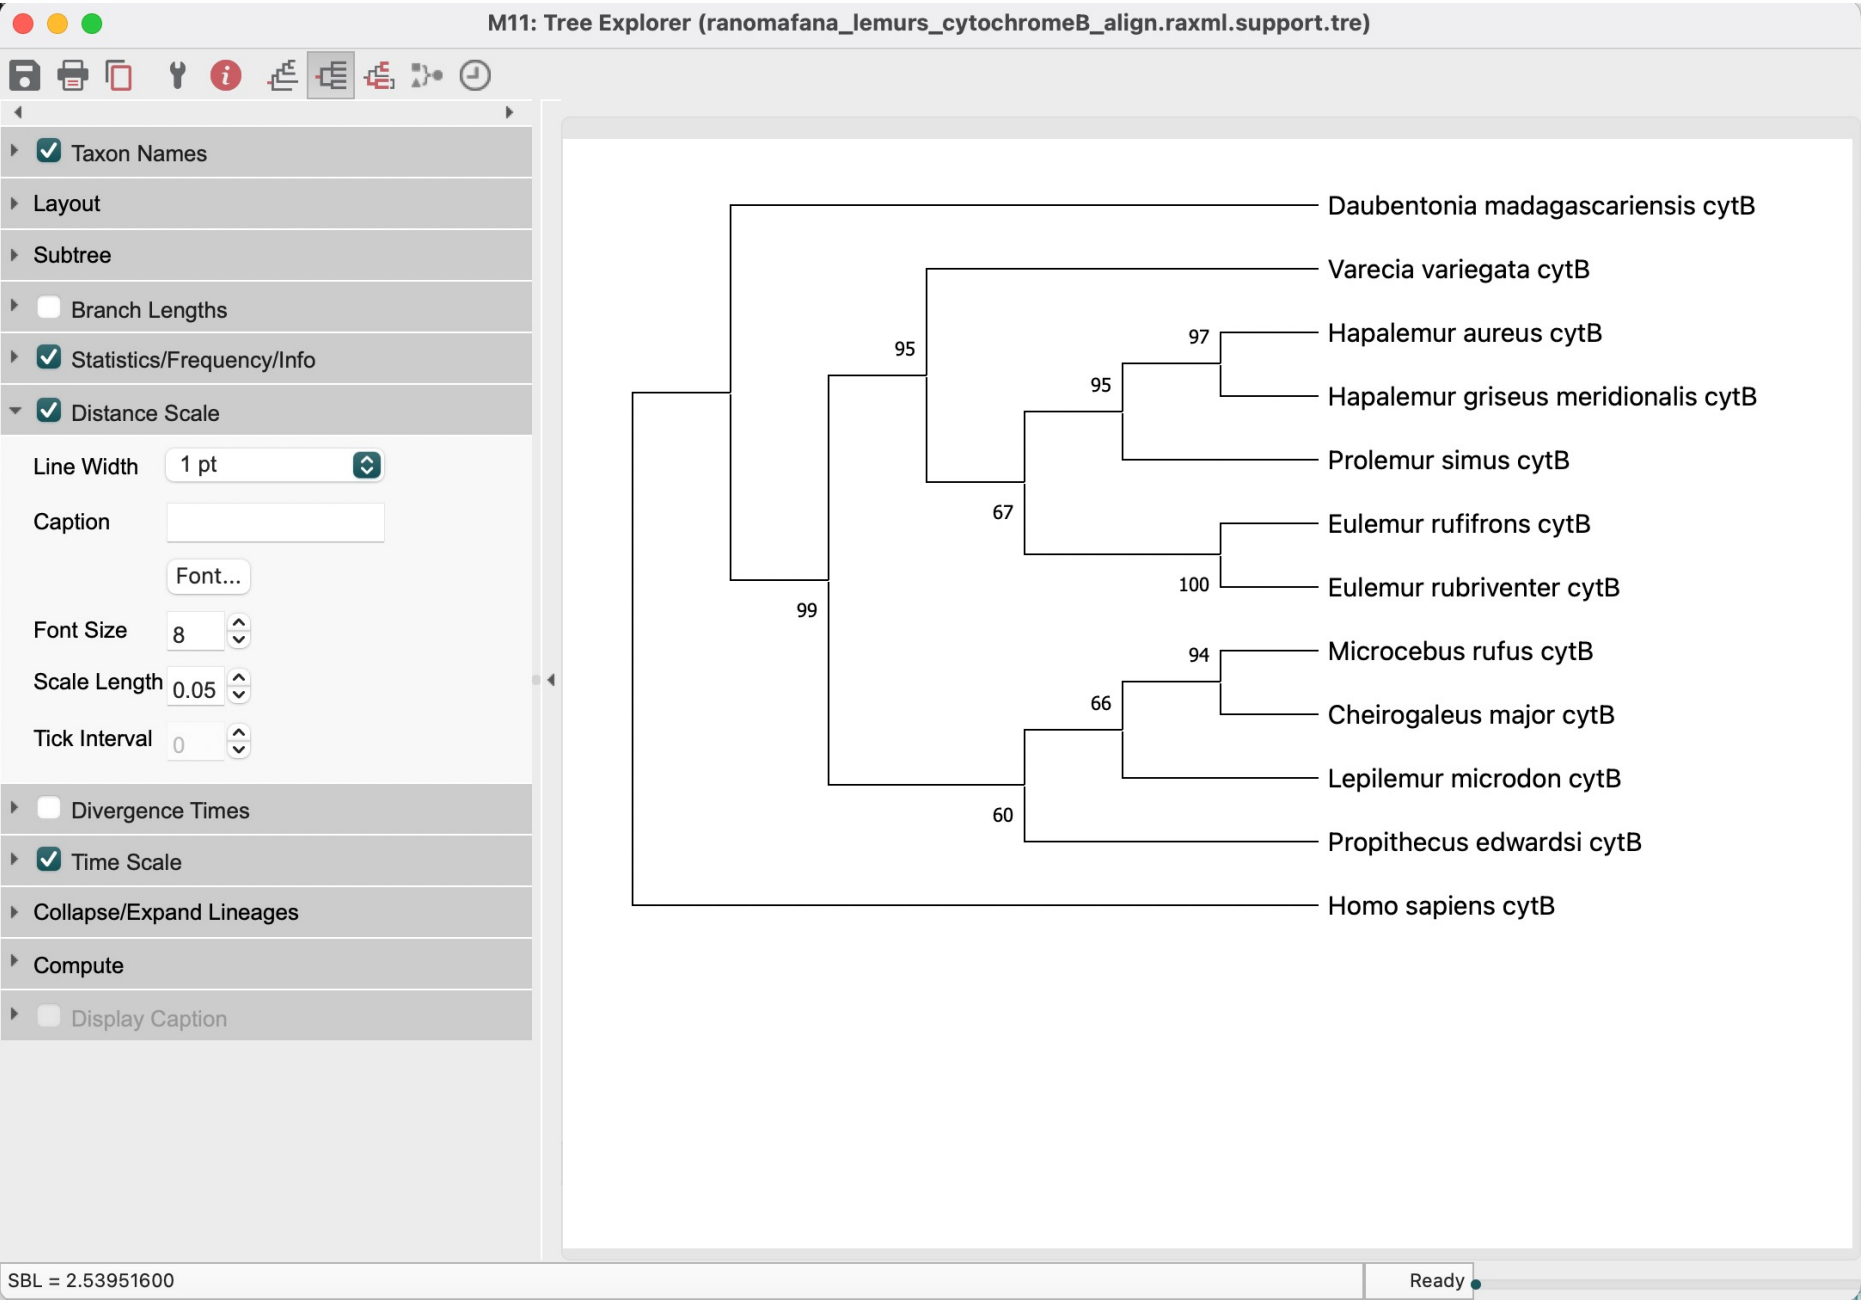

Nous voulons un fichier de l'arbre enregistré qui peut être lu dans R, donc newick. Cliquez sur Exporter les arbres... choisissez le format newick et personnalisez-le dans R

Vous pouvez également personnaliser dans MEGA... c'est juste plus limité

Nous aurions pu faire du modeltest et du RAxML dans MEGA aussi... mais prend une éternité !

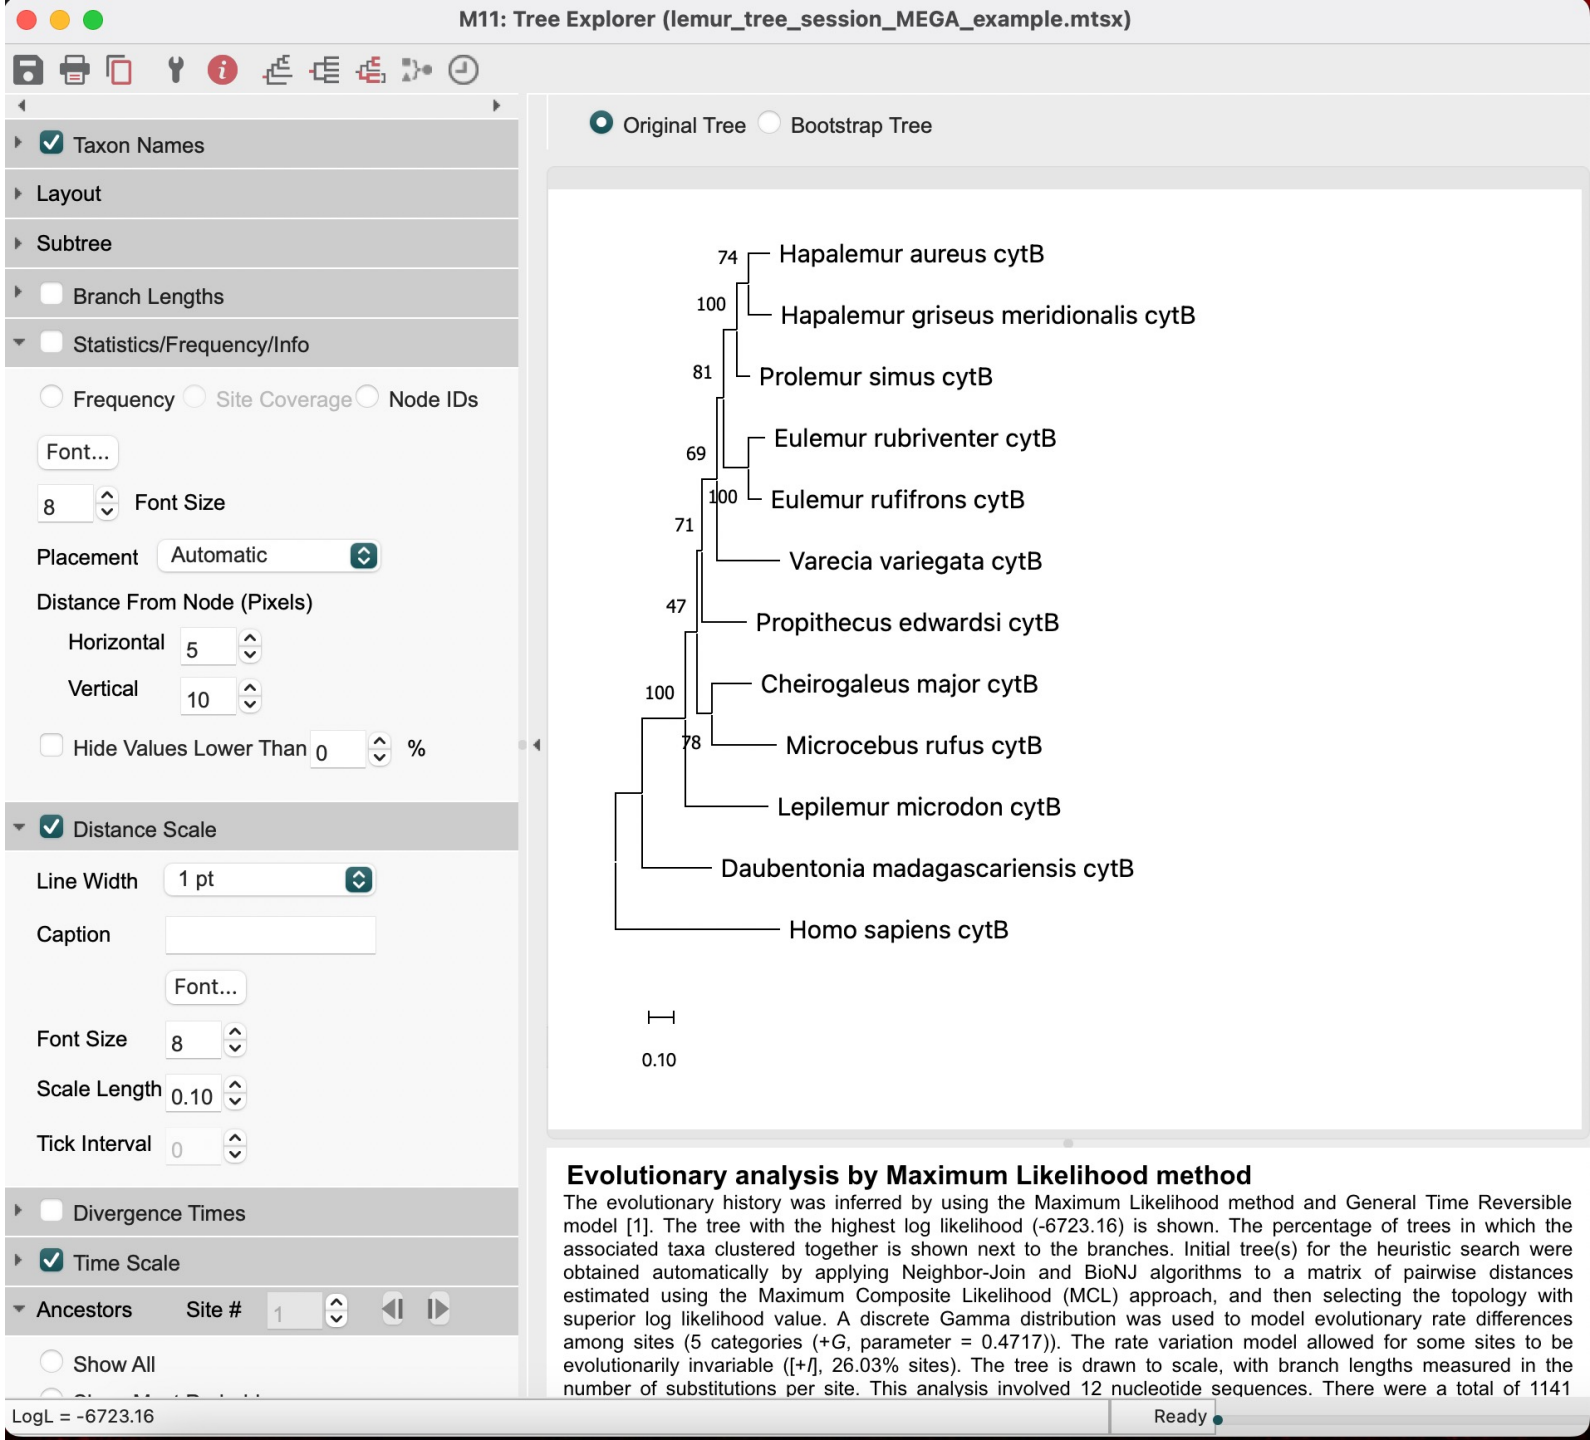

Alors faites joli en R !

- Suivez les instructions de lemur_tree_editing. Fichier R