

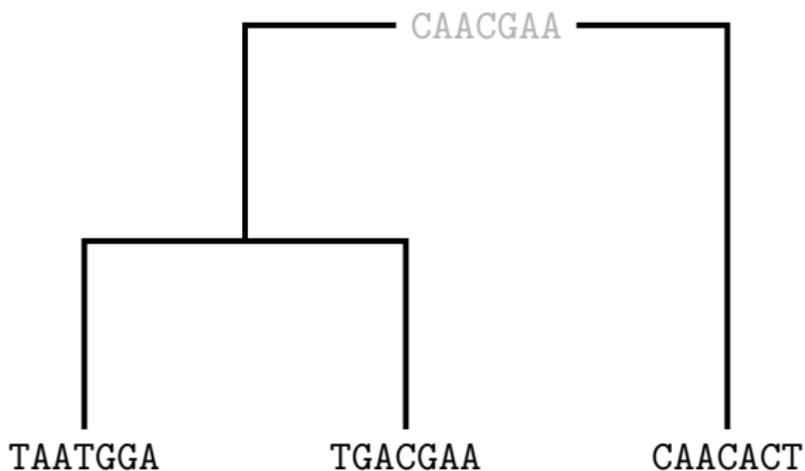
Utilisation de méthodes particulières pour l'inférence de modèles d'évolution avec dépendance au contexte

Alexis Huet

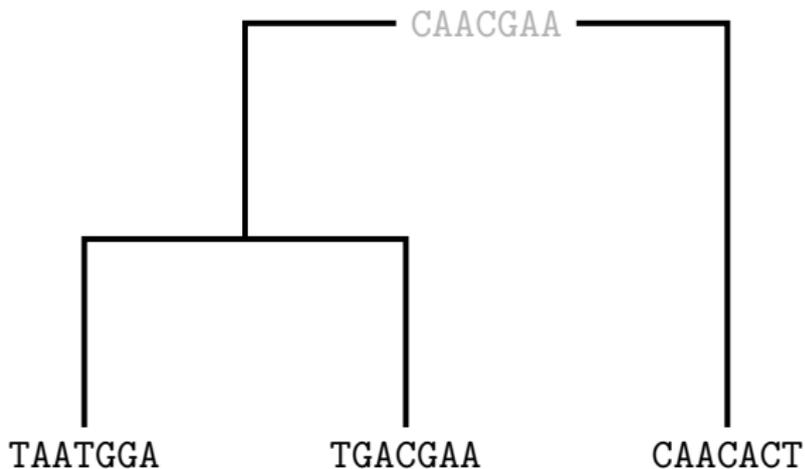
28 août 2014

- 1 Introduction
- 2 Encodages et structures markoviennes
- 3 Méthodes numériques
- 4 Applications

- 1 Introduction
- 2 Encodages et structures markoviennes
- 3 Méthodes numériques
- 4 Applications



→ Problématique : étant donné un modèle d'évolution et une loi pour la séquence ancestrale, calculer la vraisemblance d'un alignement de séquences actuelles.



→ Problématique : étant donné un modèle d'évolution et une loi pour la séquence ancestrale, calculer la vraisemblance d'un alignement de séquences actuelles.

Modèles à sites indépendants

- chaque site évolue de façon indépendante selon la même loi,
- chaîne de Markov en temps continu sur $\{A, C, G, T\}$,

Exemple : générateur pour les modèles RN95 (Rzhetsky / Nei)

$$Q = \begin{matrix} & A & C & G & T \\ \begin{matrix} A \\ C \\ G \\ T \end{matrix} & \begin{pmatrix} \cdot & v_C & w_G & v_T \\ v_A & \cdot & v_G & w_T \\ w_A & v_C & \cdot & v_T \\ v_A & w_C & v_G & \cdot \end{pmatrix} \end{matrix}$$

Deux types de bases : $A, G = \text{purines} = R$ et $C, T = \text{pyrimidines} = Y$.

Transversion : substitution $R \rightarrow Y$ ou $Y \rightarrow R$.

Transition : substitution $R \rightarrow R$ ou $Y \rightarrow Y$.

Modèles à sites indépendants

- chaque site évolue de façon indépendante selon la même loi,
- chaîne de Markov en temps continu sur $\{A, C, G, T\}$,

Exemple : générateur pour les modèles RN95 (Rzhetsky / Nei)

$$Q = \begin{matrix} & A & C & G & T \\ \begin{matrix} A \\ C \\ G \\ T \end{matrix} & \begin{pmatrix} \cdot & v_C & w_G & v_T \\ v_A & \cdot & v_G & w_T \\ w_A & v_C & \cdot & v_T \\ v_A & w_C & v_G & \cdot \end{pmatrix} \end{matrix}$$

Deux types de bases : $A, G = \text{purines} = R$ et $C, T = \text{pyrimidines} = Y$.

Transversion : substitution $R \rightarrow Y$ ou $Y \rightarrow R$.

Transition : substitution $R \rightarrow R$ ou $Y \rightarrow Y$.

Modèles à sites indépendants

- chaque site évolue de façon indépendante selon la même loi,
- chaîne de Markov en temps continu sur $\{A, C, G, T\}$,

Exemple : générateur pour les modèles RN95 (Rzhetsky / Nei)

$$Q = \begin{matrix} & A & C & G & T \\ \begin{matrix} A \\ C \\ G \\ T \end{matrix} & \begin{pmatrix} \cdot & v_C & w_G & v_T \\ v_A & \cdot & v_G & w_T \\ w_A & v_C & \cdot & v_T \\ v_A & w_C & v_G & \cdot \end{pmatrix} \end{matrix}$$

Deux types de bases : $A, G = \text{purines} = R$ et $C, T = \text{pyrimidines} = Y$.

Transversion : substitution $R \rightarrow Y$ ou $Y \rightarrow R$.

Transition : substitution $R \rightarrow R$ ou $Y \rightarrow Y$.

Modèles à sites indépendants

- chaque site évolue de façon indépendante selon la même loi,
- chaîne de Markov en temps continu sur $\{A, C, G, T\}$,

Exemple : générateur pour les modèles RN95 (Rzhetsky / Nei)

$$Q = \begin{matrix} & \begin{matrix} A & C & G & T \end{matrix} \\ \begin{matrix} A \\ C \\ G \\ T \end{matrix} & \begin{pmatrix} \cdot & v_C & w_G & v_T \\ v_A & \cdot & v_G & w_T \\ w_A & v_C & \cdot & v_T \\ v_A & w_C & v_G & \cdot \end{pmatrix} \end{matrix}$$

Deux types de bases : $A, G = \text{purines} = R$ et $C, T = \text{pyrimidines} = Y$.

Transversion : substitution $R \rightarrow Y$ ou $Y \rightarrow R$.

Transition : substitution $R \rightarrow R$ ou $Y \rightarrow Y$.

Modèles à sites indépendants

- chaque site évolue de façon indépendante selon la même loi,
- chaîne de Markov en temps continu sur $\{A, C, G, T\}$,

Exemple : générateur pour les modèles RN95 (Rzhetsky / Nei)

$$Q = \begin{matrix} & A & C & G & T \\ \begin{matrix} A \\ C \\ G \\ T \end{matrix} & \begin{pmatrix} \cdot & v_C & w_G & v_T \\ v_A & \cdot & v_G & w_T \\ w_A & v_C & \cdot & v_T \\ v_A & w_C & v_G & \cdot \end{pmatrix} \end{matrix}$$

Deux types de bases : $A, G = \text{purines} = R$ et $C, T = \text{pyrimidines} = Y$.

Transversion : substitution $R \rightarrow Y$ ou $Y \rightarrow R$.

Transition : substitution $R \rightarrow R$ ou $Y \rightarrow Y$.

Biochimiquement (par exemple chez les mammifères) :

- Taux $C \rightarrow T$ accru si le nucléotide à droite est G ,
- Taux $G \rightarrow A$ accru si le nucléotide à gauche est C .

→ Nécessité de définir des taux de substitution prenant en compte le contexte local.

Biochimiquement (par exemple chez les mammifères) :

- Taux $C \rightarrow T$ accru si le nucléotide à droite est G ,
- Taux $G \rightarrow A$ accru si le nucléotide à gauche est C .

→ Nécessité de définir des taux de substitution prenant en compte le contexte local.

$$P \left(\begin{array}{ll} \dots \text{ACGTA} \dots & \text{temps } t \\ \downarrow & \\ \dots \text{ACATA} \dots & \text{temps } t+dt \end{array} \right) = (w_A + r_{CG \rightarrow CA}) dt + o(dt),$$

$$P \left(\begin{array}{ll} \dots \text{AGGTA} \dots & \text{temps } t \\ \downarrow & \\ \dots \text{AGATA} \dots & \text{temps } t+dt \end{array} \right) = w_A dt + o(dt).$$

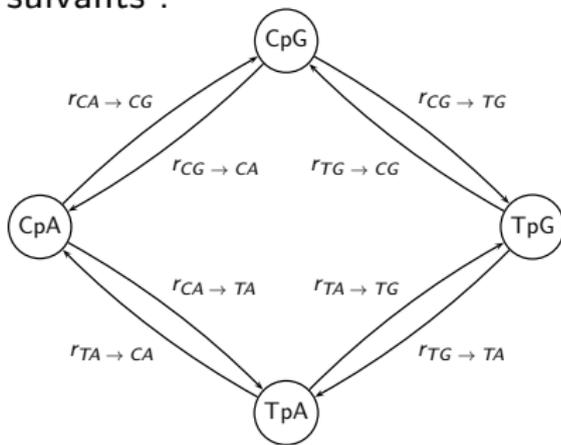
$$P \left(\begin{array}{cc} \dots \text{ACGTA} \dots & \text{temps } t \\ \downarrow & \\ \dots \text{ACATA} \dots & \text{temps } t+dt \end{array} \right) = (w_A + r_{CG \rightarrow CA})dt + o(dt),$$

$$P \left(\begin{array}{cc} \dots \text{AGGTA} \dots & \text{temps } t \\ \downarrow & \\ \dots \text{AGATA} \dots & \text{temps } t+dt \end{array} \right) = w_A dt + o(dt).$$

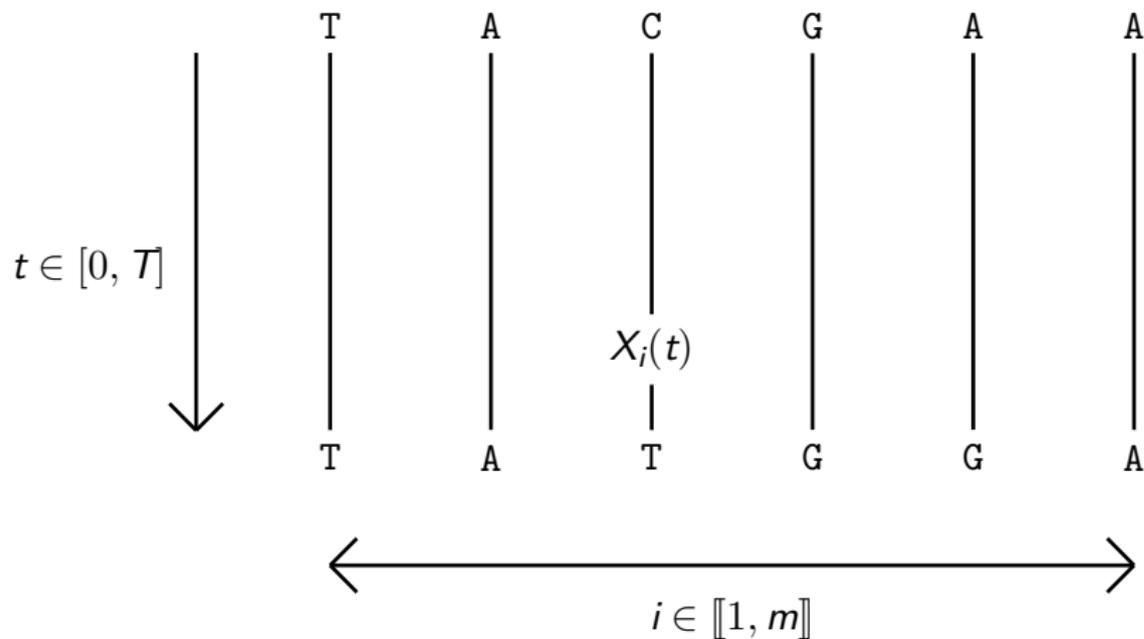
- modèle RN95 de matrice de sauts

$$\begin{matrix} & A & C & G & T \\ \begin{matrix} A \\ C \\ G \\ T \end{matrix} & \begin{pmatrix} \cdot & v_C & w_G & v_T \\ v_A & \cdot & v_G & w_T \\ w_A & v_C & \cdot & v_T \\ v_A & w_C & v_G & \cdot \end{pmatrix} \end{matrix},$$

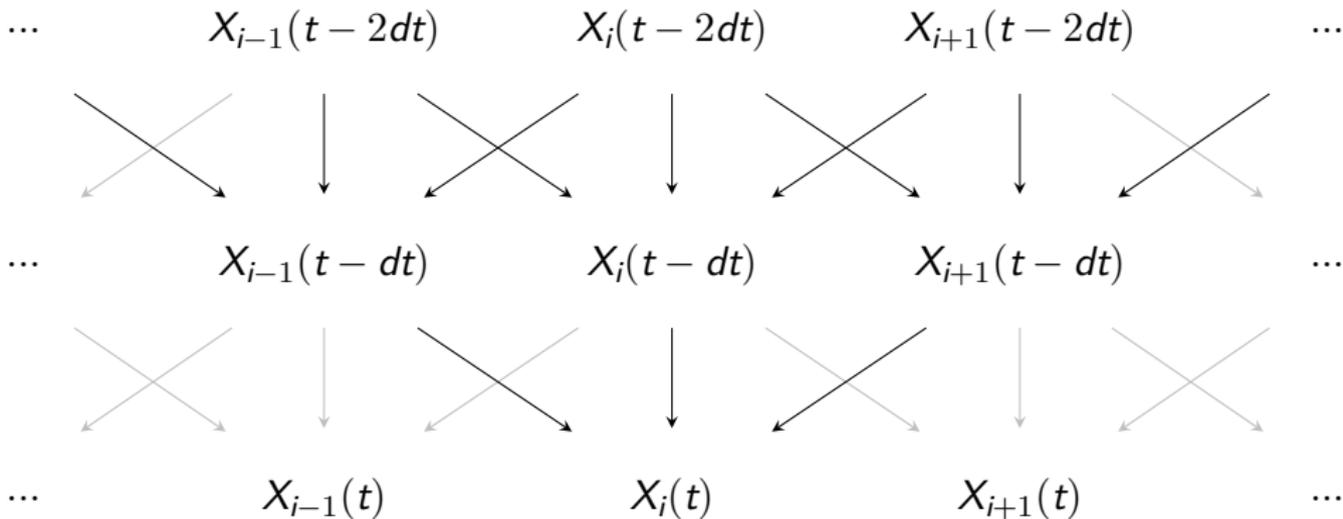
- renforcements suivants :



Évolution de séquence à séquence



Chaînes de dépendance



- 1 Introduction
- 2 Encodages et structures markoviennes**
- 3 Méthodes numériques
- 4 Applications

Encodages de nucléotides :

- $\pi(A) := R; \pi(G) := R; \pi(C) := Y; \pi(T) := Y,$
- $\rho(A) := R; \rho(G) := R; \rho(C) := C; \rho(T) := T,$
- $\eta(A) := A; \eta(G) := G; \eta(C) := Y; \eta(T) := Y.$

Φ -encodage d'une séquence de nucléotides :

$$\Phi(x_1(t), \dots, x_m(t)) = (\rho(x_1(t)), x_2(t), \dots, x_{m-1}(t), \eta(x_m(t))).$$

Encodages de nucléotides :

- $\pi(A) := R; \pi(G) := R; \pi(C) := Y; \pi(T) := Y,$
- $\rho(A) := R; \rho(G) := R; \rho(C) := C; \rho(T) := T,$
- $\eta(A) := A; \eta(G) := G; \eta(C) := Y; \eta(T) := Y.$

Φ -encodage d'une séquence de nucléotides :

$$\Phi(x_1(t), \dots, x_m(t)) = (\rho(x_1(t)), x_2(t), \dots, x_{m-1}(t), \eta(x_m(t))).$$

Évolution Φ -encodée d'une séquence

$$(\rho(X_1)(t), X_2(t), \dots, X_{m-1}(t), \eta(X_m)(t))_{t \in [0, T]}$$

issue d'un modèle RN95+YpR :

Théorème [BGP08]

Une séquence Φ -encodée évolue dans le temps selon une chaîne de Markov explicite.

- Calcul de la vraisemblance pour des séquences Φ -encodées de longueurs $m = 2, 3, 4, 5$.
- Calcul de la vraisemblance pour des observations générales ?
 - Vraisemblances composites.
 - Approximation de type Monte Carlo.

- Calcul de la vraisemblance pour des séquences Φ -encodées de longueurs $m = 2, 3, 4, 5$.
- Calcul de la vraisemblance pour des observations générales?
 - Vraisemblances composites.
 - Approximation de type Monte Carlo.

Structure de chaîne de Markov explicite

Évolution Φ -encodée d'une séquence issue d'un modèle RN95+YpR :

$$\Phi(X) = (\rho(X_1)(t), X_2(t), \dots, X_{m-1}(t), \eta(X_m)(t))_{t \in [0, T]}$$

Plutôt que de regarder l'évolution site par site, on regarde l'évolution de chaque dinucléotide Φ -encodé avec chevauchement.

Définition

$$\rho_i = (\rho(X_i(t)))_t \text{ et } \eta_i = (\eta(X_i(t)))_t,$$

$$Z_i = (\rho_i, \eta_{i+1}).$$

Alphabet associé : $\{C, T, R\} \times \{A, G, Y\}$.

$$\begin{aligned}\Phi(X) &= (\rho_1, X_2, \dots, X_{m-1}, \eta_m) \\ &\equiv (\rho_1, \eta_2, \rho_2, \dots, \eta_{m-1}, \rho_{m-1}, \eta_m) \\ &= (Z_1, \dots, Z_{m-1}).\end{aligned}$$

Structure de chaîne de Markov explicite

Évolution Φ -encodée d'une séquence issue d'un modèle RN95+YpR :

$$\Phi(X) = (\rho(X_1)(t), X_2(t), \dots, X_{m-1}(t), \eta(X_m)(t))_{t \in [0, T]}$$

Plutôt que de regarder l'évolution site par site, on regarde l'évolution de chaque dinucléotide Φ -encodé avec chevauchement.

Définition

$$\rho_i = (\rho(X_i(t)))_t \text{ et } \eta_i = (\eta(X_i(t)))_t,$$

$$Z_i = (\rho_i, \eta_{i+1}).$$

Alphabet associé : $\{C, T, R\} \times \{A, G, Y\}$.

$$\begin{aligned}\Phi(X) &= (\rho_1, X_2, \dots, X_{m-1}, \eta_m) \\ &\equiv (\rho_1, \eta_2, \rho_2, \dots, \eta_{m-1}, \rho_{m-1}, \eta_m) \\ &= (Z_1, \dots, Z_{m-1}).\end{aligned}$$

Théorème (thèse H.)

On suppose la racine fixée. Alors $(Z_i)_i$ est une chaîne de Markov.

Théorème (thèse H.)

Conditionnellement à $Z_{1:i-1}$ et $Z_i([0, t])$, la description de la loi de transition de Z_i à l'instant t est explicite.

- 1 Si $\pi_i(t^-) = \pi_i(t) \in \{R, Y\}$, matrice de taux de sauts W_R ou W_Y .
- 2 Si $\pi_i(t^-) \neq \pi_i(t)$, substitution obligatoire régie par des matrices instantanées $U_{Y \rightarrow R}$ et $U_{R \rightarrow Y}$.

Démonstration basée sur les structures spécifiques de la classe $RN95+YpR$.

Théorème (thèse H.)

On suppose la racine fixée. Alors $(Z_i)_i$ est une chaîne de Markov.

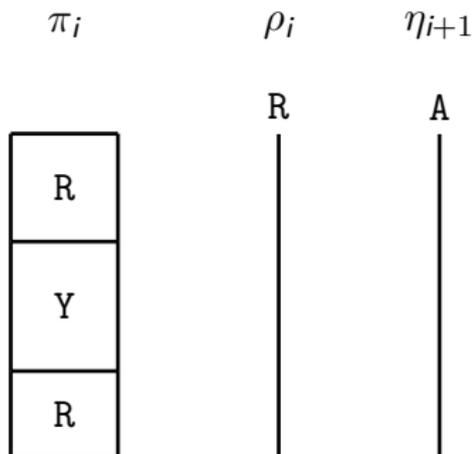
Théorème (thèse H.)

Conditionnellement à $Z_{1:i-1}$ et $Z_i([0, t])$, la description de la loi de transition de Z_i à l'instant t est explicite.

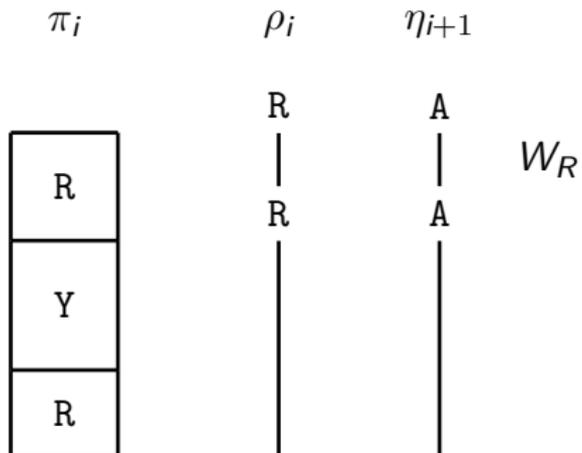
- 1 Si $\pi_i(t^-) = \pi_i(t) \in \{R, Y\}$, matrice de taux de sauts W_R ou W_Y .
- 2 Si $\pi_i(t^-) \neq \pi_i(t)$, substitution obligatoire régie par des matrices instantanées $U_{Y \rightarrow R}$ et $U_{R \rightarrow Y}$.

Démonstration basée sur les structures spécifiques de la classe $RN95+YpR$.

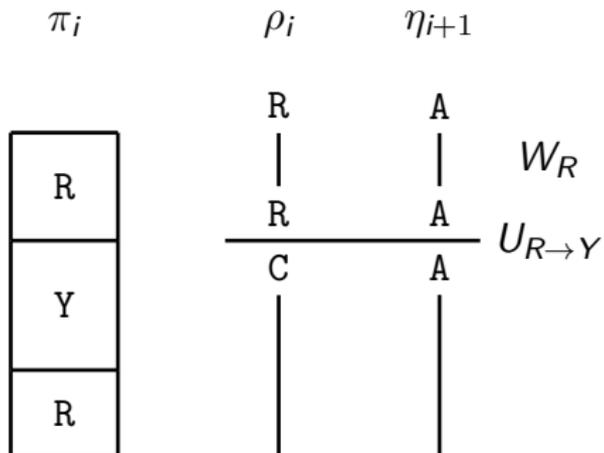
Exemple



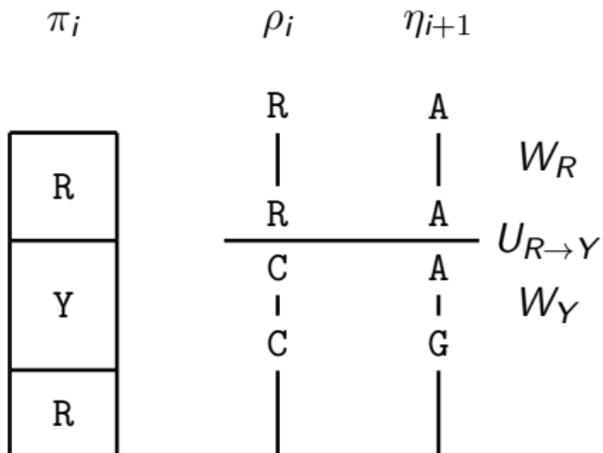
Exemple



Exemple



Exemple



Exemple

| π_i | ρ_i | η_{i+1} | |
|-------------|----------|--------------|-----------------------|
| R Y R | R | A | W_R |
| | R | A | $U_{R \rightarrow Y}$ |
| | C | A | W_Y |
| | | | |
| | C | G | $U_{Y \rightarrow R}$ |
| | R | G | |
| | | | |

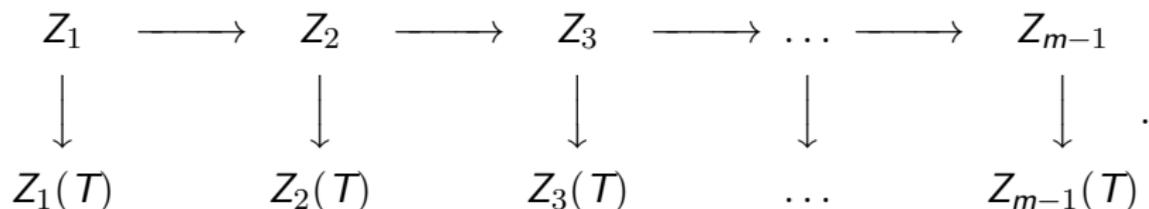
Exemple

| π_i | ρ_i | η_{i+1} | |
|-------------|----------|-----------------------|-----------------------|
| R Y R | R | A | W_R |
| | | | |
| | R | A | $U_{R \rightarrow Y}$ |
| | <hr/> | | |
| | C | A | W_Y |
| | | | |
| C | G | $U_{Y \rightarrow R}$ | |
| <hr/> | | | |
| R | G | W_R | |
| | | | |
| R | G | | |

- 1 Introduction
- 2 Encodages et structures markoviennes
- 3 Méthodes numériques**
- 4 Applications

Comment approcher la vraisemblance ?

Pour l'évolution markovienne de l'historique $(Z_i)_i$, on a :



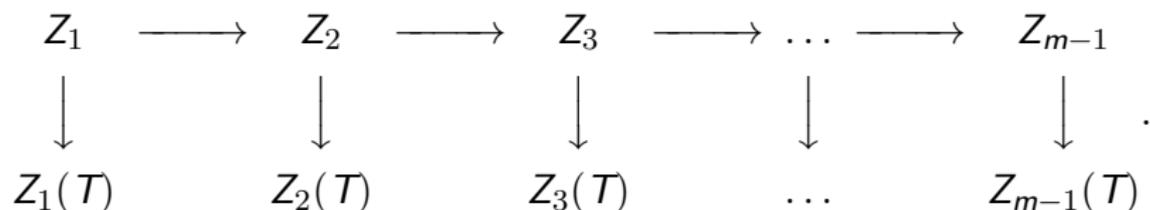
- Connaissance de $z_{1:m-1}(T)$ mais pas de $z_{1:m-1}$.
- But : calculer la vraisemblance des observations $z_{1:m-1}(T)$ par produit :

$$p(z_{1:m-1}(T)) = \prod_{i=0}^{m-2} p(z_{i+1}(T) | z_{1:i}(T)).$$

- Méthode : filtre particulaire auxiliaire (APF).

Comment approcher la vraisemblance ?

Pour l'évolution markovienne de l'historique $(Z_i)_i$, on a :



- Connaissance de $z_{1:m-1}(T)$ mais pas de $z_{1:m-1}$.
- But : calculer la vraisemblance des observations $z_{1:m-1}(T)$ par produit :

$$p(z_{1:m-1}(T)) = \prod_{i=0}^{m-2} p(z_{i+1}(T) | z_{1:i}(T)).$$

- Méthode : filtre particulaire auxiliaire (APF).

Idée de l'algorithme : approcher les lois de $z_{1:i}$ conditionnellement à $z_{1:i}(T)$ par la loi empirique associée à un nuage de particules.

- Site $i-1$:

Nuage $(z_{1:i-1}^{(j)})_j$ approche loi $(z_{1:i-1} | z_{1:i-1}(T))$.

- Pour toute particule $j \in 1 : N$, conditionnellement à $z_{1:i-1}^{(j)}$, simuler selon $p(dz_i | z_{1:i-1}, z_i(T))$:

$$z_i^{(1)}, \dots, z_i^{(N)}.$$

- Site i : Nuage $(z_{1:i}^{(j)})_j$ approche loi $(z_{1:i} | z_{1:i}(T))$.

$$\text{Puis : } p(z_{i+1}(T) | z_{1:i}(T)) = \int p(z_{i+1}(T) | z_i) p(dz_{1:i} | z_{1:i}(T)).$$

Littérature : théorèmes de convergences et de normalité asymptotique lorsque le nombre de particules N tend vers l'infini.

Idée de l'algorithme : approcher les lois de $z_{1:i}$ conditionnellement à $z_{1:i}(T)$ par la loi empirique associée à un nuage de particules.

- Site $i-1$:

Nuage $(z_{1:i-1}^{(j)})_j$ approche loi($z_{1:i-1}|z_{1:i-1}(T)$).

- Pour toute particule $j \in 1 : N$, conditionnellement à $z_{1:i-1}^{(j)}$, simuler selon $p(dz_i|z_{i-1}, z_i(T))$:

$$z_i^{(1)}, \dots, z_i^{(N)}.$$

- Site i : Nuage $(z_{1:i}^{(j)})_j$ approche loi($z_{1:i}|z_{1:i}(T)$).

$$\text{Puis : } p(z_{i+1}(T)|z_{1:i}(T)) = \int p(z_{i+1}(T)|z_i)p(dz_{1:i}|z_{1:i}(T)).$$

Littérature : théorèmes de convergences et de normalité asymptotique lorsque le nombre de particules N tend vers l'infini.

Idée de l'algorithme : approcher les lois de $z_{1:i}$ conditionnellement à $z_{1:i}(T)$ par la loi empirique associée à un nuage de particules.

- Site $i-1$:

Nuage $(z_{1:i-1}^{(j)})_j$ approche loi($z_{1:i-1}|z_{1:i-1}(T)$).

- Pour toute particule $j \in 1 : N$, conditionnellement à $z_{i-1}^{(j)}$, simuler selon $p(dz_i|z_{i-1}, z_i(T))$:

$$z_i^{(1)}, \dots, z_i^{(N)}.$$

- Site i :

Nuage $(z_{1:i}^{(j)})_j$ approche loi($z_{1:i}|z_{1:i}(T)$).

$$\text{Puis : } p(z_{i+1}(T)|z_{1:i}(T)) = \int p(z_{i+1}(T)|z_i)p(dz_{1:i}|z_{1:i}(T)).$$

Littérature : théorèmes de convergences et de normalité asymptotique lorsque le nombre de particules N tend vers l'infini.

Idée de l'algorithme : approcher les lois de $z_{1:i}$ conditionnellement à $z_{1:i}(T)$ par la loi empirique associée à un nuage de particules.

- Site $i-1$:

Nuage $(z_{1:i-1}^{(j)})_j$ approche loi $(z_{1:i-1} | z_{1:i-1}(T))$.

- Pour toute particule $j \in 1 : N$, conditionnellement à $z_{i-1}^{(j)}$, simuler selon $p(dz_i | z_{i-1}, z_i(T))$:

$$z_i^{(1)}, \dots, z_i^{(N)}.$$

- Site i : Nuage $(z_{1:i}^{(j)})_j$ approche loi $(z_{1:i} | z_{1:i}(T))$.

$$\text{Puis : } p(z_{i+1}(T) | z_{1:i}(T)) = \int p(z_{i+1}(T) | z_i) p(dz_{1:i} | z_{1:i}(T)).$$

Littérature : théorèmes de convergences et de normalité asymptotique lorsque le nombre de particules, N tend vers l'infini.

Idée de l'algorithme : approcher les lois de $z_{1:i}$ conditionnellement à $z_{1:i}(T)$ par la loi empirique associée à un nuage de particules.

- Site $i-1$:

Nuage $(z_{1:i-1}^{(j)})_j$ approche loi($z_{1:i-1} | z_{1:i-1}(T)$).

- Pour toute particule $j \in 1 : N$, conditionnellement à $z_{i-1}^{(j)}$, simuler selon $p(dz_i | z_{i-1}, z_i(T))$:

$$z_i^{(1)}, \dots, z_i^{(N)}.$$

- Site i : Nuage $(z_{1:i}^{(j)})_j$ approche loi($z_{1:i} | z_{1:i}(T)$).

$$\text{Puis : } p(z_{i+1}(T) | z_{1:i}(T)) = \int p(z_{i+1}(T) | z_i) p(dz_{1:i} | z_{1:i}(T)).$$

Littérature : théorèmes de convergences et de normalité asymptotique lorsque le nombre de particules N tend vers l'infini.

Entrées (sous forme de fichier texte) :

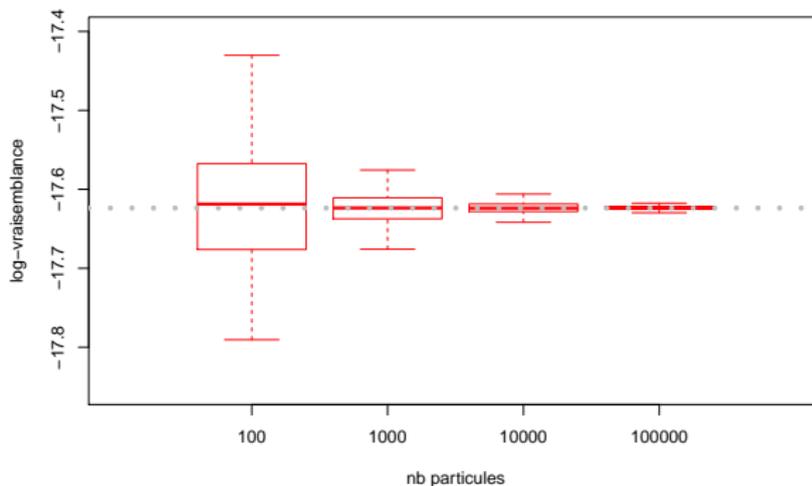
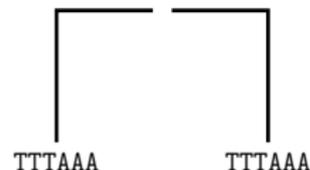
- le jeu de séquences, arbre, paramètres du modèle
- la loi à la racine (modèle markovien),
- N le nombre de particules utilisées.

Sortie :

- la log-vraisemblance approchée du jeu de séquences observé.

Exemple

- Modèle d'évolution $v_A = 7.1$, ... $r_{TG \rightarrow CG} = 7.7$.
- Arbre constitué de deux arêtes de longueur 1.
- Loi à la racine loi stationnaire du modèle.
- Séquences observées : $(TTTAAA, TTTAAA)$.



- 1 Introduction
- 2 Encodages et structures markoviennes
- 3 Méthodes numériques
- 4 Applications**

Algorithme pratique

- 1 Estimer le maximum de vraisemblance des observations par la méthode des triplets encodés (bppm1 de Bio++ [BG12, DB08, DGB⁺06]).
- 2 Calculer une approximation particulière de la vraisemblance au maximum de vraisemblance.

Exemple d'application : on dispose d'un alignement de trois séquences biologiques de 2215 nucléotides.

| modèle | T92 | T92+CpGs | GTR |
|----------------------|-------|----------|-------|
| nombre de paramètres | 2 | 3 | 8 |
| log-vrais. | -3432 | ? | -3428 |
| AIC | 6868 | ? | 6872 |
| BIC | 6879 | ? | 6918 |

→ Algorithme pratique appliqué pour le modèle T92+CpGs.

Exemple d'application : on dispose d'un alignement de trois séquences biologiques de 2215 nucléotides.

| modèle | T92 | T92+CpGs | GTR |
|----------------------|-------|----------|-------|
| nombre de paramètres | 2 | 3 | 8 |
| log-vrais. | -3432 | -3389 | -3428 |
| AIC | 6868 | 6784 | 6872 |
| BIC | 6879 | 6801 | 6918 |

→ Algorithme pratique appliqué pour le modèle T92+CpGs.

- Comparaison des approximations particulières avec d'autres approximations composites
- Inférence d'un nucléotide à la racine
- Comparaison des estimateurs du maximum de vraisemblance

- Étude d'un modèle d'évolution de l'ADN : RN95+YpR.
- Approximation consistante par approximations particulières quand le nombre de particules tend vers l'infini de la vraisemblance pour des séquences issues de ces modèles.
- Mise en œuvre de cette approche.
- Applications.

Merci de votre attention !

-  Jean Bérard and Laurent Guéguen, *Accurate estimation of substitution rates with neighbor-dependent models in a phylogenetic context*, *Systematic Biology* **61** (2012), no. 3, 510–521.
-  Jean Bérard, Jean-Baptiste Gouéré, and Didier Piau, *Solvable models of neighbor-dependent substitution processes*, *Mathematical Biosciences* **211** (2008), no. 1, 56–88. MR 2392414 (2009h :92032)
-  Julien Dutheil and Bastien Boussau, *Non-homogeneous models of sequence evolution in the Bio++ suite of libraries and programs*, *BMC Evolutionary Biology* **8** (2008), no. 1, 255.
-  Julien Dutheil, Sylvain Gaillard, Eric Bazin, Sylvain Glémin, Vincent Ranwez, Nicolas Galtier, and Khalid Belkhir, *Bio++ : a set of C++ libraries for sequence analysis, phylogenetics, molecular evolution and population genetics*, *BMC Bioinformatics* **7** (2006), no. 1, 188.