

Maximum de vraisemblance

Guy Perrière & Héloïse Philippon

Laboratoire de Biométrie et Biologie Évolutive
UMR CNRS n° 5558
Université Claude Bernard – Lyon 1

31 novembre 2017



Historique

- Bases mathématiques développées dans les années 1920 par R.A. Fisher :
 - Génération d'estimateurs applicables à des cas plus complexes que ceux traités jusqu'alors en statistiques.
- Première application à la phylogénie moléculaire par Neyman (1971).
- Élargissement par Kashyap et Subas (1974) puis par Felsenstein (1981).
- Permet d'inférer des états de caractères ancestraux.
- Nécessite en théorie l'exploration de l'ensemble des topologies possibles.

Distribution discrète

- La *fonction de vraisemblance* d'une hypothèse H est définie par :

$$L(H) = \mathbb{P}(D|H)$$

soit la probabilité d'observer les données D sous l'hypothèse H .

- Maintenant, si D se décompose en ℓ observations indépendantes $D^{(i)}$ ($1 \leq i \leq \ell$), alors :

$$L(H) = \mathbb{P}(D^{(1)}|H) \times \mathbb{P}(D^{(2)}|H) \times \cdots \times \mathbb{P}(D^{(\ell)}|H)$$

$$= \prod_{i=1}^{\ell} L^{(i)}(H) = \prod_{i=1}^{\ell} \mathbb{P}(D^{(i)}|H)$$

Soit, sous forme logarithmique :

$$\ln L(H) = \sum_{i=1}^{\ell} \ln L^{(i)}(H) = \sum_{i=1}^{\ell} \ln \mathbb{P}(D^{(i)}|H)$$

Distribution continue

- Expression sous la forme d'une *fonction de densité*.
- Soit $\mathbf{x} = (x_1, x_2, x_3, \dots, x_\ell)$ un échantillon provenant d'une distribution de paramètres $\boldsymbol{\theta} = (\theta_1, \theta_2, \dots, \theta_k)$ inconnus.
- Dans ce cas, la fonction de vraisemblance associée est telle que :

$$\begin{aligned} L(\boldsymbol{\theta}) &= f(\mathbf{x}|\boldsymbol{\theta}) = f(x_1|\boldsymbol{\theta}) \times f(x_2|\boldsymbol{\theta}) \times \cdots \times f(x_\ell|\boldsymbol{\theta}) \\ &= \prod_{i=1}^{\ell} f(x_i|\boldsymbol{\theta}) \end{aligned}$$

Soit, sous forme logarithmique :

$$\ln L(\boldsymbol{\theta}) = \sum_{i=1}^{\ell} \ln f(x_i|\boldsymbol{\theta})$$

Caractéristiques

■ Maximiser la vraisemblance consiste à :

- Trouver un ensemble d'estimations des paramètres $\hat{\boldsymbol{\theta}}$ de façon à ce que que $f(\mathbf{x}|\hat{\boldsymbol{\theta}})$ soit maximisée.
- La fonction de vraisemblance $f(\mathbf{x}|\boldsymbol{\theta})$ n'est *pas* une fonction de densité de probabilité et, la plupart du temps :

$$\int f(\mathbf{x}|\boldsymbol{\theta})d\boldsymbol{\theta} \neq 1$$

■ Les estimations au maximum de vraisemblance sont :

- Non biaisées ($\mathbb{E}(\hat{\boldsymbol{\theta}}) = \boldsymbol{\theta}$).
- Consistantes (l'estimation converge vers la vraie valeur quand $\ell \rightarrow \infty$).
- De variance minimale.

Notations pour la phylogénie

- En phylogénie moléculaire, les données sont représentées par un ensemble de séquences alignées S :
 - Chaque site dans l'alignement est désigné par le terme $S^{(i)}$ ($1 \leq i \leq \ell$).
- Par ailleurs, le vecteur des paramètres est $\boldsymbol{\theta} = (\tau, \mathbf{b}, \boldsymbol{\vartheta}, \alpha)$, avec :
 - τ la topologie de l'arbre.
 - \mathbf{b} le vecteur des longueurs de branches.
 - $\boldsymbol{\vartheta}$ le vecteur des paramètre du modèle d'évolution utilisé.
 - α le paramètre de forme de la loi Gamma, le cas échéant.
- On en déduit l'expression de la vraisemblance de S , étant donné $\boldsymbol{\theta}$:

$$L(\boldsymbol{\theta}) = \mathbb{P}(S|\boldsymbol{\theta}) = \prod_{i=1}^{\ell} \mathbb{P}\left(S^{(i)}|\tau, \mathbf{b}, \boldsymbol{\vartheta}, \alpha\right)$$

Modèle de Jukes et Cantor

- Le calcul de la distance évolutive entre deux séquences au moyen du modèle de Jukes et Cantor est donnée par la formule :

$$d = -\frac{3}{4} \ln \left(1 - \frac{4}{3}p \right) \Leftrightarrow p = \frac{3}{4} - \frac{3}{4}e^{-4d/3}$$

- Soit ℓ le nombre de sites dans l'alignement et n le nombre de sites pour lesquels il y a une substitution entre les deux séquences :
 - Dans ce cas, la fonction de vraisemblance pour d est donnée par la loi binomiale $\mathcal{B}(\ell, p)$ telle que :

$$\begin{aligned} L(d) &= f(p|d) = \binom{\ell}{n} p^n (1-p)^{\ell-n} \\ &= \frac{\ell!}{n!(\ell-n)!} \left(\frac{3}{4} - \frac{3}{4}e^{-4d/3} \right)^n \left(\frac{1}{4} + \frac{3}{4}e^{-4d/3} \right)^{\ell-n} \end{aligned}$$

Simplification des calculs


- Le coefficient binomial $\binom{\ell}{n}$ étant une constante, il peut être omis pour effectuer les calculs :
 - La vraisemblance obtenue change, mais le maximum sera toujours obtenu pour la même valeur de d .
- Passage en logarithmes pour éviter les dérives numériques du fait que les valeurs attendues sont très faibles :

$$\ln L(d) \propto n \ln \left(\frac{3}{4} - \frac{3}{4} e^{-4d/3} \right) + (\ell - n) \ln \left(\frac{1}{4} + \frac{3}{4} e^{-4d/3} \right)$$

- Variation des valeurs de d sur l'intervalle $[0.001, 2]$, réaliste du point de vue évolutif.


Application numérique

- Paire Homme-Gorille du jeu de données de Brown *et al.* (1982) :
 - $\ell = 896$
 - $n = 89$
- Calcul direct de la distance :
 - $d \simeq 0.1066$
- Estimation au maximum de vraisemblance :
 - $\max[\ln(L(d))] \simeq -289.95$
soit $d \simeq 0.1066$



Arbre à quatre UTO

- Soit un arbre à quatre UTO de topologie τ et dont les longueurs de branches sont fixées.
- U_1, U_2, U_3 et U_4 représentent les feuilles de l'arbre.
- V_1, V_2 et V_3 représentent les nœuds internes.
- Les états de caractères correspondants sont dénotés par $u_1, u_2, u_3, u_4, v_1, v_2, v_3 \in \{A, C, T, G\}$.



Fonction de vraisemblance

- La vraisemblance à un site $S^{(i)}$ de l'alignement est telle que :

$$\begin{aligned} L^{(i)}(\boldsymbol{\theta}) &= \mathbb{P}(S^{(i)} | \tau, \mathbf{b}, \boldsymbol{\vartheta}) \\ &= \mathbb{P}(u_1, u_2, u_3, u_4, v_1, v_2, v_3 | \tau, \mathbf{b}, \boldsymbol{\vartheta}) \end{aligned}$$

- Or les états ancestraux v_1 , v_2 et v_3 sont inconnus :

- Nécessité de prendre en compte tous les scénarios évolutifs possibles à chaque noeud interne de l'arbre.
- L'expression de la vraisemblance s'écrit alors comme :

$$\begin{aligned} L^{(i)}(\boldsymbol{\theta}) &= \sum_{v_1} \sum_{v_2} \sum_{v_3} \mathbb{P}(v_1) \mathbb{P}(v_2 | v_1, b_5) \mathbb{P}(v_3 | v_1, b_6) \mathbb{P}(u_1 | v_2, b_1) \\ &\quad \times \mathbb{P}(u_2 | v_2, b_2) \mathbb{P}(u_3 | v_3, b_3) \mathbb{P}(u_4 | v_3, b_4) \end{aligned}$$

Calcul de la vraisemblance

- La détermination de la vraisemblance totale nécessite le calcul de $L^{(i)}(\theta)$ pour chacun des ℓ sites.
- Le calcul des probabilités conditionnelles $\mathbb{P}(x|y, b)$ se fait par l'intermédiaire des modèles probabilistes vus précédemment.
- Sous l'hypothèse que le processus markovien modélisant l'évolution des séquences est à l'état stationnaire, on a :

$$\mathbb{P}(v_1) = \pi_{v_1}$$

La valeur de π_{v_1} étant estimée par la fréquence de l'état de caractère v_1 dans S .


Exemple de calcul

■ Données :

- Site de l'alignement tel que : $u_1 = \text{C}$, $u_2 = \text{T}$, $u_3 = \text{A}$, $u_4 = \text{A}$.

■ Vecteur des paramètres θ :

- Topologie τ racinée en V_1 .
- Vecteur \mathbf{b} des longueurs de branches tel que : $b_1 = 0.5$, $b_2 = 0.4$, $b_3 = b_6 = 0.3$, $b_4 = b_5 = 0.2$
- Modèle de Jukes et Cantor à un paramètre (p) :
 - Fréquences à l'équilibre $\pi_i = 1/4 \forall i$.



Probabilités de substitution

- Calcul des probabilités de substitution associées à chaque branche de longueur b au moyen de la relation :

$$p(b) = \frac{3}{4} - \frac{3}{4}e^{-4b/3}$$

On en déduit les valeurs de $p(b)$ pour les différentes longueurs de branches observées :

- $p(b_1) = p(0.5) = 0.36$
- $p(b_2) = p(0.4) = 0.31$
- $p(b_3) = p(b_6) = p(0.3) = 0.25$
- $p(b_4) = p(b_5) = p(0.2) = 0.18$

- Les probabilités de substitution p_{ij} ($i \neq j$) sont toutes égales à $p(b)/3$.
- Les probabilités de conservations p_{ii} sont toutes égales à $1 - p(b)$.

Matrices de substitution

- On en déduit les matrices de substitution $\mathbf{P}(b)$ associées aux différentes longueurs de branches :
 - Valeurs utilisées pour calculer les probabilités conditionnelles $\mathbb{P}(x|y, b)$:

$$\mathbf{P}(0.5) = \begin{pmatrix} 0.64 & 0.12 & 0.12 & 0.12 \\ 0.12 & 0.64 & 0.12 & 0.12 \\ 0.12 & 0.12 & 0.64 & 0.12 \\ 0.12 & 0.12 & 0.12 & 0.64 \end{pmatrix} \quad \mathbf{P}(0.4) = \begin{pmatrix} 0.69 & 0.10 & 0.10 & 0.10 \\ 0.10 & 0.69 & 0.10 & 0.10 \\ 0.10 & 0.10 & 0.69 & 0.10 \\ 0.10 & 0.10 & 0.10 & 0.69 \end{pmatrix}$$

$$\mathbf{P}(0.3) = \begin{pmatrix} 0.75 & 0.08 & 0.08 & 0.08 \\ 0.08 & 0.75 & 0.08 & 0.08 \\ 0.08 & 0.08 & 0.75 & 0.08 \\ 0.08 & 0.08 & 0.08 & 0.75 \end{pmatrix} \quad \mathbf{P}(0.2) = \begin{pmatrix} 0.82 & 0.06 & 0.06 & 0.06 \\ 0.06 & 0.82 & 0.06 & 0.06 \\ 0.06 & 0.06 & 0.82 & 0.06 \\ 0.06 & 0.06 & 0.06 & 0.82 \end{pmatrix}$$

Calcul d'une valeur

- On se place dans le cas où $v_1 = v_2 = v_3 = A$:

- Calcul de :

$$\begin{aligned} & \mathbb{P}(v_1 = A)\mathbb{P}(v_2 = A|v_1 = A, b_5 = 0.2)\mathbb{P}(v_3 = A|v_1 = A, b_6 = 0.3) \\ & \times \mathbb{P}(u_1 = C|v_2 = A, b_1 = 0.5)\mathbb{P}(u_2 = T|v_2 = A, b_2 = 0.4) \\ & \times \mathbb{P}(u_3 = A|v_3 = A, b_3 = 0.3)\mathbb{P}(u_4 = A|v_3 = A, b_4 = 0.2) \end{aligned}$$

Soit, avec une écriture simplifiée :

$$\begin{aligned} & \mathbb{P}(A)\mathbb{P}(A|A, 0.2)\mathbb{P}(A|A, 0.3)\mathbb{P}(C|A, 0.5)\mathbb{P}(T|A, 0.4) \\ & \times \mathbb{P}(A|A, 0.3)\mathbb{P}(A|A, 0.2) \\ & = \pi_A p_{AA}(0.2)p_{AA}(0.3)p_{CA}(0.5)p_{TA}(0.4)p_{AA}(0.3)p_{AA}(0.2) \\ & = 0.25 \times 0.82 \times 0.75 \times 0.12 \times 0.10 \times 0.75 \times 0.82 \\ & = 0.001134675 \end{aligned}$$

Calcul des toutes les combinaisons (I)


v_1	v_2	v_3	Vraisemblance	v_1	v_2	v_3	Vraisemblance
A	A	A	1.134675×10^{-3}	C	A	A	8.856×10^{-6}
A	A	C	9.4464×10^{-7}	C	A	C	6.48×10^{-7}
A	A	T	9.4464×10^{-7}	C	A	T	6.912×10^{-8}
A	A	G	9.4464×10^{-7}	C	A	G	6.912×10^{-8}
A	C	A	4.428×10^{-4}	C	C	A	6.45504×10^{-4}
A	C	C	3.6864×10^{-7}	C	C	C	4.7232×10^{-5}
A	C	T	3.6864×10^{-7}	C	C	T	5.03808×10^{-6}
A	C	G	3.6864×10^{-7}	C	C	G	5.03808×10^{-6}
A	T	A	5.728725×10^{-4}	C	T	A	6.11064×10^{-5}
A	T	C	4.76928×10^{-7}	C	T	C	4.4712×10^{-6}
A	T	T	4.76928×10^{-7}	C	T	T	4.76928×10^{-7}
A	T	G	4.76928×10^{-7}	C	T	G	4.76928×10^{-7}
A	G	A	8.3025×10^{-5}	C	G	A	8.856×10^{-6}
A	G	C	6.912×10^{-8}	C	G	C	6.48×10^{-7}
A	G	T	6.912×10^{-8}	C	G	T	6.912×10^{-8}
A	G	G	6.912×10^{-8}	C	G	G	6.912×10^{-8}

Calcul des toutes les combinaisons (II)

v_1	v_2	v_3	Vraisemblance	v_1	v_2	v_3	Vraisemblance
T	A	A	8.856×10^{-6}	G	A	A	8.856×10^{-6}
T	A	C	6.912×10^{-8}	G	A	C	6.912×10^{-8}
T	A	T	6.48×10^{-7}	G	A	T	6.912×10^{-8}
T	A	G	6.912×10^{-8}	G	A	G	6.48×10^{-7}
T	C	A	4.7232×10^{-5}	G	C	A	4.7232×10^{-5}
T	C	C	3.6864×10^{-7}	G	C	C	3.6864×10^{-7}
T	C	T	3.456×10^{-6}	G	C	T	3.6864×10^{-7}
T	C	G	3.6864×10^{-7}	G	C	G	3.456×10^{-6}
T	T	A	8.351208×10^{-4}	G	T	A	6.11064×10^{-5}
T	T	C	6.518016×10^{-6}	G	T	C	4.76928×10^{-7}
T	T	T	6.11064×10^{-5}	G	T	T	4.76928×10^{-7}
T	T	G	6.518016×10^{-6}	G	T	G	4.4712×10^{-6}
T	G	A	8.856×10^{-6}	G	G	A	1.21032×10^{-4}
T	G	C	6.912×10^{-8}	G	G	C	9.4464×10^{-7}
T	G	T	6.48×10^{-7}	G	G	T	9.4464×10^{-7}
T	G	G	6.912×10^{-8}	G	G	G	8.856×10^{-6}

Sommation de tous les termes : $L^{(i)}(\boldsymbol{\theta}) = 0.004267$


Ensemble des scénarios possibles



$$4^3 = 64 \text{ scénarios pour chaque site } S^i$$

Nombre de termes de la fonction

- Le nombre de termes de la fonction de vraisemblance croît de façon exponentielle avec le nombre d'UTO :
 - Complexité en $O(\ell c^{n-1})$ pour le calcul de $L(\theta)$:
 - Avec $c = 4$ (séquences nucléotidiques) ou $c = 20$ (séquences protéïques).
 - Expression rapidement incalculable.
- Simplifications possibles, du fait que les mêmes valeurs sont recalculées de nombreuses fois :



Algorithme

- Felsenstein (1981) a proposé une méthode dite *d'élagage*, permettant de réduire très fortement la complexité des calculs :
 - Modification de la fonction de vraisemblance en décalant les sommes le plus à droite possible :

$$L^{(i)}(\boldsymbol{\theta}) = \sum_{v_1} \mathbb{P}(v_1) \left[\sum_{v_2} \mathbb{P}(v_2|v_1, b_5) \mathbb{P}(u_1|v_2, b_1) \mathbb{P}(u_2|v_2, b_2) \right] \\ \times \left[\sum_{v_3} \mathbb{P}(v_3|v_1, b_6) \mathbb{P}(u_3|v_3, b_3) \mathbb{P}(u_4|v_3, b_4) \right]$$

- Approche fondée sur le calcul de vraisemblances *conditionnelles* (ou *partielles*) $L_K^{(i)}(k)$ à chaque nœud K de l'arbre :
 - Probabilités d'observer les données aux feuilles du sous-arbre raciné par K , sachant l'état de caractère k à ce nœud.

Vraisemblances partielles d'une feuille

- Dans le cas de séquences nucléotidiques, si K correspond à une feuille quelconque de l'arbre, alors :

- $L_K^{(i)}(k) = 1$ pour l'un des quatre états de caractère et $L_K^{(i)}(k) = 0$ pour les trois autres ($k \in \{A, C, T, G\}$).
- Par exemple, si le nucléotide C est observé à la feuille U_1 , alors le vecteur des vraisemblances partielles correspondant est :

$$\mathbf{L}_{U_1}^{(i)} = \left(L_{U_1}^{(i)}(A), L_{U_1}^{(i)}(C), L_{U_1}^{(i)}(T), L_{U_1}^{(i)}(G) \right) = (0, 1, 0, 0)$$

- Cette représentation permet de prendre en compte les ambiguïtés pouvant exister à certaines positions :
 - Pour une pyrimidine, le vecteur sera égal à $(0, 1, 1, 0)$.
 - Pour un *gap*, il sera égal à $(1, 1, 1, 1)$.

Vraisemblance partielle d'un nœud

- Si K correspond à un nœud, alors :


$$L_K^{(i)}(k) = \sum_l \mathbb{P}(l|k, b_l) L_L^{(i)}(l) \times \sum_m \mathbb{P}(m|k, b_m) L_M^{(i)}(m)$$

avec L et M les deux nœuds fils de K , b_l la longueur de la branche reliant K à L et b_m la longueur de la branche reliant K à M .

- En partant des feuilles, le calcul est réitéré jusqu'à atteindre la racine V_1 de l'arbre.
- À la racine, le vecteur des vraisemblances partielles obtenu permet de déterminer :

$$L^{(i)}(\boldsymbol{\theta}) = \sum_{v_1} \pi_{v_1} L_{V_1}^{(i)}(v_1)$$

Calcul à un nœud



Calcul de la vraisemblance partielle $L_K(A)$

Complexité de l'algorithme

- Aucune influence de la position de la racine sous l'hypothèse de réversibilité du processus markovien.
- Pour un site, c vraisemblances partielles sont déterminées pour chacun des $n - 1$ nœuds de la topologie racinée :
 - Chacun de ces calculs implique le produit de deux termes, chaque terme étant le résultat d'une somme de c produits :
 - Complexité en $O(\ell nc^2)$ pour le calcul de $L(\theta)$:
 - Avec $c = 4$ (séquences nucléotidiques) ou $c = 20$ (séquences protéïques).
- Gains de temps possibles au moyen de certaines astuces :
 - Identification des sites identiques dans l'alignement afin d'éviter le recalcul de la même valeur.

Vraisemblances partielles aux feuilles

- Sachant que $u_1 = \text{C}$, $u_2 = \text{T}$, $u_3 = \text{A}$, $u_4 = \text{A}$, les vecteurs de vraisemblances partielles aux feuilles sont donc tels que :

$$\mathbf{L}_{U_1}^{(i)} = \left(L_{U_1}^{(i)}(\text{A}), L_{U_1}^{(i)}(\text{C}), L_{U_1}^{(i)}(\text{T}), L_{U_1}^{(i)}(\text{G}) \right) = (0, 1, 0, 0)$$


$$\mathbf{L}_{U_2}^{(i)} = \left(L_{U_2}^{(i)}(\text{A}), L_{U_2}^{(i)}(\text{C}), L_{U_2}^{(i)}(\text{T}), L_{U_2}^{(i)}(\text{G}) \right) = (0, 0, 1, 0)$$

$$\mathbf{L}_{U_3}^{(i)} = \left(L_{U_3}^{(i)}(\text{A}), L_{U_3}^{(i)}(\text{C}), L_{U_3}^{(i)}(\text{T}), L_{U_3}^{(i)}(\text{G}) \right) = (1, 0, 0, 0)$$

$$\mathbf{L}_{U_4}^{(i)} = \left(L_{U_4}^{(i)}(\text{A}), L_{U_4}^{(i)}(\text{C}), L_{U_4}^{(i)}(\text{T}), L_{U_4}^{(i)}(\text{G}) \right) = (1, 0, 0, 0)$$

Vraisemblances partielles aux feuilles

- Initialisation du calcul de $L^{(i)}(\theta)$ aux feuilles :



Vraisemblances partielles au nœud V_2

- Calcul de $L_{V_2}^{(i)}(A)$:

$$\begin{aligned}
 L_{V_2}^{(i)}(A) &= \left[p_{AA}(0.5)L_{U_1}^{(i)}(A) + p_{AC}(0.5)L_{U_1}^{(i)}(C) + p_{AT}(0.5)L_{U_1}^{(i)}(T) + p_{AG}(0.5)L_{U_1}^{(i)}(G) \right] \\
 &\quad \times \left[p_{AA}(0.4)L_{U_2}^{(i)}(A) + p_{AC}(0.4)L_{U_2}^{(i)}(C) + p_{AT}(0.4)L_{U_2}^{(i)}(T) + p_{AG}(0.4)L_{U_2}^{(i)}(G) \right] \\
 &= \left[0 + p_{AC}(0.5)L_{U_1}^{(i)}(C) + 0 + 0 \right] \times \left[0 + 0 + p_{AT}(0.4)L_{U_2}^{(i)}(T) + 0 \right] \\
 &= 0.12 \times 1 \times 0.10 \times 1 = 0.012
 \end{aligned}$$

- Calcul de $L_{V_2}^{(i)}(C)$:

$$\begin{aligned}
 L_{V_2}^{(i)}(C) &= \left[p_{CA}(0.5)L_{U_1}^{(i)}(A) + p_{CC}(0.5)L_{U_1}^{(i)}(C) + p_{CT}(0.5)L_{U_1}^{(i)}(T) + p_{CG}(0.5)L_{U_1}^{(i)}(G) \right] \\
 &\quad \times \left[p_{CA}(0.4)L_{U_2}^{(i)}(A) + p_{CC}(0.4)L_{U_2}^{(i)}(C) + p_{CT}(0.4)L_{U_2}^{(i)}(T) + p_{CG}(0.4)L_{U_2}^{(i)}(G) \right] \\
 &= \left[0 + p_{CC}(0.5)L_{U_1}^{(i)}(C) + 0 + 0 \right] \times \left[0 + 0 + p_{CT}(0.4)L_{U_2}^{(i)}(T) + 0 \right] \\
 &= 0.64 \times 1 \times 0.10 \times 1 = 0.064
 \end{aligned}$$

Vraisemblances partielles au nœud V_2

- Calcul de $L_{V_2}^{(i)}(T)$:


$$\begin{aligned}
 L_{V_2}^{(i)}(T) &= \left[p_{TA}(0.5)L_{U_1}^{(i)}(A) + p_{TC}(0.5)L_{U_1}^{(i)}(C) + p_{TT}(0.5)L_{U_1}^{(i)}(T) + p_{TG}(0.5)L_{U_1}^{(i)}(G) \right] \\
 &\quad \times \left[p_{TA}(0.4)L_{U_2}^{(i)}(A) + p_{TC}(0.4)L_{U_2}^{(i)}(C) + p_{TT}(0.4)L_{U_2}^{(i)}(T) + p_{TG}(0.4)L_{U_2}^{(i)}(G) \right] \\
 &= \left[0 + p_{TC}(0.5)L_{U_1}^{(i)}(C) + 0 + 0 \right] \times \left[0 + 0 + p_{TT}(0.4)L_{U_2}^{(i)}(T) + 0 \right] \\
 &= 0.12 \times 1 \times 0.69 \times 1 = 0.0828
 \end{aligned}$$

- Calcul de $L_{V_2}^{(i)}(G)$:

$$\begin{aligned}
 L_{V_2}^{(i)}(G) &= \left[p_{GA}(0.5)L_{U_1}^{(i)}(A) + p_{GC}(0.5)L_{U_1}^{(i)}(C) + p_{GT}(0.5)L_{U_1}^{(i)}(T) + p_{GG}(0.5)L_{U_1}^{(i)}(G) \right] \\
 &\quad \times \left[p_{GA}(0.4)L_{U_2}^{(i)}(A) + p_{GC}(0.4)L_{U_2}^{(i)}(C) + p_{GT}(0.4)L_{U_2}^{(i)}(T) + p_{GG}(0.4)L_{U_2}^{(i)}(G) \right] \\
 &= \left[0 + p_{GC}(0.5)L_{U_1}^{(i)}(C) + 0 + 0 \right] \times \left[0 + 0 + p_{GT}(0.4)L_{U_2}^{(i)}(T) + 0 \right] \\
 &= 0.12 \times 1 \times 0.10 \times 1 = 0.012
 \end{aligned}$$

Vraisemblances partielles au nœud V_2

- Construction du vecteur des vraisemblances partielles $\mathbf{L}_{V_2}^{(i)}$:



Vraisemblances partielles au nœud V_3

- Calcul de $L_{V_3}^{(i)}(A)$:

$$\begin{aligned}
 L_{V_3}^{(i)}(A) &= \left[p_{AA}(0.3)L_{U_3}^{(i)}(A) + p_{AC}(0.3)L_{U_3}^{(i)}(C) + p_{AT}(0.3)L_{U_3}^{(i)}(T) + p_{AG}(0.3)L_{U_3}^{(i)}(G) \right] \\
 &\quad \times \left[p_{AA}(0.2)L_{U_4}^{(i)}(A) + p_{AC}(0.2)L_{U_4}^{(i)}(C) + p_{AT}(0.2)L_{U_4}^{(i)}(T) + p_{AG}(0.2)L_{U_4}^{(i)}(G) \right] \\
 &= \left[p_{AA}(0.3)L_{U_3}^{(i)}(A) + 0 + 0 + 0 \right] \times \left[p_{AA}(0.2)L_{U_4}^{(i)}(A) + 0 + 0 + 0 \right] \\
 &= 0.75 \times 1 \times 0.82 \times 1 = 0.615
 \end{aligned}$$

- Calcul de $L_{V_3}^{(i)}(C)$:

$$\begin{aligned}
 L_{V_3}^{(i)}(C) &= \left[p_{CA}(0.3)L_{U_3}^{(i)}(A) + p_{CC}(0.3)L_{U_3}^{(i)}(C) + p_{CT}(0.3)L_{U_3}^{(i)}(T) + p_{CG}(0.3)L_{U_3}^{(i)}(G) \right] \\
 &\quad \times \left[p_{CA}(0.2)L_{U_4}^{(i)}(A) + p_{CC}(0.2)L_{U_4}^{(i)}(C) + p_{CT}(0.2)L_{U_4}^{(i)}(T) + p_{CG}(0.2)L_{U_4}^{(i)}(G) \right] \\
 &= \left[p_{CA}(0.3)L_{U_3}^{(i)}(A) + 0 + 0 + 0 \right] \times \left[p_{CA}(0.2)L_{U_4}^{(i)}(A) + 0 + 0 + 0 \right] \\
 &= 0.08 \times 1 \times 0.06 \times 1 = 0.048
 \end{aligned}$$

Vraisemblances partielles au nœud V_3

- Calcul de $L_{V_3}^{(i)}(T)$:


$$\begin{aligned}
 L_{V_3}^{(i)}(T) &= \left[p_{TA}(0.3)L_{U_3}^{(i)}(A) + p_{TC}(0.3)L_{U_3}^{(i)}(C) + p_{TT}(0.3)L_{U_3}^{(i)}(T) + p_{TG}(0.3)L_{U_3}^{(i)}(G) \right] \\
 &\quad \times \left[p_{TA}(0.2)L_{U_4}^{(i)}(A) + p_{TC}(0.2)L_{U_4}^{(i)}(C) + p_{TT}(0.2)L_{U_4}^{(i)}(T) + p_{TG}(0.2)L_{U_4}^{(i)}(G) \right] \\
 &= \left[p_{TA}(0.3)L_{U_3}^{(i)} + 0 + 0 + 0 \right] \times \left[p_{TA}(0.2)L_{U_4}^{(i)} + 0 + 0 + 0 \right] \\
 &= 0.08 \times 1 \times 0.06 \times 1 = 0.048
 \end{aligned}$$

- Calcul de $L_{V_3}^{(i)}(G)$:

$$\begin{aligned}
 L_{V_3}^{(i)}(G) &= \left[p_{GA}(0.3)L_{U_3}^{(i)}(A) + p_{GC}(0.3)L_{U_3}^{(i)}(C) + p_{GT}(0.3)L_{U_3}^{(i)}(T) + p_{GG}(0.3)L_{U_3}^{(i)}(G) \right] \\
 &\quad \times \left[p_{GA}(0.2)L_{U_4}^{(i)}(A) + p_{GC}(0.2)L_{U_4}^{(i)}(C) + p_{GT}(0.2)L_{U_4}^{(i)}(T) + p_{GG}(0.2)L_{U_4}^{(i)}(G) \right] \\
 &= \left[[p_{GA}(0.3)L_{U_3}^{(i)} + 0 + 0 + 0] \right] \times \left[[p_{GA}(0.2)L_{U_4}^{(i)} + 0 + 0 + 0] \right] \\
 &= 0.08 \times 1 \times 0.06 \times 1 = 0.048
 \end{aligned}$$

Vraisemblances partielles au nœud V_3

- Construction du vecteur des vraisemblances partielles $\mathbf{L}_{V_3}^{(i)}$:



Vraisemblances partielles à la racine V_1

- Calcul de $L_{V_1}^{(i)}(A)$:

$$\begin{aligned}
 L_{V_1}^{(i)}(A) &= \left[p_{AA}(0.2)L_{V_2}^{(i)}(A) + p_{AC}(0.2)L_{V_2}^{(i)}(C) + p_{AT}(0.2)L_{V_2}^{(i)}(T) + p_{AG}(0.2)L_{V_2}^{(i)}(G) \right] \\
 &\quad \times \left[p_{AA}(0.3)L_{V_3}^{(i)}(A) + p_{AC}(0.3)L_{V_3}^{(i)}(C) + p_{AT}(0.3)L_{V_3}^{(i)}(T) + p_{AG}(0.3)L_{V_3}^{(i)}(G) \right] \\
 &= [0.82 \times 0.012 + 0.06 \times 0.064 + 0.06 \times 0.0828 + 0.06 \times 0.012] \\
 &\quad \times [0.75 \times 0.615 + 0.08 \times 0.0048 + 0.08 \times 0.0048 + 0.08 \times 0.0048] \\
 &= 0.008956
 \end{aligned}$$

- Calcul de $L_{V_1}^{(i)}(C)$:

$$\begin{aligned}
 L_{V_1}^{(i)}(C) &= \left[p_{CA}(0.2)L_{V_2}^{(i)}(A) + p_{CC}(0.2)L_{V_2}^{(i)}(C) + p_{CT}(0.2)L_{V_2}^{(i)}(T) + p_{CG}(0.2)L_{V_2}^{(i)}(G) \right] \\
 &\quad \times \left[p_{CA}(0.3)L_{V_3}^{(i)}(A) + p_{CC}(0.3)L_{V_3}^{(i)}(C) + p_{CT}(0.3)L_{V_3}^{(i)}(T) + p_{CG}(0.3)L_{V_3}^{(i)}(G) \right] \\
 &= [0.06 \times 0.012 + 0.82 \times 0.064 + 0.06 \times 0.0828 + 0.06 \times 0.012] \\
 &\quad \times [0.08 \times 0.615 + 0.75 \times 0.0048 + 0.08 \times 0.0048 + 0.08 \times 0.0048] \\
 &= 0.003155
 \end{aligned}$$

Vraisemblances partielles à la racine V_1

- Calcul de $L_{V_1}^{(i)}(T)$:


$$\begin{aligned}
 L_{V_1}^{(i)}(T) &= \left[p_{TA}(0.2)L_{V_2}^{(i)}(A) + p_{TC}(0.2)L_{V_2}^{(i)}(C) + p_{TT}(0.2)L_{V_2}^{(i)}(T) + p_{TG}(0.2)L_{V_2}^{(i)}(G) \right] \\
 &\quad \times \left[p_{TA}(0.3)L_{V_3}^{(i)}(A) + p_{TC}(0.3)L_{V_3}^{(i)}(C) + p_{TT}(0.3)L_{V_3}^{(i)}(T) + p_{TG}(0.3)L_{V_3}^{(i)}(G) \right] \\
 &= [0.06 \times 0.012 + 0.06 \times 0.064 + 0.82 \times 0.0828 + 0.06 \times 0.012] \\
 &\quad \times [0.08 \times 0.615 + 0.08 \times 0.0048 + 0.75 \times 0.0048 + 0.08 \times 0.0048] \\
 &= 0.00392
 \end{aligned}$$

- Calcul de $L_{V_1}^{(i)}(G)$:

$$\begin{aligned}
 L_{V_1}^{(i)}(G) &= \left[p_{GA}(0.2)L_{V_2}^{(i)}(A) + p_{GC}(0.2)L_{V_2}^{(i)}(C) + p_{GT}(0.2)L_{V_2}^{(i)}(T) + p_{GG}(0.2)L_{V_2}^{(i)}(G) \right] \\
 &\quad \times \left[p_{GA}(0.3)L_{V_3}^{(i)}(A) + p_{GC}(0.3)L_{V_3}^{(i)}(C) + p_{GT}(0.3)L_{V_3}^{(i)}(T) + p_{GG}(0.3)L_{V_3}^{(i)}(G) \right] \\
 &= [0.06 \times 0.012 + 0.06 \times 0.064 + 0.06 \times 0.0828 + 0.82 \times 0.012] \\
 &\quad \times [0.08 \times 0.615 + 0.08 \times 0.0048 + 0.08 \times 0.0048 + 0.75 \times 0.0048] \\
 &= 0.001038
 \end{aligned}$$

Vraisemblances partielles à la racine V_1

- Construction du vecteur des vraisemblances partielles $\mathbf{L}_{V_1}^{(i)}$:



Calcul de la vraisemblance au site $S^{(i)}$

- À partir du vecteur des vraisemblances partielles à la racine, on en déduit la valeur de $L^{(i)}(\boldsymbol{\theta})$:

$$\begin{aligned} L^{(i)}(\boldsymbol{\theta}) &= \sum_{v_1} \pi_{v_1} L_{V_1}^{(i)}(v_1) \\ &= \pi_A L_{V_1}^{(i)}(A) + \pi_C L_{V_1}^{(i)}(C) + \pi_T L_{V_1}^{(i)}(T) + \pi_G L_{V_1}^{(i)}(G) \\ &= \frac{1}{4}(0.008956 + 0.003155 + 0.00392 + 0.001038) \\ &= 0.004267 \end{aligned}$$

Soit, sous forme logarithmique :

$$\ln L^{(i)}(\boldsymbol{\theta}) = \ln(0.004267) \simeq -5.4568$$

Procédure générale

- En théorie, nécessité d'explorer l'ensemble des topologies et des combinaisons de longueurs de branches :
 - Impossible du fait de la croissance très rapide du nombre de topologies et du caractère continu des longueurs de branches.
- En pratique :
 - Exploration de l'espace des topologies via les heuristiques vues précédemment (NNI, SPR, TBR).
 - Optimisation branche par branche pour déterminer les longueurs maximisant la vraisemblance.
- Pour une topologie et un ensemble de longueurs de branches données :
 - Calcul des valeurs de vraisemblances par site $L^{(i)}(\boldsymbol{\theta})$:
 - Calcul de la vraisemblance globale $\ln L(\boldsymbol{\theta}) = \sum_i \ln L^{(i)}(\boldsymbol{\theta})$.

Avantages et limitations

- Méthode la mieux justifiée du point de vue théorique (si vous êtes fréquentiste).
- Donne de meilleurs résultats que la parcimonie ou les méthodes de distances dans la plupart des cas.
- Consistante si l'on utilise le bon modèle.
- Coûteuse en temps de calcul :
 - *Bootstrap* standard difficile d'utilisation.
- Risques de surparamétrisation avec les modèles trop complexes :
 - Tests pour sélectionner le modèle permettant d'obtenir le meilleur compromis vraisemblance/nombre de paramètres.

Performances en simulation

- Génération aléatoire de 5000 arbres à 40 UTO :
 - Variation des longueurs de branches.
- Construction des séquences d'ADN correspondantes :
 - Modèle de Kimura à deux paramètres.
- Qualité des reconstructions obtenues :
 - Distance topologique entre l'arbre vrai (connu) et l'arbre reconstruit.

