

ALIGNEMENT STATISTIQUE


Paire-HMM

Modèle de Markov caché :


→ états = {insertion, suppression, substitution/identité}

→ émission : colonne de l'alignement

Problème d'inférence : on connaît les séquences sans trous — qu'est-ce qu'on peut dire sur l'alignement inconnu ?




Paire-HMM : alignement



Viterbi pour trouver le meilleur alignement . . .

Procéssus d'indel

On a vu les modèles de Markov pour substitutions — est-ce qu'on peut modéliser aussi les indels par un procéssus stochastique ?



Idée : événements forment un procéssus (p.e., Poisson de taux θ), il faut juste spécifier ce qui se passe lors d'un événement

Longueur d'insertion/suppressions ? Distributions $p_{\text{Ins}}(\ell)$ et $p_{\text{Del}}(\ell)$:


$$\sum_{\ell=1}^{\infty} p_{\text{Ins}}(\ell) + \sum_{\ell=1}^{\infty} p_{\text{Del}}(\ell) = 1$$

→ très difficile (ou impossible) de travailler avec un tel modèle générique

Thorne-Kishino-Felsenstein 1991

Modèle simple : insertions et suppressions de longueur 1


Un processus indel à chaque caractère + au début, en parallèle avec les processus de substitution (iid à chaque résidue)



Événement d'insertion : choix d'un caractère selon la distribution stationnaire

TKF 2

But : étant donné une séquence ancestrale et une séquence descendante, établir de la homologie au niveau des caractères (représenté par un alignement)



C=ancêtre ou son homologue (match/mismatch)

#=aucune homologue à l'ancêtre (insertion)

TKF 3

Les caractères s'évoluent indépendamment : on peut considérer le **sort** de chaque caractère ancestral séparément

$C \underbrace{\# \dots \#}_{n \text{ fois}}$	ancêtre survivant, avec $n \geq 0$ caractères insérés à côté	$C---$ $C###$
$\square \underbrace{\# \dots \#}_{n \text{ fois}}$	ancêtre mort, avec $n > 0$ caractères insérés à côté	$C---$ $-###$
\square	ancêtre mort, aucune insertion à côté	\underline{C}
$\star \underbrace{\# \dots \#}_{n \text{ fois}}$	insertion de $n \geq 0$ caractères au début	$---$ $###$

TKF 4

Taux d'insertion λ à chaque caractère ainsi qu'au début
taux de suppression μ à chaque caractère

Longueur stationnaire ($t \rightarrow \infty$) de la séquence? Soit $p_\ell = \mathbb{P}\{\text{longueur} = \ell\}$.
En équilibre, on a pour tout $\ell \geq 0$:

$$\underbrace{\lambda(\ell + 1) \cdot p_\ell}_{\text{taux } \ell \rightarrow \ell + 1} = \underbrace{\mu(\ell + 1) \cdot p_{\ell+1}}_{\text{taux } \ell + 1 \rightarrow \ell}$$

$$\text{d'où } \frac{p_{\ell+1}}{p_\ell} = \frac{\lambda}{\mu}$$

Si $\lambda \geq \mu$, alors $p_\ell \equiv 0$ (la séquence croît sans borne)

$$\text{Si } \lambda < \mu, \text{ alors } p_\ell \propto \left(\frac{\lambda}{\mu}\right)^\ell$$

\Rightarrow distribution géométrique ($\sum_{\ell=0}^{\infty} p_\ell = 1$)

TKF 5

Il est possible de trouver les formules exactes pour les probabilités des sorts :

Sort	probabilité $X \rightarrow Y$
$C \rightarrow C\#^{n-1}$	$H_t B_t^{n-1}$
$C \rightarrow \square\#^n$	$N_t B_t^{n-1}$
$C \rightarrow \square$	E_t
$\star \rightarrow \star\#^n$	$I_t B_t^n$

avec

$$B_t = \lambda\beta_t \qquad E_t = \mu\beta_t \qquad I_t = 1 - \lambda\beta_t$$

$$H_t = e^{-\mu t}(1 - \lambda\beta_t) \quad N_t = (1 - e^{-\mu t} - \mu\beta_t)(1 - \lambda\beta_t);$$

$$\text{et } \beta_t = \frac{1 - e^{-(\mu-\lambda)t}}{\mu - \lambda e^{-(\mu-\lambda)t}}.$$

TKF 6

Maintenant on peut

- trouver le meilleur alignement
- maximiser la vraisemblance pour deux séquences homologues et ainsi trouver les valeurs de λ , μ , t
- concevoir des tests de homologie basés sur la valeur de la vraisemblance
- évaluer la fiabilité de l'alignement optimal

TKF 7

Calculer la vraisemblance — utiliser de la PD (en se servant des queues géométriques $\propto B^n$)

$L(i, j)$ probabilité de l'alignement de préfixes $X[1..i]$ et $Y[1..j]$;

$Z(i, j)$ variables auxiliaires

$$\begin{aligned} Z(i, j) = & p_{i,j} \cdot H \cdot Z(i-1, j-1) \quad \{H \times B^{n-1}\} \\ & + p_j \cdot N \cdot Z(i-1, j-1) \quad \{N \times B^{n-1}\} \\ & + p_j \cdot B \cdot Z(i, j-1) \quad \{N \text{ ou } H \times B^{n-1}\} \\ L(i, j) = & Z(i, j) + E \cdot L(i-1, j) \end{aligned}$$


où $p_{i,j}$ est la probabilité $X[i] \rightarrow Y[j]$ dans la matrice de substitution et p_j est la probabilité stationnaire de $Y[j]$;

initialisation :

$$Z(0, 0) = L(0, 0) = I$$

TKF 8

Il est possible de trouver un paire-HMM équivalent



(p_{MM} , p_{MI} , etc. sont calculés à partir de I_t , B_t , H_t , N_t , E_t)