

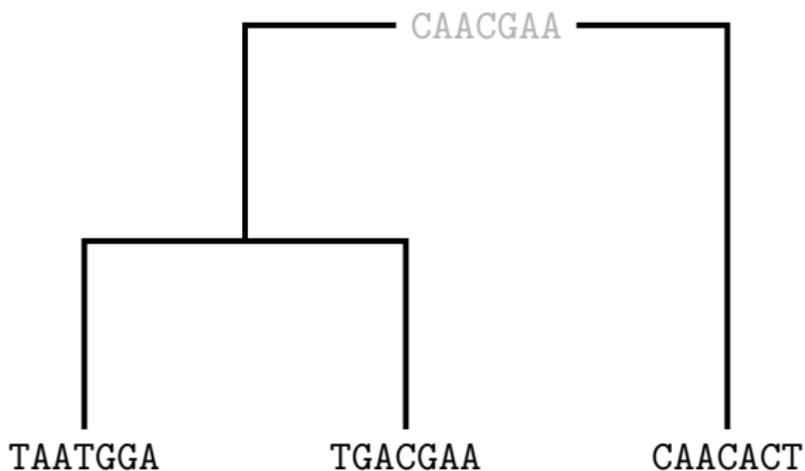
Méthodes particulières et vraisemblances pour l'inférence de modèles d'évolution avec dépendance au contexte

Alexis Huet

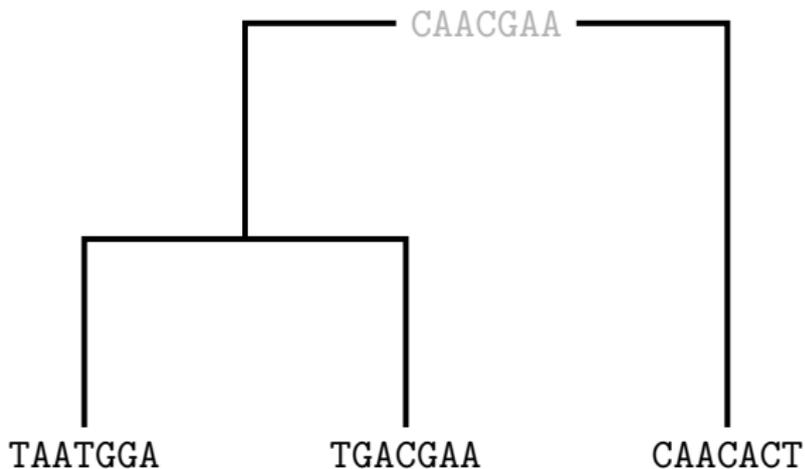
27 juin 2014

- 1 Introduction
- 2 Encodages et vraisemblances composites
- 3 Structures markoviennes
- 4 Méthodes numériques
- 5 Applications

- 1 Introduction
- 2 Encodages et vraisemblances composites
- 3 Structures markoviennes
- 4 Méthodes numériques
- 5 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)

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

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 $Y \rightarrow Y$.

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)

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

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 $Y \rightarrow Y$.

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

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

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

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

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.

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

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

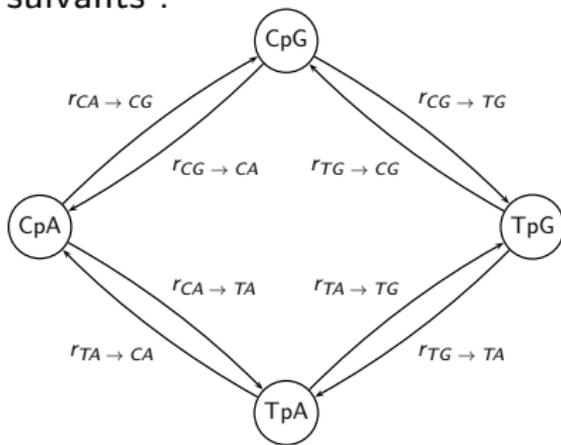
$$P \left(\begin{array}{cc} \dots \text{ACGTA} \dots & \text{temps } t \\ \downarrow & \\ \dots \text{ACATA} \dots & \text{temps } t+dt \end{array} \right) = (w_A + r_{CG \rightarrow CA})dt + o(dt),$$

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

- 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 :



- Mise en évidence de structures de dépendances markoviennes.
- Introduction de méthodes particulières pour calculer les vraisemblances en exploitant ces structures :
 - création de code (C++),
 - applications.
- Comportement asymptotique d'estimateurs :
 - consistance et normalité asymptotique du maximum de vraisemblance,
 - estimateur semi-empirique de la variance pour la méthode d'estimation de [BG12].
- Introduction d'une vraisemblance composite « approximation markovienne ».
- Étude théorique de cas limites (mise en évidence des phénomènes de dépendance).

- Mise en évidence de structures de dépendances markoviennes.
- Introduction de méthodes particulières pour calculer les vraisemblances en exploitant ces structures :
 - création de code (C++),
 - applications.
- Comportement asymptotique d'estimateurs :
 - consistance et normalité asymptotique du maximum de vraisemblance,
 - estimateur semi-empirique de la variance pour la méthode d'estimation de [BG12].
- Introduction d'une vraisemblance composite « approximation markovienne ».
- Étude théorique de cas limites (mise en évidence des phénomènes de dépendance).

- Mise en évidence de structures de dépendances markoviennes.
- Introduction de méthodes particulières pour calculer les vraisemblances en exploitant ces structures :
 - création de code (C++),
 - applications.
- Comportement asymptotique d'estimateurs :
 - consistance et normalité asymptotique du maximum de vraisemblance,
 - estimateur semi-empirique de la variance pour la méthode d'estimation de [BG12].
- Introduction d'une vraisemblance composite « approximation markovienne ».
- Étude théorique de cas limites (mise en évidence des phénomènes de dépendance).

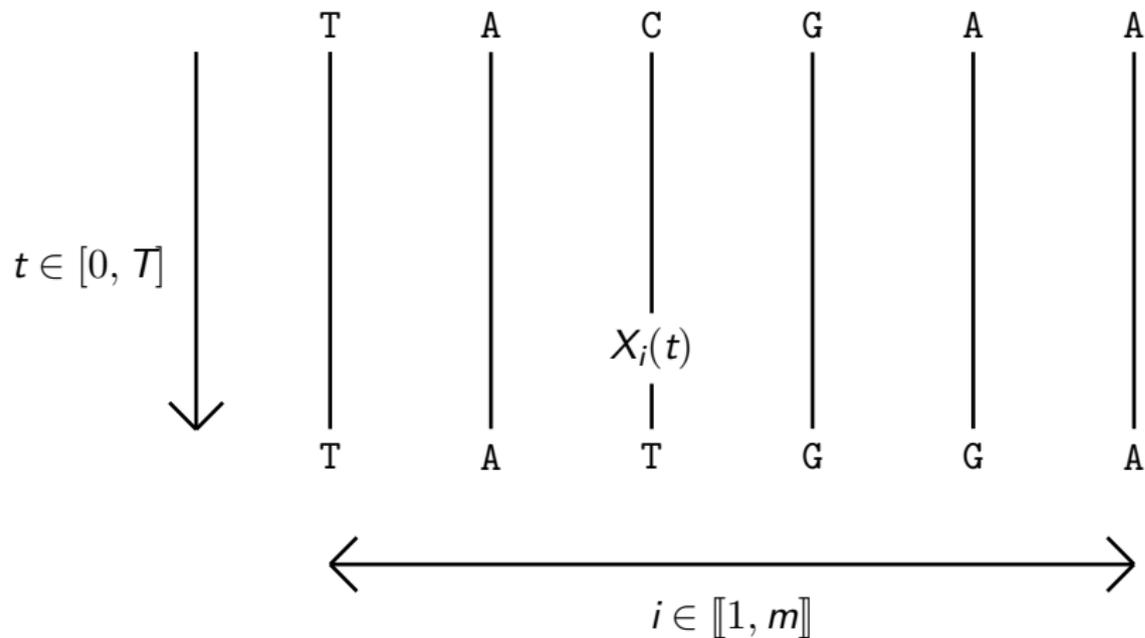
- Mise en évidence de structures de dépendances markoviennes.
- Introduction de méthodes particulières pour calculer les vraisemblances en exploitant ces structures :
 - création de code (C++),
 - applications.
- Comportement asymptotique d'estimateurs :
 - consistance et normalité asymptotique du maximum de vraisemblance,
 - estimateur semi-empirique de la variance pour la méthode d'estimation de [BG12].
- Introduction d'une vraisemblance composite « approximation markovienne ».
- Étude théorique de cas limites (mise en évidence des phénomènes de dépendance).

- Mise en évidence de structures de dépendances markoviennes.
- Introduction de méthodes particulières pour calculer les vraisemblances en exploitant ces structures :
 - création de code (C++),
 - applications.
- Comportement asymptotique d'estimateurs :
 - consistance et normalité asymptotique du maximum de vraisemblance,
 - estimateur semi-empirique de la variance pour la méthode d'estimation de [BG12].
- Introduction d'une vraisemblance composite « approximation markovienne ».
- Étude théorique de cas limites (mise en évidence des phénomènes de dépendance).

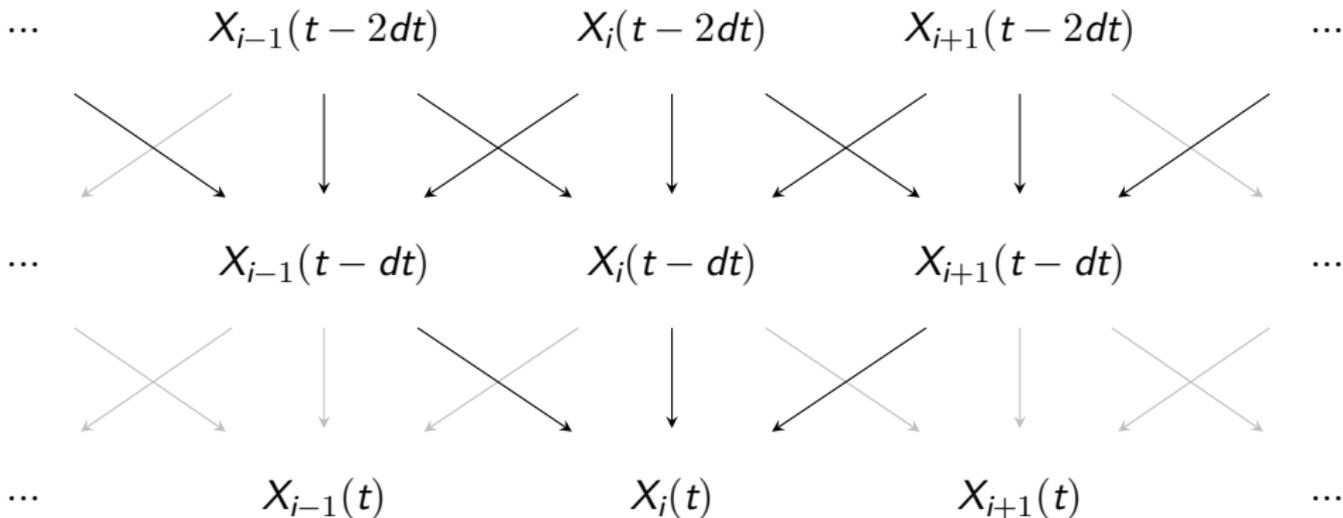
- Mise en évidence de structures de dépendances markoviennes.
- Introduction de méthodes particulières pour calculer les vraisemblances en exploitant ces structures :
 - création de code (C++),
 - applications.
- Comportement asymptotique d'estimateurs :
 - consistance et normalité asymptotique du maximum de vraisemblance,
 - estimateur semi-empirique de la variance pour la méthode d'estimation de [BG12].
- Introduction d'une vraisemblance composite « approximation markovienne ».
- Étude théorique de cas limites (mise en évidence des phénomènes de dépendance).

- 1 Introduction
- 2 Encodages et vraisemblances composites
- 3 Structures markoviennes
- 4 Méthodes numériques
- 5 Applications

Évolution de séquence à séquence



Chaînes de dépendance



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.
- Des séquences Φ -encodées disjointes évoluent indépendamment.

- Calcul de la vraisemblance pour des séquences Φ -encodées de longueurs $m = 2, 3, 4, 5$.
- Découpage RY en séquences Φ -encodées minimales.

Exemple :

$$L(\Phi(\text{TAATGGA})) = L(\Phi(\text{TAA})\Phi(\text{TGGA})) = L(\Phi(\text{TAA}))L(\Phi(\text{TGGA})).$$

→ 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 $m = 2, 3, 4, 5$.
- Découpage RY en séquences Φ -encodées minimales.

Exemple :

$$L(\Phi(\text{TAATGGA})) = L(\Phi(\text{TAA})\Phi(\text{TGGA})) = L(\Phi(\text{TAA}))L(\Phi(\text{TGGA})).$$

→ 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 $m = 2, 3, 4, 5$.
- Découpage RY en séquences Φ -encodées minimales.

Exemple :

$$L(\Phi(\text{TAATGGA})) = L(\Phi(\text{TAA})\Phi(\text{TGGA})) = L(\Phi(\text{TAA}))L(\Phi(\text{TGGA})).$$

→ Calcul de la vraisemblance pour des observations générales ?

- Vraisemblances composites.
- Approximation de type Monte Carlo.

Découpage des séquences en triplets Φ -encodés [BG12] :

$$\begin{array}{ccc} \underbrace{X_1(T)X_2(T)X_3(T)} & \underbrace{X_4(T)X_5(T)X_6(T)} & \dots \\ \Phi(X_1(T)X_2(T)X_3(T)) & \Phi(X_4(T)X_5(T)X_6(T)) & \dots \end{array}$$

On déduit pour chaque paramètre θ une vraisemblance composite $\hat{L}_{\text{triplets}}(\theta)$.

→ Cette vraisemblance composite a été exploitée numériquement dans [BG12].

Découpage des séquences en triplets Φ -encodés [BG12] :

$$\begin{array}{ccc} \underbrace{X_1(T)X_2(T)X_3(T)} & \underbrace{X_4(T)X_5(T)X_6(T)} & \dots \\ \Phi(X_1(T)X_2(T)X_3(T)) & \Phi(X_4(T)X_5(T)X_6(T)) & \dots \end{array}$$

On déduit pour chaque paramètre θ une vraisemblance composite $\hat{L}_{\text{triplets}}(\theta)$.

→ Cette vraisemblance composite a été exploitée numériquement dans [BG12].

- $\hat{L}_{\text{triplets}}(\theta)$ définie à l'aide des triplets Φ -encodés,
- $\hat{L}_{\text{couples}}(\theta)$ définie de même avec les couples Φ -encodés.

Définition

$$\hat{L}_{\text{Markov}}(\theta) = \frac{\hat{L}_{\text{triplets}}(\theta)}{\hat{L}_{\text{couples}}(\theta)}.$$

- Justification du nom : approximation exacte si

$$P(\Phi(X_i X_{i+1})(T) | \Phi(X_1 \dots X_i)(T)) = P(\Phi(X_i X_{i+1})(T) | \Phi(X_{i-1} X_i)(T)).$$

- Intérêt : approximation composite de la vraisemblance.

- $\hat{L}_{\text{triplets}}(\theta)$ définie à l'aide des triplets Φ -encodés,
- $\hat{L}_{\text{couples}}(\theta)$ définie de même avec les couples Φ -encodés.

Définition

$$\hat{L}_{\text{Markov}}(\theta) = \frac{\hat{L}_{\text{triplets}}(\theta)}{\hat{L}_{\text{couples}}(\theta)}.$$

- Justification du nom : approximation exacte si

$$P(\Phi(X_i X_{i+1})(T) | \Phi(X_1 \dots X_i)(T)) = P(\Phi(X_i X_{i+1})(T) | \Phi(X_{i-1} X_i)(T)).$$

- Intérêt : approximation composite de la vraisemblance.

- 1 Introduction
- 2 Encodages et vraisemblances composites
- 3 Structures markoviennes**
- 4 Méthodes numériques
- 5 Applications

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

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

Théorème (thèse H.)

La séquence évolutive Φ -encodée $\{(\Phi(X))_i ; i \in \llbracket 1, m \rrbracket\}$ est un champ markovien d'ordre un.

- Forme explicite de l'évolution d'un site i conditionnellement aux autres sites.
- Induit une structure spatiale de chaîne de Markov... Mais forme non explicite.

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

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

Théorème (thèse H.)

La séquence évolutive Φ -encodée $\{(\Phi(X))_i ; i \in \llbracket 1, m \rrbracket\}$ est un champ markovien d'ordre un.

- Forme explicite de l'évolution d'un site i conditionnellement aux autres sites.
- Induit une structure spatiale de chaîne de Markov... Mais forme non explicite.

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

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

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 $U_{R \rightarrow Y}$.

Théorème (thèse H.)

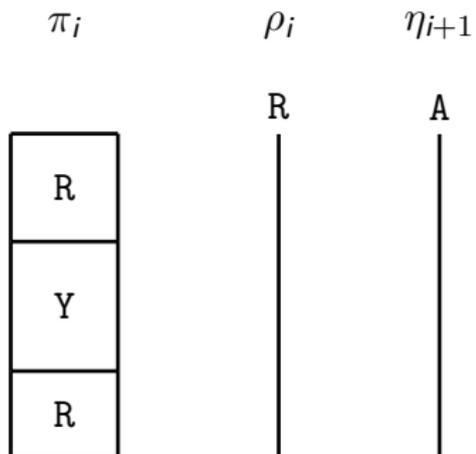
On suppose la racine fixée. Alors $(Z_i)_i$ est une chaîne de Markov.

Théorème (thèse H.)

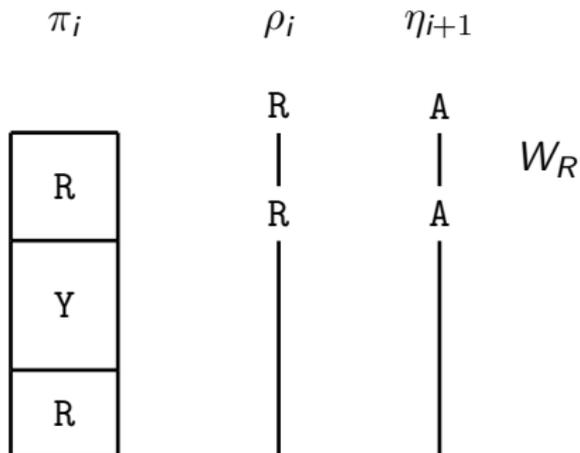
Conditionnellement à $Z_{1:i-1}$ et $Z_i([0, t])$, la description de la loi de transition de Z_i à l'instant t est explicite :

- 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 $U_{R \rightarrow Y}$.

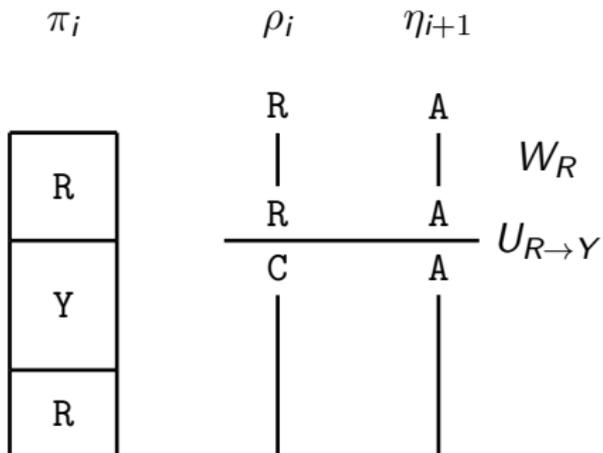
Exemple



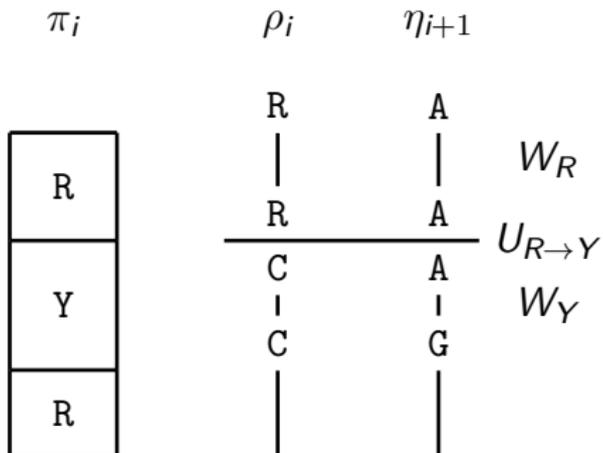
Exemple



Exemple



Exemple



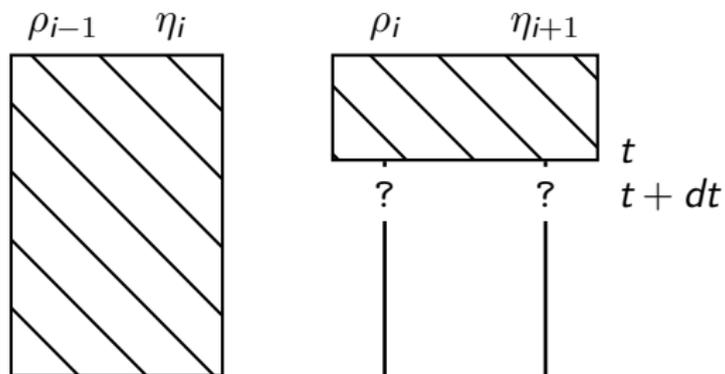
Exemple

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 	

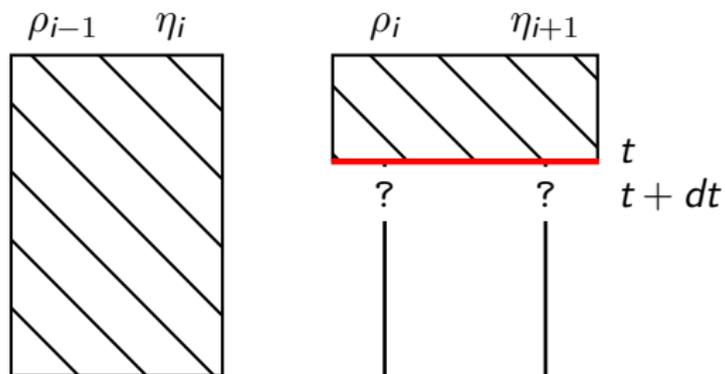
Exemple

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		

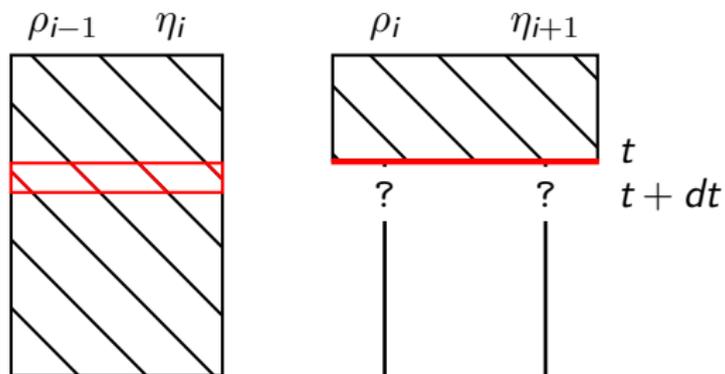
Idée de la démonstration



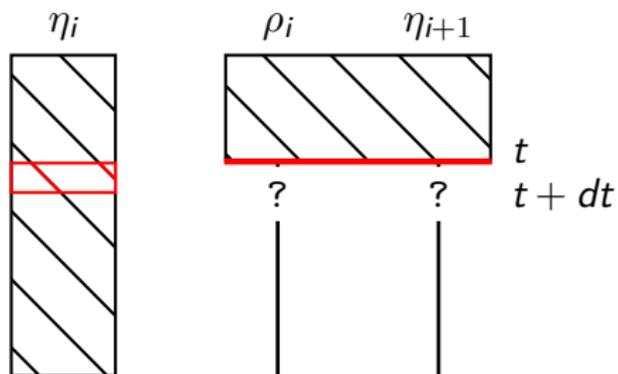
Idée de la démonstration



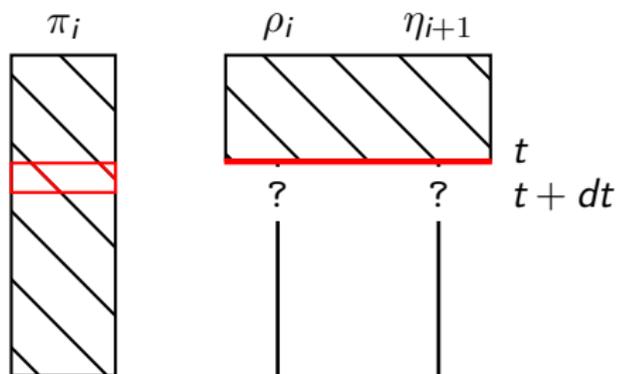
Idée de la démonstration



Idée de la démonstration



Idée de la démonstration



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

$$\begin{array}{ccccccccc} Z_1 & \longrightarrow & Z_2 & \longrightarrow & Z_3 & \longrightarrow & \dots & \longrightarrow & Z_{m-1} \\ \downarrow & & \downarrow & & \downarrow & & \downarrow & & \downarrow \\ Z_1(T) & & Z_2(T) & & Z_3(T) & & \dots & & Z_{m-1}(T) \end{array} .$$

Théorème (thèse H.)

Consistance et normalité asymptotique de l'estimateur du maximum de vraisemblance pour des observations issues d'un modèle RN95+YpR (sous des conditions de compacité et d'identifiabilité des paramètres).

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

$$\begin{array}{ccccccccc} Z_1 & \longrightarrow & Z_2 & \longrightarrow & Z_3 & \longrightarrow & \dots & \longrightarrow & Z_{m-1} \\ \downarrow & & \downarrow & & \downarrow & & \downarrow & & \downarrow \\ Z_1(T) & & Z_2(T) & & Z_3(T) & & \dots & & Z_{m-1}(T) \end{array} .$$

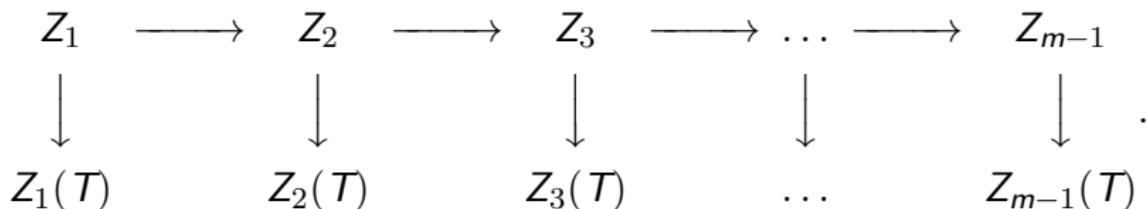
Théorème (thèse H.)

Consistance et normalité asymptotique de l'estimateur du maximum de vraisemblance pour des observations issues d'un modèle RN95+YpR (sous des conditions de compacité et d'identifiabilité des paramètres).

- 1 Introduction
- 2 Encodages et vraisemblances composites
- 3 Structures markoviennes
- 4 Méthodes numériques**
- 5 Applications

Comment approcher la vraisemblance ?

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



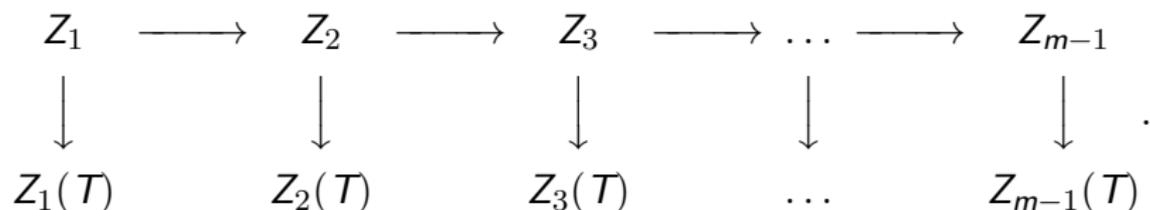
- Connaissance de $z_{1:m-1}(T)$ mais pas de $z_{1:m-1}$.
- But : calculer la vraisemblance des observations $z_{1:m-1}(T)$ par produit :

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

- 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 $i-1$:

$$\frac{1}{N} \sum_{j=1}^N \mathbf{1}_{z_{1:i-1}^{(j)}}(z_{1:i-1}) \approx \text{loi}(z_{1:i-1} | z_{1:i-1}(T)).$$

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

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

- Site i :

$$\frac{1}{N} \sum_{j=1}^N \mathbf{1}_{z_{1:i}^{(j)}}(z_{1:i}) \approx \text{loi}(z_{1:i} | z_{1:i}(T)).$$

Puis :

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

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 $i-1$:

$$\frac{1}{N} \sum_{j=1}^N \mathbf{1}_{z_{1:i-1}^{(j)}}(z_{1:i-1}) \approx \text{loi}(z_{1:i-1} | z_{1:i-1}(T)).$$

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

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

- Site i :

$$\frac{1}{N} \sum_{j=1}^N \mathbf{1}_{z_{1:i}^{(j)}}(z_{1:i}) \approx \text{loi}(z_{1:i} | z_{1:i}(T)).$$

Puis :

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

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 $i-1$:

$$\frac{1}{N} \sum_{j=1}^N \mathbf{1}_{z_{1:i-1}^{(j)}}(z_{1:i-1}) \approx \text{loi}(z_{1:i-1} | z_{1:i-1}(T)).$$

- 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 :

$$\frac{1}{N} \sum_{j=1}^N \mathbf{1}_{z_{1:i}^{(j)}}(z_{1:i}) \approx \text{loi}(z_{1:i} | z_{1:i}(T)).$$

Puis :

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

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 $i-1$:

$$\frac{1}{N} \sum_{j=1}^N \mathbf{1}_{z_{1:i-1}^{(j)}}(z_{1:i-1}) \approx \text{loi}(z_{1:i-1} | z_{1:i-1}(T)).$$

- 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 :

$$\frac{1}{N} \sum_{j=1}^N \mathbf{1}_{z_{1:i}^{(j)}}(z_{1:i}) \approx \text{loi}(z_{1:i} | z_{1:i}(T)).$$

Puis :

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

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 $i-1$:

$$\frac{1}{N} \sum_{j=1}^N \mathbf{1}_{z_{1:i-1}^{(j)}}(z_{1:i-1}) \approx \text{loi}(z_{1:i-1} | z_{1:i-1}(T)).$$

- 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 :

$$\frac{1}{N} \sum_{j=1}^N \mathbf{1}_{z_{1:i}^{(j)}}(z_{1:i}) \approx \text{loi}(z_{1:i} | z_{1:i}(T)).$$

Puis :

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

Théorème

Pour un nombre de sites m fixé, l'estimateur de $p(z_{i+1}(T)|z_{1:i}(T))$ est consistant et asymptotiquement normal lorsque le nombre de particules N tend vers l'infini.

Théorème

Pour un nombre de sites m fixé, le produit des estimateurs de $p(z_{i+1}(T)|z_{1:i}(T))$ (pour $i \in 0 : m - 2$) est un estimateur consistant et asymptotiquement normal de $p(z_{1:m-1}(T))$ 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.

Implémentation

```
class EvolSite
{
public:
//////////
// Constructeurs //
//////////
EvolSite(int lettreInitialeAlph, std::vector<double>
tempsChangementGauche, std::vector<char> quelChangementGauche, double
tempsInit, double tempsFinal, Noyau &noyau); //constructeur complet,
classique.
EvolSite(std::vector<double> tempsChangementGauche, std::vector<char>
quelChangementGauche, double tempsInit, double tempsFinal, Noyau
&noyau); //sans lettre initiale
EvolSite(int lettreInitialeAlph, double tempsInit, double tempsFinal,
Noyau &noyau); //sans renseignement de ce qui est à gauche
EvolSite(double tempsInit, double tempsFinal, Noyau &noyau); //sans
connaissance à gauche ni de la lettre initiale.
EvolSite();

//////////
// Méthodes constantes pour le site en cours //
//////////
//temps
double getTempsInit() const;
double getTempsFinal() const;
double getTempsActuel() const;
//dernier changement
int getQuelChangementMatBack() const; //parmi 0..2 ou 0..5
int getQuelChangementAlphBack() const; //parmi 0..8
//nucléotide à la racine
bool racineEstVide() const; //1 si pas de site initial fixé. 0 non vide.
1 vide.
int getLettreInitialeMat() const; //parmi 0..2 ou 0..5
int getLettreInitialeAlph() const; //parmi 0..8
//noyau
Noyau& getNoyau() const; //sert pour l'évolution sur l'arbre pour
obtenir les différents taux

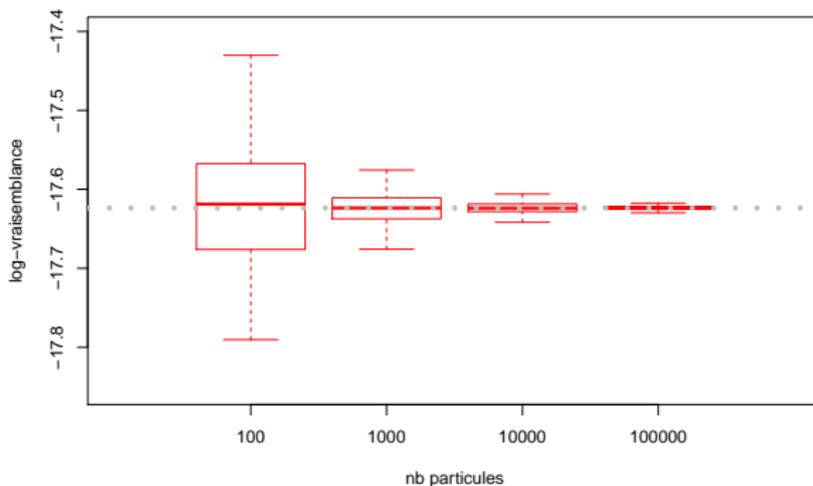
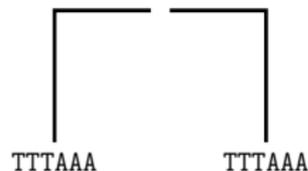
//////////
// Méthodes constantes pour le site à gauche du site évoluant //
//////////
//au temps t
char elementAGAucheC(double t) const; //élément à gauche parmi 'R' ou
'Y' lorsqu'on est au temps t
int indiceProchainChangementAGAuche(double t) const; //indice du vecteur
ou prochain changement à gauche après t (strictement)
double tempsProchainChangementAGAuche(double t) const; //instant du
prochain changement à gauche après t (strictement)
//au temps final
char getQuelChangementGaucheFinal() const;
//écarts entre les différents instants de changement à gauche dans {R,Y},
sert entre autres à obtenir la matrice d'évolution
std::vector<double> differentsEcartEntre(double s, double t) const; //
donne les écarts à gauche sur |s,t|
std::vector<char> differentsCaractEntre(double s, double t) const; //
donne les caract à gauche sur |s,t|
//temps passés en Y et en R, sert pour calculer la fonction de survie
double tempsPasseY(double s, double t) const; //cumul des temps entre s
et t où le pi à gauche du site considéré vaut Y.
double tempsPasseR(double s, double t) const; //pareil avec R
double tempsPasse(char N, double s, double t) const; //N parmi {R,Y}.

//////////
// Méthodes constantes pour le site évoluant //
//////////
//réduit l'information de couples quotientés par la surjection dans
l'ensemble {R,Y}
//Ex: si on a "RA" suivi de "CA" suivi de "CG" suivi de "CY" au site en
cours, alors l'évolution dans pi du nucléotide à droite est 'R' suivi de
'R' suivi de 'R' suivi de 'Y'.
std::vector<int> indiceChangementRY() const; //prend que les indices des
changements qui font vraiment aller de R vers Y ou le contraire.
std::vector<double> tempsChangementRY() const;
std::vector<char> quelChangementRY() const; //dans l'exemple, 'R' puis
'Y'.

//////////
// Calcul de la matrice d'évolution // (à partir de l'histoire à gauche
dans {R,Y})
//////////
std::vector<Eigen::MatrixXd> matriceEvol(double s, double t) const; //
donne les matrices d'évolutions du temps s au temps t, une par inter-
durée.
void remplirMorceauxExp(); //remplit m_morceauxExp à partir de
matriceEvol, qui sont les différents morceaux que l'on a à multiplier du
temps initial au temps final.
Eigen::MatrixXd matriceDEvolution(double s) const; //matrices
d'évolution de s jusqu'au temps final (de l'arête). Correspond au produit
des matrices d'évolutions intermédiaires  $\exp(t_1 W_R) * U_{(R \rightarrow Y)} * \exp(t_2 W_Y)$  etc., où les  $t_i$  sont les écarts de temps.
```

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 : $(TTTAAA, TTTAAA)$.

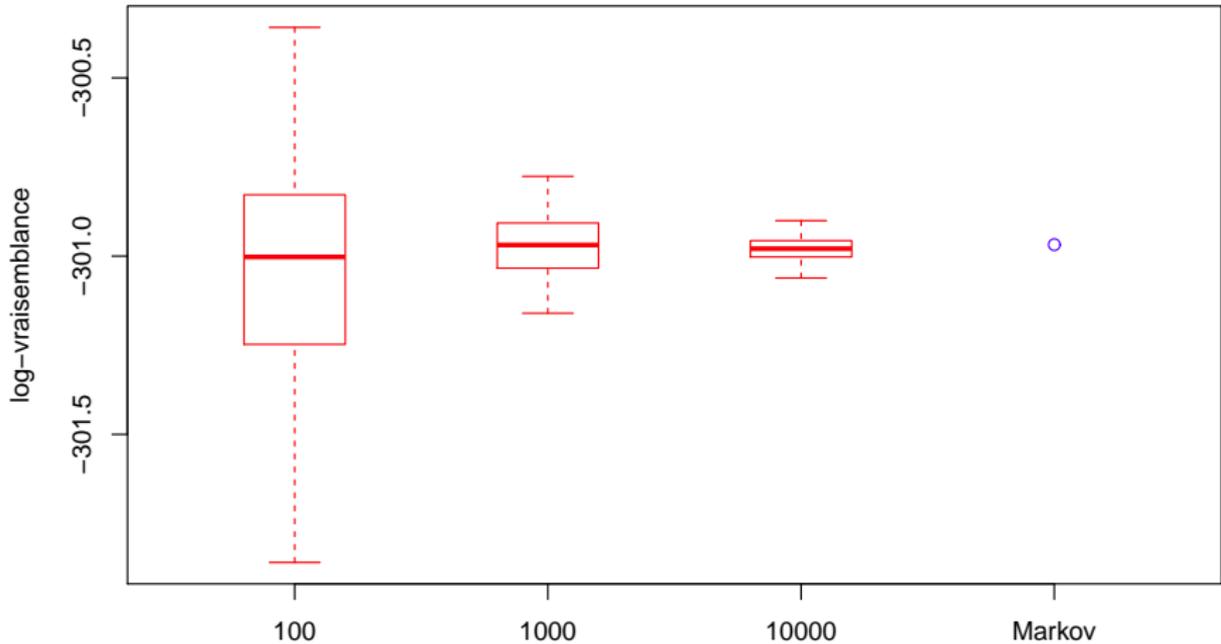


- 1 Introduction
- 2 Encodages et vraisemblances composites
- 3 Structures markoviennes
- 4 Méthodes numériques
- 5 Applications**

Qualité de l'approximation markovienne ?

Qualité de l'approximation markovienne ?

- Modèle d'évolution et séquences observées tirés aléatoirement, $m = 100$ sites.

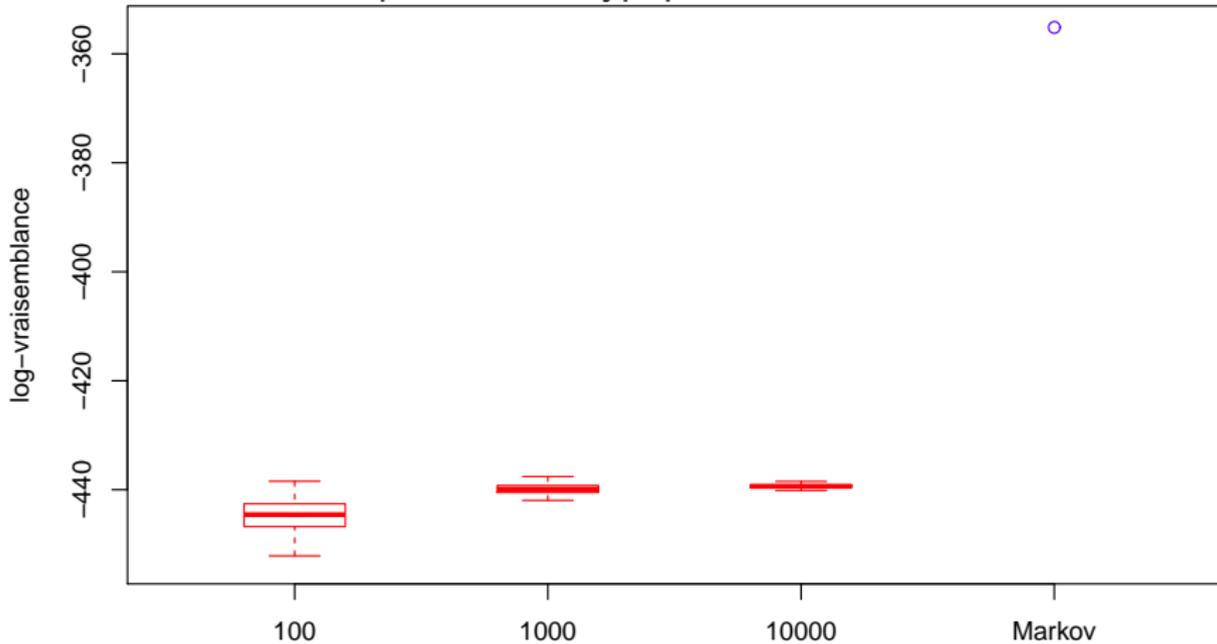


Qualité de l'approximation markovienne ?

- Modèle d'évolution et séquences observées choisis pour obtenir un comportement atypique, $m = 100$ sites.

Qualité de l'approximation markovienne ?

- Modèle d'évolution et séquences observées choisis pour obtenir un comportement atypique, $m = 100$ sites.



Inférence d'un nucléotide à la racine

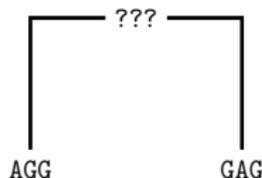
Problématique : dépendance aux voisins de l'estimation d'un nucléotide de la séquence ancestrale.

Inférence d'un nucléotide à la racine

Problématique : dépendance aux voisins de l'estimation d'un nucléotide de la séquence ancestrale.

Exemple :

Modèle d'évolution atypique, loi à la racine i.i.d.

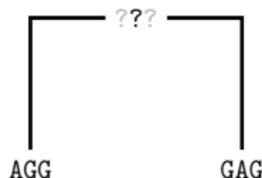


Inférence d'un nucléotide à la racine

Problématique : dépendance aux voisins de l'estimation d'un nucléotide de la séquence ancestrale.

Exemple :

Modèle d'évolution atypique, loi à la racine i.i.d.

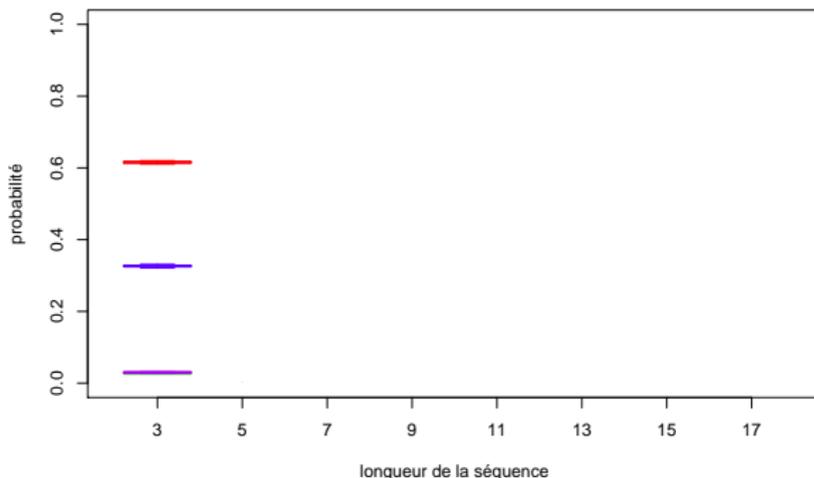
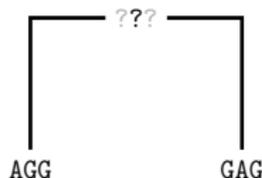


Inférence d'un nucléotide à la racine

Problématique : dépendance aux voisins de l'estimation d'un nucléotide de la séquence ancestrale.

Exemple :

Modèle d'évolution atypique, loi à la racine i.i.d. A, G, C, T.

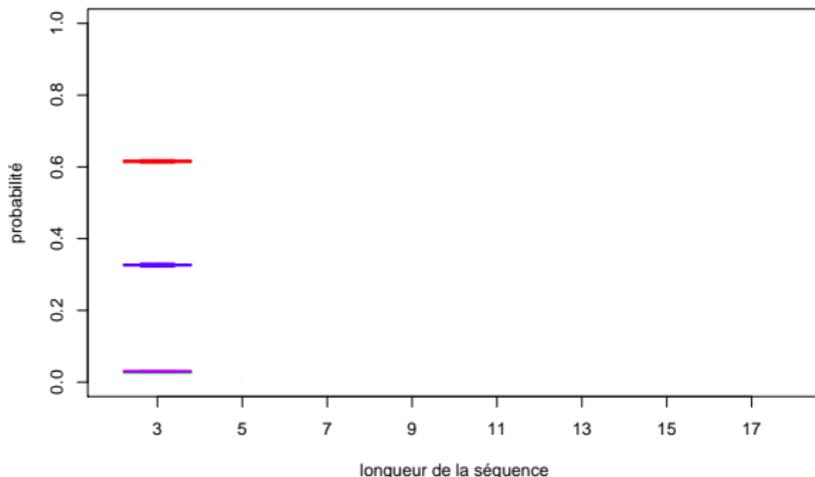
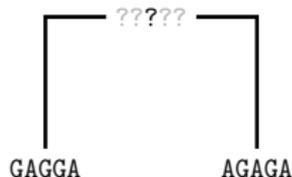


Inférence d'un nucléotide à la racine

Problématique : dépendance aux voisins de l'estimation d'un nucléotide de la séquence ancestrale.

Exemple :

Modèle d'évolution atypique, loi à la racine i.i.d. A, G, C, T.

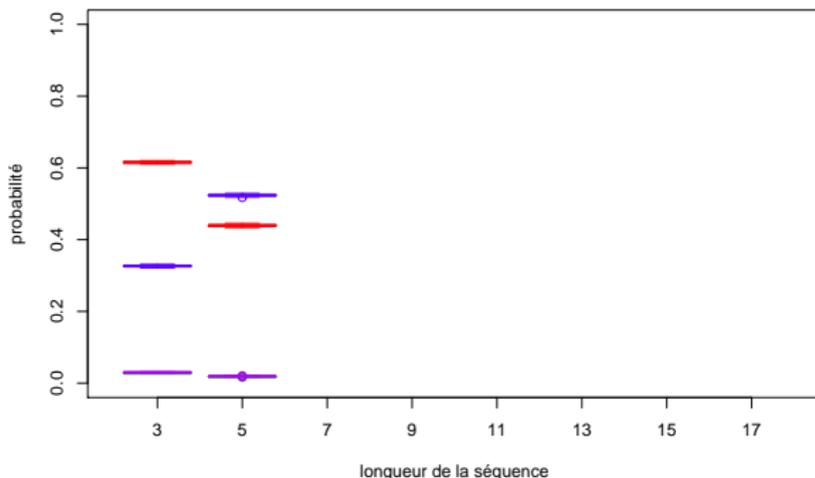
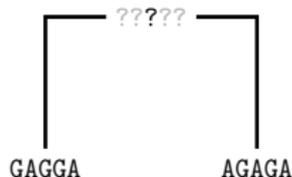


Inférence d'un nucléotide à la racine

Problématique : dépendance aux voisins de l'estimation d'un nucléotide de la séquence ancestrale.

Exemple :

Modèle d'évolution atypique, loi à la racine i.i.d. A, G, C, T.

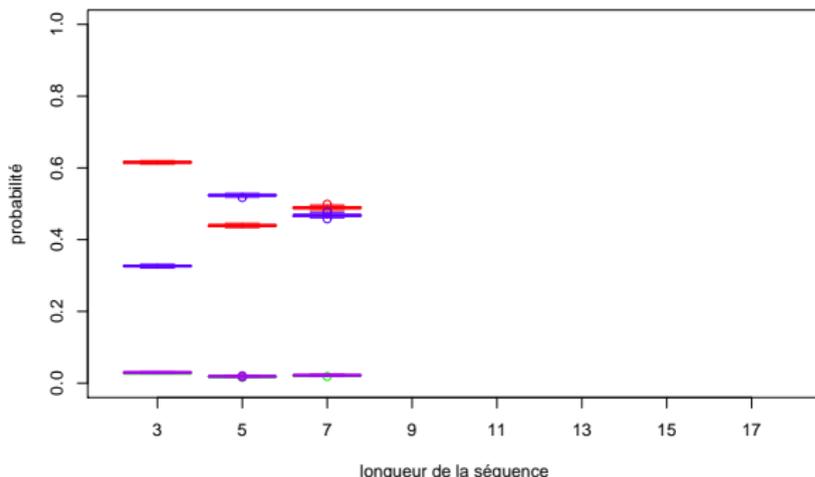
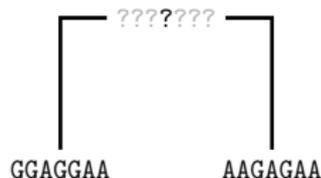


Inférence d'un nucléotide à la racine

Problématique : dépendance aux voisins de l'estimation d'un nucléotide de la séquence ancestrale.

Exemple :

Modèle d'évolution atypique, loi à la racine i.i.d. A, G, C, T.

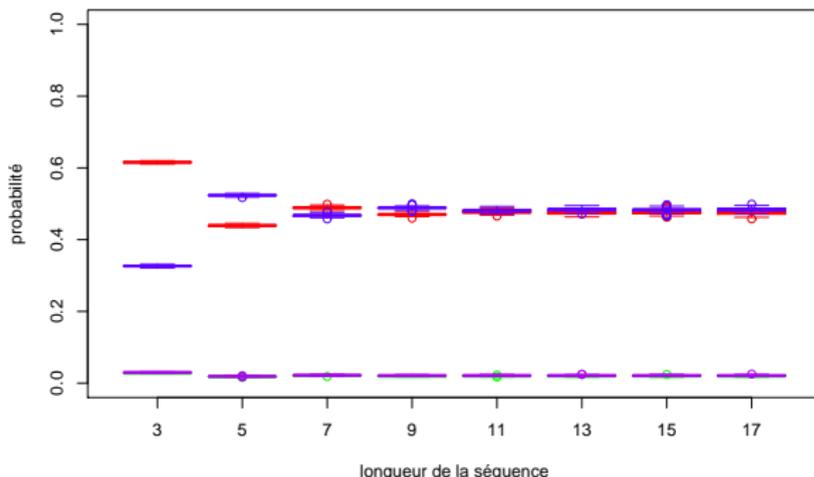
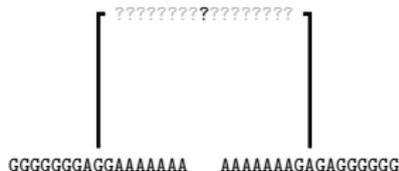


Inférence d'un nucléotide à la racine

Problématique : dépendance aux voisins de l'estimation d'un nucléotide de la séquence ancestrale.

Exemple :

Modèle d'évolution atypique, loi à la racine i.i.d. **A**, **G**, **C**, **T**.



Comparaison des estimations entre celles obtenues :

- par vraisemblance composite par triplets Φ -encodés,
- par approximations particulières.

→ Sur les exemples testés (un paramètre réel à estimer), écart d'estimation « faible ».

→ Conforte l'utilisation des triplets Φ -encodés pour estimer le max. de vraisemblance.

Comparaison des estimations entre celles obtenues :

- par vraisemblance composite par triplets Φ -encodés,
- par approximations particulières.

→ Sur les exemples testés (un paramètre réel à estimer), écart d'estimation « faible ».

→ Conforte l'utilisation des triplets Φ -encodés pour estimer le max. de vraisemblance.

Comparaison des estimations entre celles obtenues :

- par vraisemblance composite par triplets Φ -encodés,
- par approximations particulières.

→ Sur les exemples testés (un paramètre réel à estimer), écart d'estimation « faible ».

→ Conforte l'utilisation des triplets Φ -encodés pour estimer le max. de vraisemblance.

Algorithme pratique

- 1 Estimer le maximum de vraisemblance des observations par la méthode des triplets encodés (bppm1 de Bio++ [BG12, DB08, DGB⁺06]).
- 2 Découper les observations en morceaux indépendants (découpage RY).
- 3 Pour chaque morceau :
 - Si le nombre de nucléotides est « petit » (< 6), calculer exactement la vraisemblance de ce morceau.
 - Sinon, calculer une approximation particulière de la vraisemblance du morceau.
- 4 En déduire une approximation 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.

- Étude d'un modèle d'évolution de l'ADN : RN95+YpR.
- Deux manières d'approcher la vraisemblance pour des séquences issues de ces modèles :
 - approximations markoviennes,
 - approximations particulières.
- Mise en œuvre et comparaison de ces deux approches.
- Applications.

Merci de votre attention !