

Structure d'ARN

20 novembre 2023 09:04

Entrée: séquence S d'ARN $\Sigma = \{A, C, G, U\}$

$P = \text{paires de nucléotides appariables}$ (liste)

Sortie: liste A de paires de nucléotides,

appelés appariements,


tels que

pour tous $(s_i, t_i), (s_j, t_j) \in A$ distincts,

on a

$$s_i < s_j < t_i \Rightarrow s_i < t_j < t_i$$

ex:

$S = a c c u g a g$  $P = \{\{a, u\}, \{c, g\}\}$

Algo de Nussinov (1978)



- Par prog. dynamique

$M[i, j] = \# \text{ d'appariements maximum possible dans } S[i:j]$


• Cas de base


$$M[i, i] = 0 \quad \forall i = 1, \dots, n \quad n = |S|$$

• Récurrence: $\forall i < j$

$$M[i, j] = \max \begin{cases} M[i+1, j] \\ \max_{i < k \leq j} (M[i+1, k-1] + M[k+1, j] + \delta_{i,k}) \end{cases}$$

Cas possibles pour sol. opt. sur $S[i:j]$

① i est non apparié,
il suffit d'optimiser sur $S[i+1, j]$ 
 $\rightarrow \text{cas } ① \Rightarrow M[i+1, j]$

② i est apparié avec un certain $S[k]$, où 



On ne connaît pas ce k , alors on les essaie tous

$$\text{Cas } ② \rightarrow \max_{i < k \leq j} (M[i+1, k-1] + M[k+1, j] + \delta_{i,k})$$

$$\text{où } \delta_{i,k} = \begin{cases} 1 & \text{si } \{S[i], S[k]\} \in P \\ -\infty & \text{sinon} \end{cases}$$

align. global

Nussinov



$S = a c a g u n c a$
1 2 3 4 5 6 7

$S = \text{acagucg}$

	1	2	3	4	5	6	7
i	a	c	a	g	u	c	g
j	a	c	a	g	u	c	g
1	o	o	o	o	o	o	o
2	o	o	o	o	o	o	o
3	o	o	o	o	o	o	o
4	o	o	o	o	o	o	o
5	o	o	o	o	o	o	o
6	o	o	o	o	o	o	o
7	o	o	o	o	o	o	o

$$i=6 \quad j=7$$

$$i \quad j=k$$

$$c \quad g$$

$$M[i+1, j-1] + M[j+1, j] + 1$$

On calcule $M[i, j]$ récursivement

global M (init None partout)

nussinov(S, i, j)

```

    si  $i \geq j$ , return 0
    si  $M[i, j] \neq \text{None}$ , return  $M[i, j]$ 
     $m_1 = \text{nussinov}(i+1, j) // M[i+1, j]$ 
     $m_2 = -\infty$ 
    pour  $k = i+1, \dots, j$ 
         $m_2 = \max(m_2, \text{nussinov}(i+1, k-1) +
                    \text{nussinov}(k+1, j) + d_{i,k})$ 
     $M[i, j] = \max(m_1, m_2)$ 
    return  $M[i, j]$ 

```

$O(n)$
tours

Appel initial avec $\text{nussinov}(1, n)$ pour calculer $M[1, n]$

Complexité: # d'entrées $M[i, j]$ \times temps par entrée

$$O(n^2) \times O(n)$$

$\sim n$ choix pour i
 $\sim n$ choix pour j


$$\rightarrow O(n^2 \cdot n) = O(n^3)$$

exo: reconstruire une liste concrète à partir de M .

Comment dessiner une structure 2D d'appariements

↳ on nous donne les appariements A



on doit dessiner la structure



a a c g s a c c u a c g u g u s a c c u u



Les conditions de non-croisement permettent de construire un arbre d'appariements.

Nœuds = appar. A_i parent de A_j si A_j est "emboîté" dans A_i.



A savoir : comment construire l'arbre


- Note : il se peut qu'il y ait plusieurs racines.



Dans ce cas, on met une racine "virtuelle"

Predictions de sous-structures

- Sous-structures possibles sur un ARN (sans pseudo-nœuds / croisements)




③ Tige-boucle T

Appariement avec aucun autre

① Empilement E

Deux appariements consécutifs



Appariements (i,j) (i+1,j+1)

② Boucle interne B


Deux appariements consécutifs, mais avec des nucl. non-appariés sur le chemin.

Appariement avec aucun autre entre



(i, j) avec aucun
 (i', j') tel que
 $i < i' < j' < j$


mais avec des nucl. non-appariés sur le chemin.



Appariements (i, j) (i', j') avec
 $i < i' < j' < j$ et $\{i', j'\} \neq \{i+1, j-1\}$

④ Multi-boucle M

Sous-structure de branchement



Suite d'appariements

$(i_1, j_1), (i_1, j_1), (i_2, j_2), \dots, (i_k, j_k)$

telle que $i < i_1 < j_1 < i_2 < j_2 < \dots < i_k < j_k < j$

Entrée: séquence d'ARN S ,

fonction e de coûts des sous-structures

<0 $eE(i, j)$ = coût d'empilement à (i, j)

>0 $eB(i, j, i', j')$ = coût d'une boucle $i \boxed{\quad} j$

>0 $eT(i, j)$ = coût de tige-boucle

>0 $eM(i, j, i_1, j_1, \dots, i_k, j_k)$ = coût de multi-boucle

Sortie: liste d'appariements dont la structure 2D minimise la somme des coûts des sous-structures

Par prog. dynamique

$M[i, j]$ = coût min. en énergie pour $S[i..j]$
avec la contrainte que $(i..j)$ soient appariées



On cherche $M[1, n]$?

Non

On cherche $\min_{1 \leq i \leq j \leq n} M[i, j]$



Cas de base: $i=j$

$$M[i, i] = \infty$$

Réurrence: $i < j$




On liste les cas possibles, on prend le min

Cas ①: E , i, j sont le départ d'un empilement

: $i+1 \dots$


Cas ①: E , i, j sont le départ d'un empilement



$$\text{cout: } eE(i, j) + M[i+1, j-1]$$

$O(1)$

Cas ②: B , i, j sont le départ d'une boucle




On prend i', j' optimal qui ferme la boucle

$$\text{cout: } \min_{i' < i' < j' < j} (eB(i, j, i', j') + M[i', j'])$$

$O(n^2)$


Cas ③: T , i, j = tige-boucle



$$\text{cout: } eT(i, j)$$

$O(1)$

Cas ④: M , i, j sont le début d'une multi-boucle



On essaie toutes les façons d'avoir cette multi-boucle

$$\min_{\substack{i < i_1 < j_1 < i_2 < j_2 < \dots < i_k < j_k < j}} (eM(i, j, i_1, j_1, \dots, i_k, j_k) + \sum_{l=1}^k M[i_l, j_l])$$

$$\text{On prend } M[i, j] = \min$$

(1)
(2)
(3)
(4)

Nombre de cas à énumérer pour un k donné
 $= O(n^{2k})$

$$\text{ex: } k=2 \rightarrow n \cdot n \cdot n \cdot n = n^4$$

$$\text{ex: } k=3 \rightarrow n \cdot n \cdot n \cdot n \cdot n = n^6$$

$$\rightarrow \sum_{k=1}^{n/2} n^{2k} \text{ cas à évaluer}$$

Complexité: horrible

dominée par ④

$\hookrightarrow O(n^{2k})$ avec $k = \text{nb de branchements permis}$

Souvent, on prend $k=2, 3$