

MODÈLES PROBABILISTES DE SÉQUENCES

OU COMMENT ÉCRIRE LE LIVRE
AUTOMATIQUEMENT

Gènes ARN

ARN de transfert

ARN ribosomale

d'autres (p.e., Ribonucléase P ARN)

acide nucléique à un brin — repliement par liaisons hydrogène

structure est importante


ARNt



(notez les hélices)

[Wikipedia](#)

Structure secondaire — RNase P RNA




Recherche de gènes ARN

- modèle de structure secondaire : scanner la séquence du génome
- exemple : tRNAScan

Gènes ARN dans des thermophiles

en procaryotes thermophiliques on peut identifier les gènes ARN par contenu de GC



Segmentation

Modèle : séquence X de longueur n où $X[i] \in \{W, S\}$
($W = \{A, T\}$; $S = \{C, G\}$).

Classe de positions : séquence Z de longueur n où $Z[i] \in \{0, 1\}$;
 $0 =$ riche en AT; $1 =$ riche en GC.

Caractère en position i dépend de $Z[i]$ seulement :

$$\mathbb{P}\left\{X[i] = x \mid Z[i] = z\right\} = p_z(x).$$

M. jannaschii : $p_0(S) = 0.22, p_1(S) = 0.66$

Segmentation : trouver Z à partir de X

Vraisemblance

Étant donné la séquence x :

- vraisemblance de z :

$$L(z) = \mathbb{P}\left\{X = x \mid Z = z\right\} = \prod_{i=1}^n p_{z[i]}(x[i]).$$

- log-vraisemblance

$$\begin{aligned}\ell(z) = \log L(z) &= \sum_{i=1}^n \log p_{z[i]}(x[i]) \\ &= \underbrace{\sum_{i=1}^n \log p_0(x[i])}_{\text{vrais. de l'hypo } Z = 0} + \underbrace{\sum_{i=1}^n \log \frac{p_{z[i]}(x[i])}{p_0(x[i])}}_{\text{LLR de l'hypo } z}.\end{aligned}$$

Problème : le z qui maximise $\ell(z)$ n'est pas utile : $z[i] = \operatorname{argmax}_z p_z(x[i])$
— trop de segments ($z[i] = 0$ si $x[i] = W$ et $z[i] = 1$ si $x[i] = S$)

Longueur de description

Comment choisir z ?

Principe de **longueur de description minimale** : le meilleur hypothèse est celui qui est le plus court à encoder (Rissanen 1983)

Encodage : données et modèle en même temps

Ici : encoder x et z :

$$\underbrace{001010 \dots 1}_{x \text{ encodé en binaire}} \# \underbrace{C(z)}_{z \text{ encodé}}$$

Encodage

Encoder x : codage optimale en utilisant z
– $\lg p_{z[i]}(x[i])$ bits pour encoder $x[i]$.

Comment ? Encodage Huffman de blocs de taille m

Exemple de l'avantage de Huffman : $p(W) = 0.75, p(S) = 0.25; m = 2$

$WW \rightarrow 0, WS \rightarrow 10, SW \rightarrow 110, SS \rightarrow 111$

Nombre de bits par bloc en moyenne : $\frac{9}{16} \cdot 1 + \frac{3}{16} \cdot 2 + \frac{3}{16} \cdot 3 + \frac{1}{16} \cdot 3 = \frac{27}{16}$,
donc 0.84 bits par caractère

Encodage — segmentation


Segmentation z — comment l'encoder ?

Il y a beaucoup moins de changements $z[i] \neq z[i - 1]$ que la longueur n de la séquence

Donc, on va juste donner la liste de *points de changement* ou $z[i] \neq z[i - 1]$

1 bit pour encoder $z[0]$

chaque point de changement encodé en $\lg(n - 1)$ bits (entier entre 2 et n)




Encodage de z avec k points de changements : $1 + k \lg(n - 1)$ bits

Encodage complète

Longueur de l'encodage complète x et z quand k points de changements :

$$\sum_{i=1}^n \left(-\lg p_{z[i]}(x[i]) \right) + k \lg n + O(1) = -\lg L(z) + k \lg n + O(1)$$

Le meilleur choix de z minimise cette longueur — c-à-d il maximise



Principe universel de sélection de modèles probabilistes :

balancer la complexité du modèle et son accord avec les données

Algorithme

But : trouver z qui maximise $\text{LLR}(z) - kh$

(car $\ell(z) = \ell(0) + \text{LLR}(z)$; $h = \log n$)

Notation : $w(i) = \log \frac{p_1(x[i])}{p_0(x[i])}$ donc $\text{LLR}(z) = \sum_{i: z[i]=1} w(i)$.


PD : $V_a(i)$ est le score de la meilleure segmentation de $1..i$ où $z[i] = a$.

$$\begin{aligned} V_0(i) &= \max\{V_0(i-1), V_1(i-1) - h\} & i > 1 \\ V_1(i) &= \max\{V_0(i-1) + w(i) - h, V_1(i-1) + w(i)\} & i > 1 \\ V_0(1) &= 0; V_1(1) = w(1) \end{aligned}$$

+ traceback sur les max

Modèle de Markov caché

Un autre modèle : Z est une chaîne de Markov



Chaîne de Markov :

- ensemble d'états Q
- probabilité initiale $\mu_q = \mathbb{P}\{z[1] = q\}$
- probabilités de transition $t_{q \rightarrow q'} = \mathbb{P}\{z[i+1] = q' \mid z[i] = q\}$

Probabilité *a priori* de la segmentation $z \in Q^n$

$$\mathbb{P}\{Z = z\} = \mu_{z[1]} \prod_{i=2}^n t_{z[i-1] \rightarrow z[i]}.$$

Modèle de Markov caché 2

Trouver la meilleure segmentation

$$\begin{aligned}\mathbb{P}\{Z = z \mid X = x\} &= \frac{\mathbb{P}\{Z = z; X = x\}}{\mathbb{P}\{X = x\}} \\ &= \frac{\mathbb{P}\{X = x \mid Z = z\} \mathbb{P}\{Z = z\}}{\mathbb{P}\{X = x\}} \\ &\propto L(z) \cdot P(z)\end{aligned}$$

Maintenant,

$$\mathbb{P}\{Z = z; X = x\} = \mu_{z[1]} p_{z[1]}(x[1]) \prod_{i=2}^n p_{z[i]}(x[i]) t_{z[i-1] \rightarrow z[i]}.$$

Modèle de Markov caché 3

Avec les logarithmes

$$\begin{aligned}\log \mathbb{P}\{Z = z; X = x\} &= \ell(0) + (n - 1) \log t_{0 \rightarrow 0} && // \text{constante} \\ &+ \sum_{i: z[i]=1} \left(\log \frac{p_1(x[i])}{p_0(x[i])} + \log \frac{t_{1 \rightarrow 1}}{t_{0 \rightarrow 0}} \right) && // \sum_i w(i) \\ &+ \sum_{i: z[i]=1; z[i-1]=0} \log \frac{t_{0 \rightarrow 1}}{t_{1 \rightarrow 1}} && // k_1 h_1 \\ &+ \sum_{i: z[i]=0; z[i-1]=1} \log \frac{t_{1 \rightarrow 0}}{t_{0 \rightarrow 0}} && // k_0 h_0\end{aligned}$$

Donc, il faut maximiser une expression de genre $\sum_{i: z[i]=1} w(i) - k_1 h_1 - k_0 h_0$ où k_j est le nombre de positions i avec $z[i] = j$ et $z[i-1] = 1 - j$.

— presque le même problème qu'avant.

Segmentation postérieure

Au lieu de trouver z de probabilité maximale, trouver j avec $\mathbb{P}\{Z[i] = j \mid X = x\}$ maximale en chaque position $i = 1, \dots, n$.

Méthode :

prob. préfixe $\alpha_j(i) = \mathbb{P}\{Z[i] = j; X[1..i] = x[1..i]\}$

prob. suffixe $\beta_j(i) = \mathbb{P}\{Z[i] = j; X[i + 1..n] = x[i + 1..n]\}$.

Alors

$$\delta_j(i) = \mathbb{P}\{Z[i] = j \mid X = x\} = \frac{\alpha_j(i)\beta_j(i)}{\sum_{j \in Q} \alpha_j(i)\beta_j(i)}.$$

Segmentation postérieure 2

Probabilités préfixe

$$\begin{aligned}\alpha_j(1) &= \mu_j p_j(x[1]) \\ \alpha_j(i) &= \left(\sum_{j' \in Q} \alpha_{j'}(i-1) t_{j' \rightarrow j} \right) p_j(x[i]) \quad i > 1\end{aligned}$$

Probabilités suffixe

$$\begin{aligned}\beta_j(n) &= 1 \\ \beta_j(i) &= \sum_{j' \in Q} t_{j \rightarrow j'} p_{j'}(x[i+1]) \beta_{j'}(i+1) \quad i < n\end{aligned}$$

Aspects pratiques

Pbl : probabilités deviennent très petites, précision double (double de Java) ne permet que 10^{-307}

Solution : travailler explicitement avec des paires de mantisse-exponent (double, int)

Pbl : trop de mémoire (au moins $12n|Q|$ octets)

Solution : couper la séquence en blocs de taille $B = \sqrt{n}$ — checkpoints

1. de droite à gauche : calculer tous les $\beta_j(i)$ et les stocker pour $i = B + 1, 2B + 1, 3B + 1, \dots$
2. de gauche à droite : calculer tous les $\alpha_j(i)$; en arrivant au début de bloc k calculer d'abord $\beta_j(i)$ pour $i = kB + 1..(k + 1)B$

Usage de mémoire : $O(\sqrt{n}|Q|)$

Apprentissage de paramètres

Approche I. calculer la meilleure segmentation (Viterbi)

$$\hat{t}_{j \rightarrow j'} = \frac{\sum_{i=2}^n \{z[i] = j'; z[i-1] = j\}}{\sum_{i=2}^n \{z[i-1] = j\}}$$
$$\hat{p}_j(a) = \frac{\sum_{i=1}^n \{x[i] = a; z[i] = j\}}{\sum_{i=1}^n \{z[i] = j\}}.$$

Refaire la segmentation, recalculer les paramètres, etc.

Approche II. (Baum-Welch) calculer les probabilités postérieures


$$\hat{t}_{j \rightarrow j'} = \frac{\sum_{i=2}^n \delta_{j' \rightarrow j}(i)}{\sum_{i=2}^n \sum_{j \in Q} \delta_{j' \rightarrow j}(i)}$$
$$\hat{p}_j(a) = \frac{\sum_{i=1}^n \delta_j(i) \{x[i] = a\}}{\sum_{i=1}^n \{x[i] = n\} \sum_{j \in Q} \delta_j(i)}$$

où $\delta_{j' \rightarrow j}(i) = \alpha_{j'}(i-1)t_{j' \rightarrow j}p_j(x[i])\beta_j(i)$. Refaire la segmentation, recalculer les paramètres, etc.

Machine d'alignement

HMM : émission de caractères (a, b) où $a, b \in \{A, G, T, C, -\}$ (sauf $a = b = -$)

états : M («match»), I (insertion), D (suppression), transitions probabilistes t



Knudsen & Miyamoto *J. Mol. Biol.* 333 : 453 (2003)

Machine 2

Émission d'appariements en chaque état : une série d'émissions donne l'alignement : probabilités p_M , p_I , p_D .

Problème : trouver le meilleur alignement global de deux séquences S et T .

Sous-problèmes pour programmation dynamique : $M(i, j)$, $D(i, j)$, $I(i, j)$ score de l'alignement des préfixes si on finit en état M , I , ou D .


Récurrentes

$$\begin{aligned}M(i, j) &= p_M \left[\frac{S[i-1]}{T[j-1]} \right] \cdot \max \left\{ M(i-1, j-1)t(M \rightarrow M), \right. \\ &\quad \left. D(i-1, j-1)t(D \rightarrow M), I(i-1, j-1)t(I \rightarrow M) \right\} \\ D(i, j) &= p_D \left[\frac{-}{T[j-1]} \right] \cdot \max \left\{ M(i, j-1)t(M \rightarrow D), \right. \\ &\quad \left. D(i, j-1)t(D \rightarrow D), I(i, j-1)t(I \rightarrow D) \right\} \\ I(i, j) &= p_I \left[\frac{S[i-1]}{-} \right] \cdot \max \left\{ M(i-1, j)t(M \rightarrow I), \right. \\ &\quad \left. D(i-1, j)t(D \rightarrow I), I(i-1, j)t(I \rightarrow I) \right\}.\end{aligned}$$

+initialisation quand $i = 0$ ou $j = 0 \dots$

Si on regarde les **log** de ces vraisemblances d'alignements, on arrive à une pondération de trous linéaire+pondération de substitutions linéaire +coûts de substitutions comme avant


Probabilité postérieure



Lunter & al (2005)

Phylogenetic shadowing

Comparaison de séquences entre des espèces proches :
modèles d'évolution rapide/lente (HMM)



Boffelli & al. *Science* 299 :1391 (2003)