

INTRODUCTION À LA PRÉDICTION DE STRUCTURES D'ARN

Manuel Lafond, Université de Sherbrooke

□ Vous vous rappelez que l'ADN est transcrit en ARN.

□ Structure de l'ADN = double-hélice



□ Structure de l'ARN = ???

□ Vous vous rappelez que l'ADN est transcrit en ARN.

□ Structure de l'ADN = double-hélice



□ Structure de l'ARN = ???

▣ ADN = alphabet A,C,G,T

▣ ARN = alphabet A,C,G,U

□ Vous vous rappelez que l'ADN est transcrit en ARN.

□ Structure de l'ADN = double-hélice



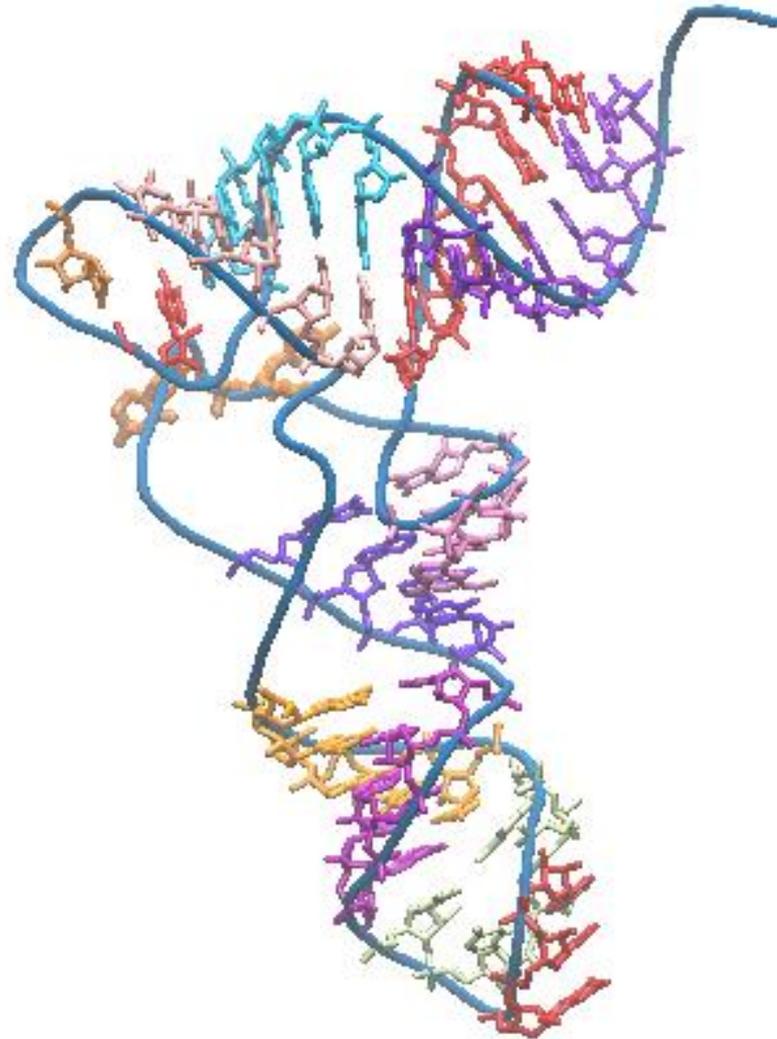
□ Structure de l'ARN = ???

▣ ADN = alphabet A,C,G,T

▣ ARN = alphabet A,C,G,U

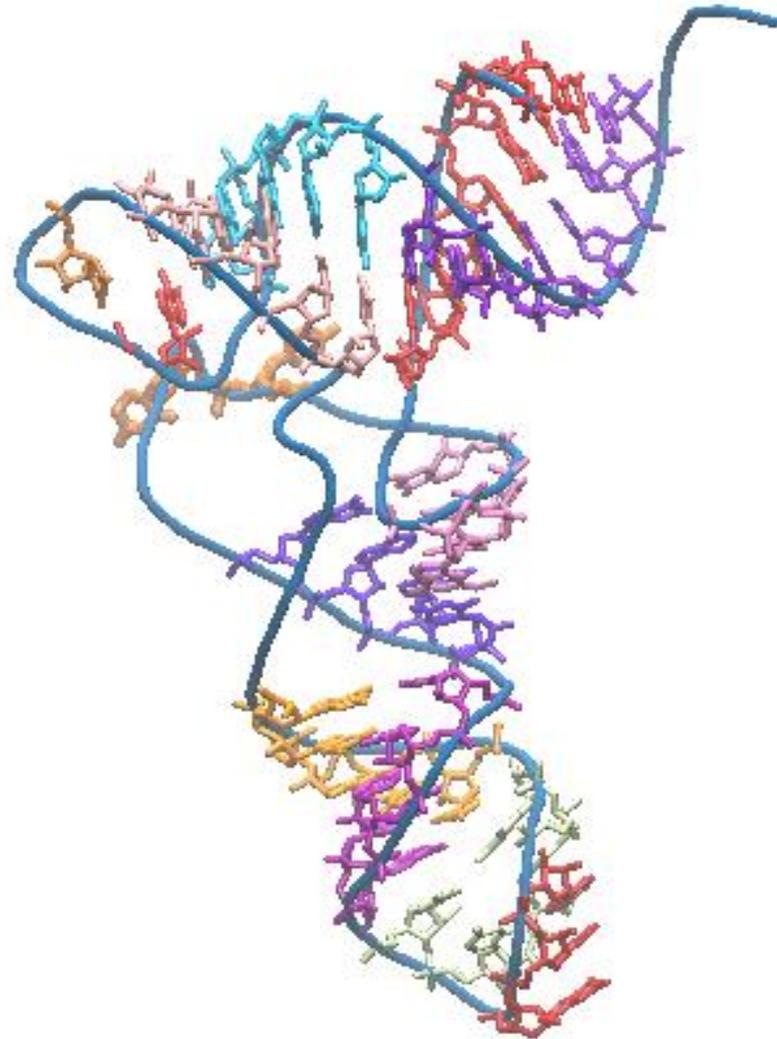
▣ La structure dépend beaucoup de la séquence

▣ Chaque nucléotide (A,C,G,U) veut s'apparier.

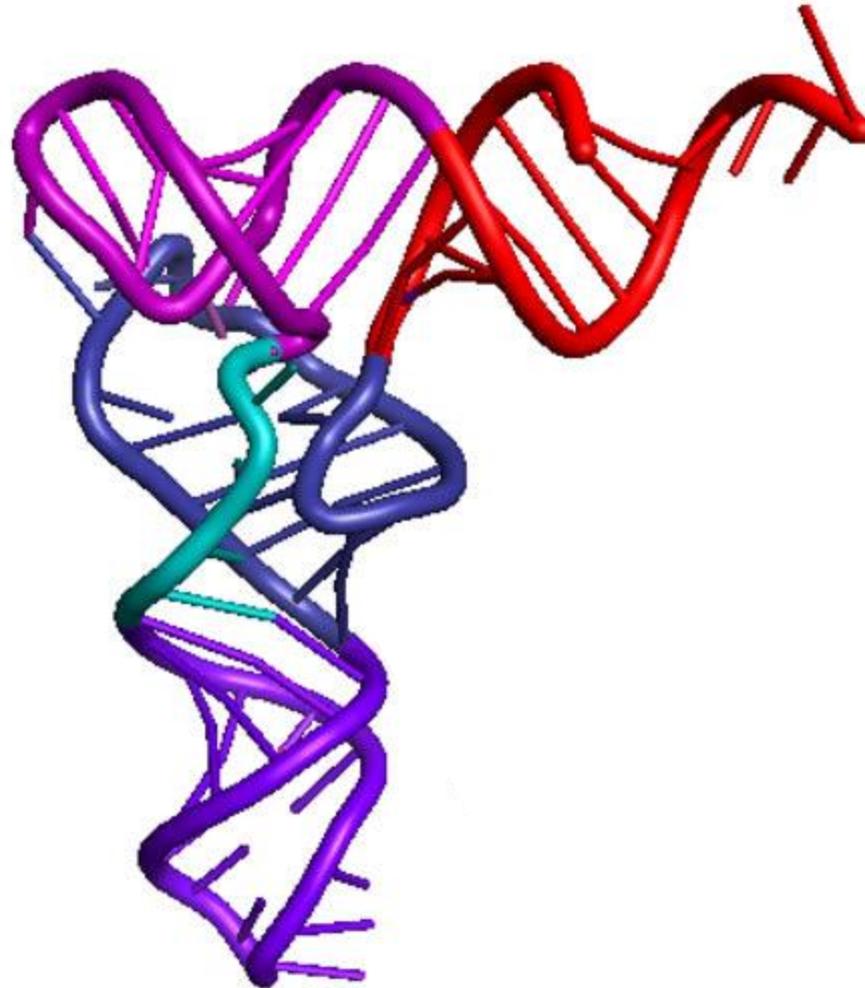


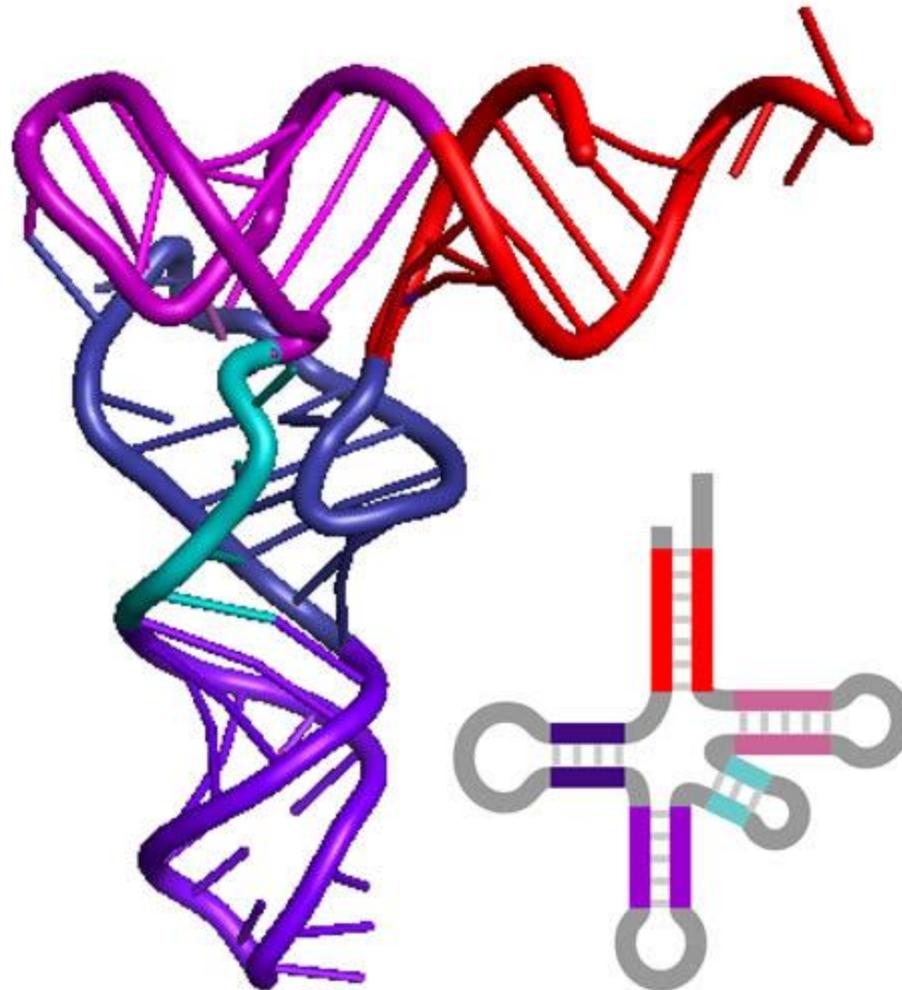
Source: <http://lowelab.ucsc.edu/tRNAscan-SE/image/3D-tRNA-lowelab.png>

- ADN => 2 brins => chaque nucléotide déjà apparié
- ARN => 1 brin => recherche d'"auto-appariements"

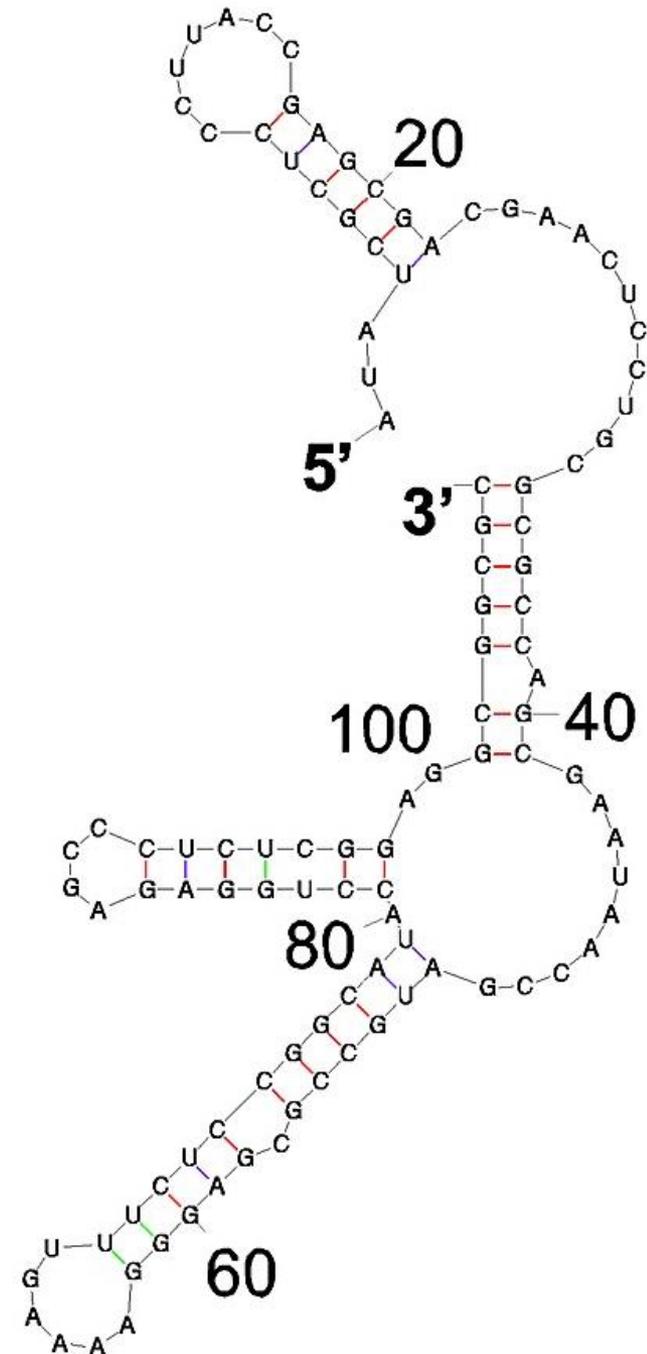


Source: <http://lowelab.ucsc.edu/tRNAscan-SE/image/3D-tRNA-lowelab.png>

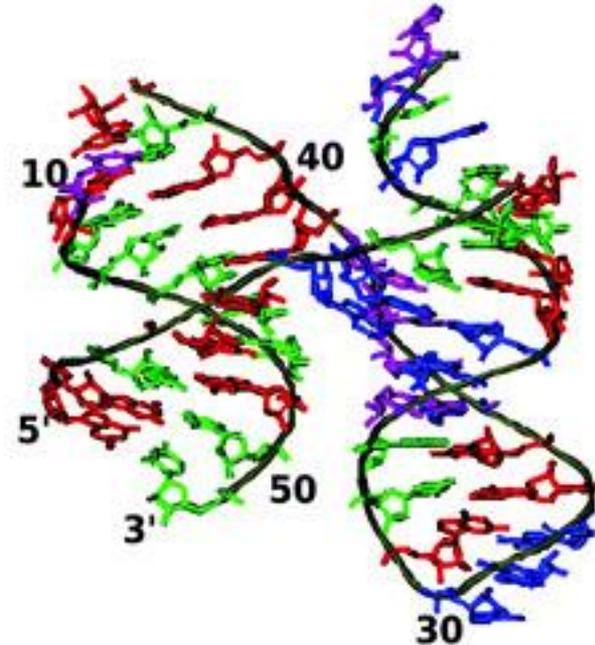
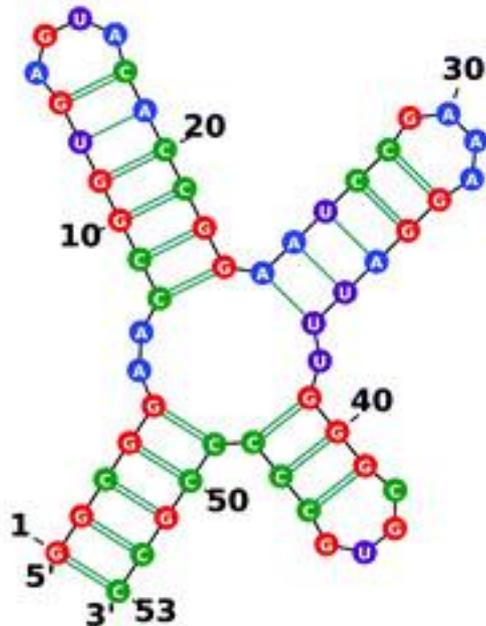




- La structure 2D sert à montrer les appariements.
- Les sous-structures de la représentation informent (parfois) sur la fonction de l'ARN.
- Non-appariement = énergie libre (à combler)

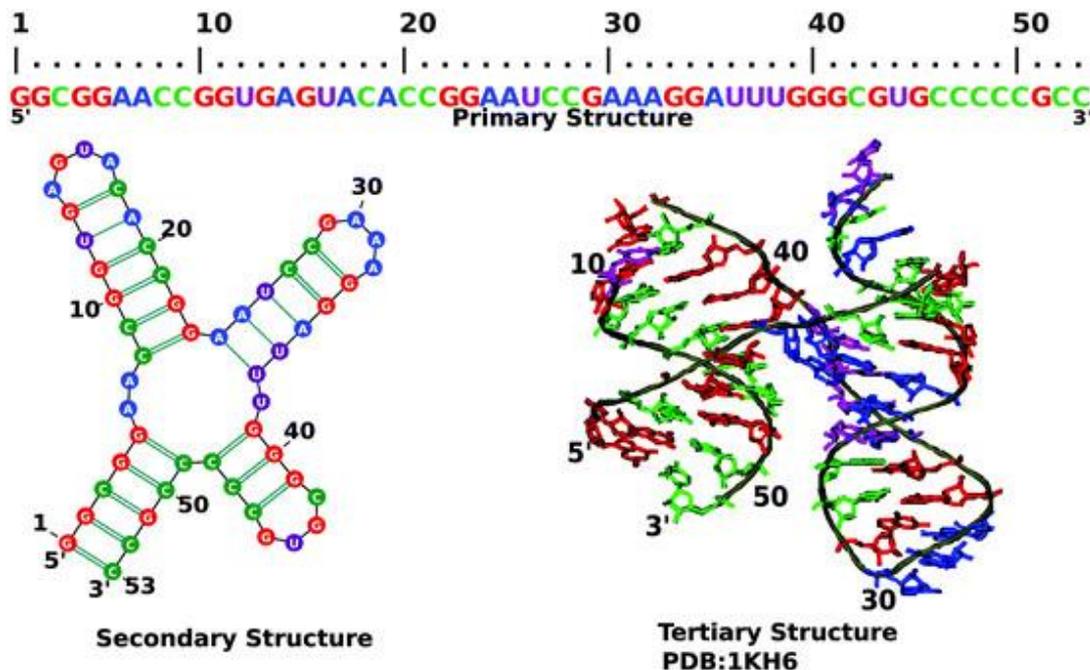


Structures de l'ARN



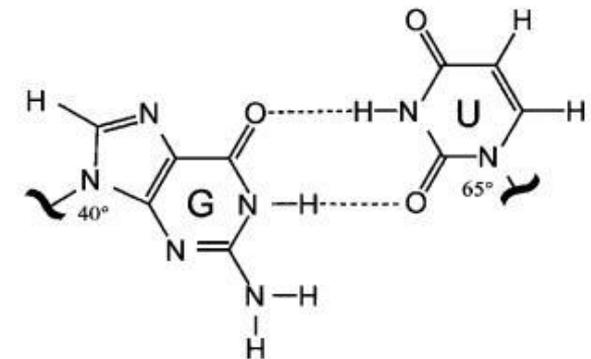
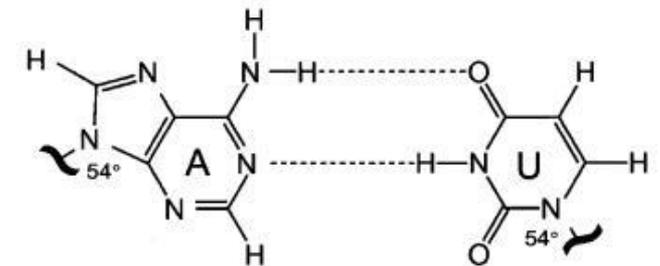
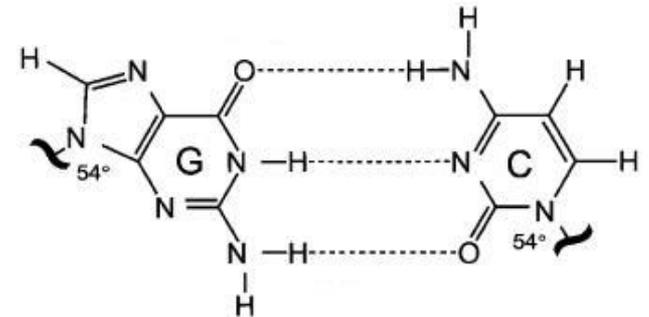
Structures de l'ARN

- Structure primaire: la séquence (1D)
- Structure secondaire: paires de bases appariées (2D)
- Structure tertiaire: représentation (3D)



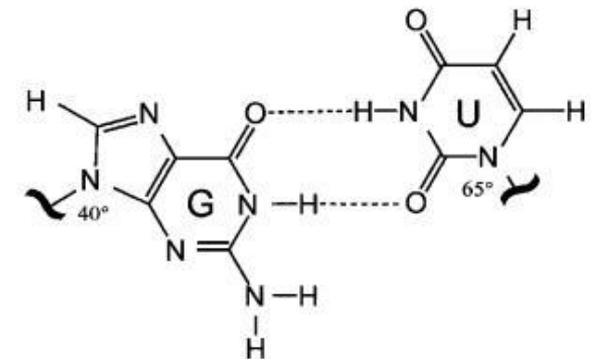
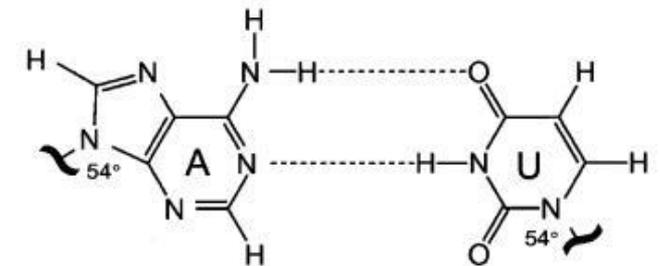
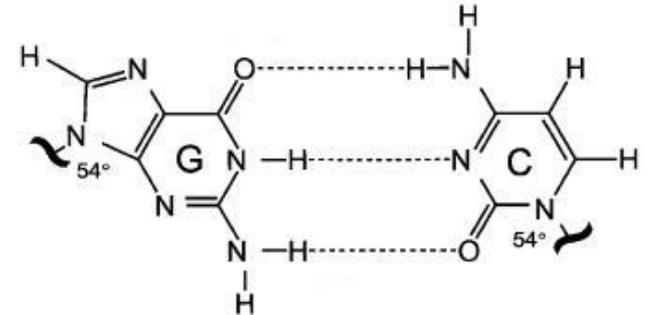
Qui se ressemble s'apparie

- Paire de bases = deux nucléotides appariés
- Appariements canoniques
 - ▣ G - C
 - ▣ A - U
- Appariement "wobble"
 - ▣ G - U
- Autres appariements possibles, mais rares.



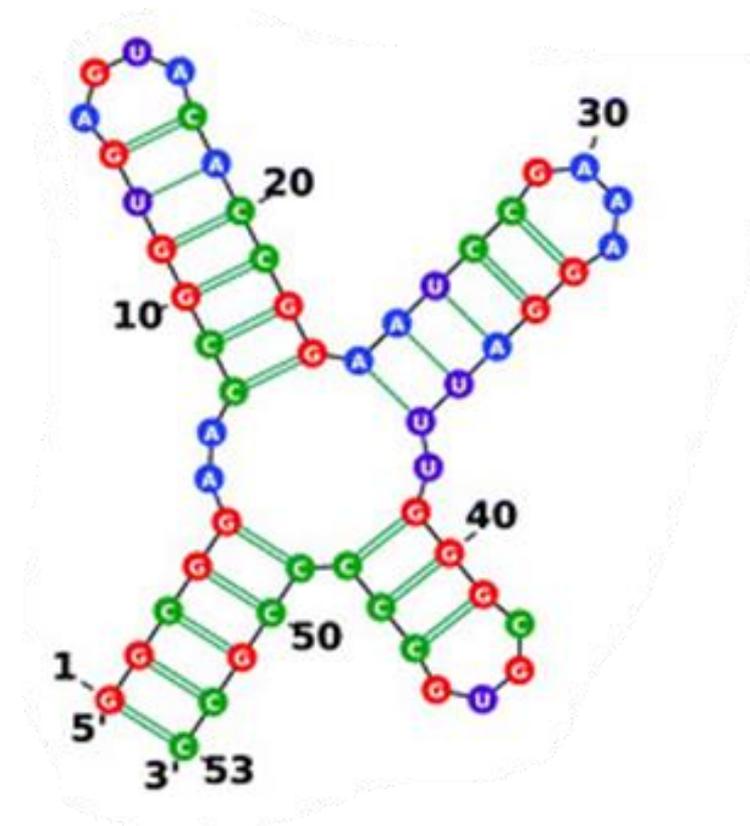
Qui se ressemble s'apparie

- Pour nos fins, appariements possibles
 - ▣ G - C
 - ▣ A - U
 - ▣ G - U
- Possiblement avec poids différent.



Qui se ressemble s'apparie

- Pour nos fins, appariements possibles
 - ▣ G - C
 - ▣ A - U
 - ▣ G - U
- Possiblement avec poids différent.



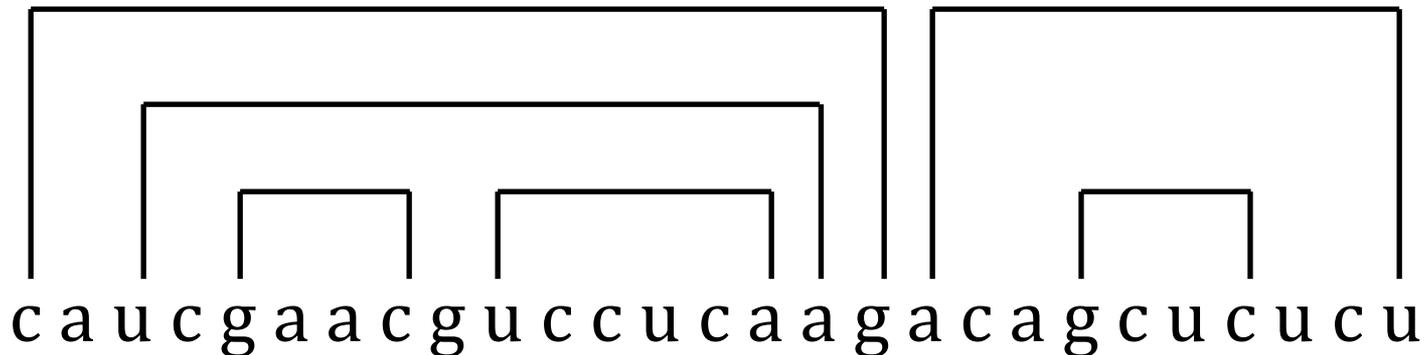
Modélisation du problème

- Entrée: séquence S d'ARN
- Sortie: liste des paires de positions
 $(s_1, t_1), (s_2, t_2), \dots, (s_k, t_k)$ des paires de bases.

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

Modélisation du problème

- Entrée: séquence S d'ARN
- Sortie: liste des paires de positions
 $(s_1, t_1), (s_2, t_2), \dots, (s_k, t_k)$ des paires de bases.

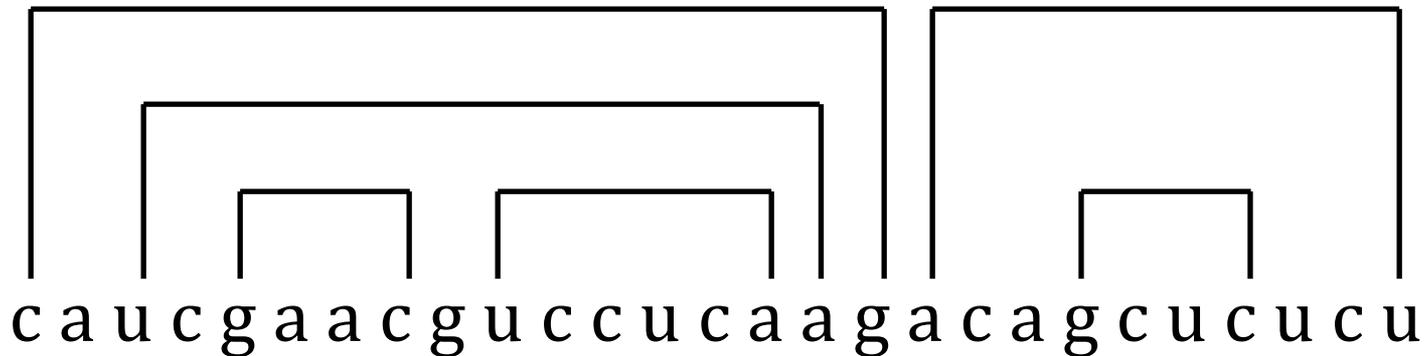


Modélisation du problème

- Entrée: séquence S d'ARN
- Sortie: liste des paires de positions
 $(s_1, t_1), (s_2, t_2), \dots, (s_k, t_k)$ des paires de bases.
- Nucléotide non-apparié = énergie libre
- **Hypothèse 0**: l'ARN va se replier de façon à minimiser l'énergie libre.
 - => l'ARN a tendance à maximiser les appariements

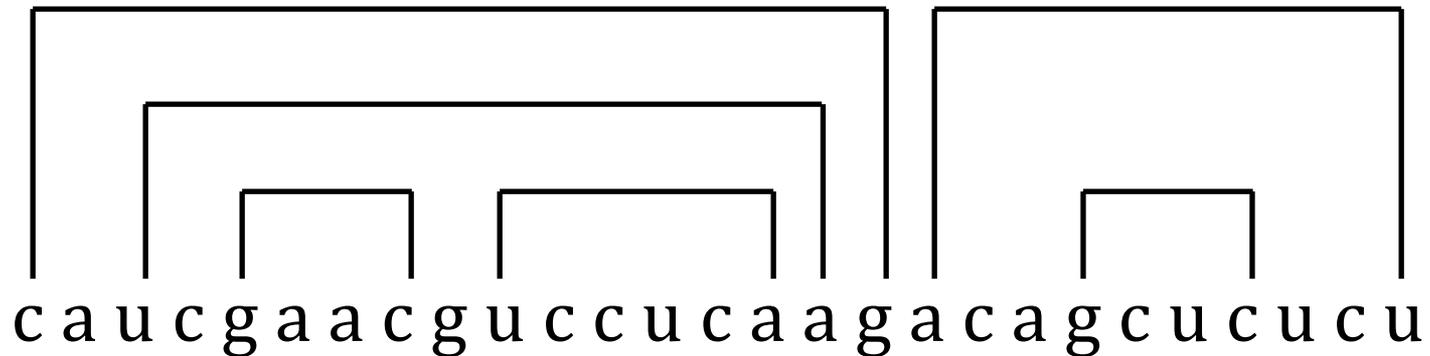
Modélisation du problème

- Nucléotide non-apparié = énergie libre
- **Hypothèse 0**: l'ARN va se replier de façon à minimiser l'énergie libre.
 - => l'ARN a tendance à maximiser les appariements



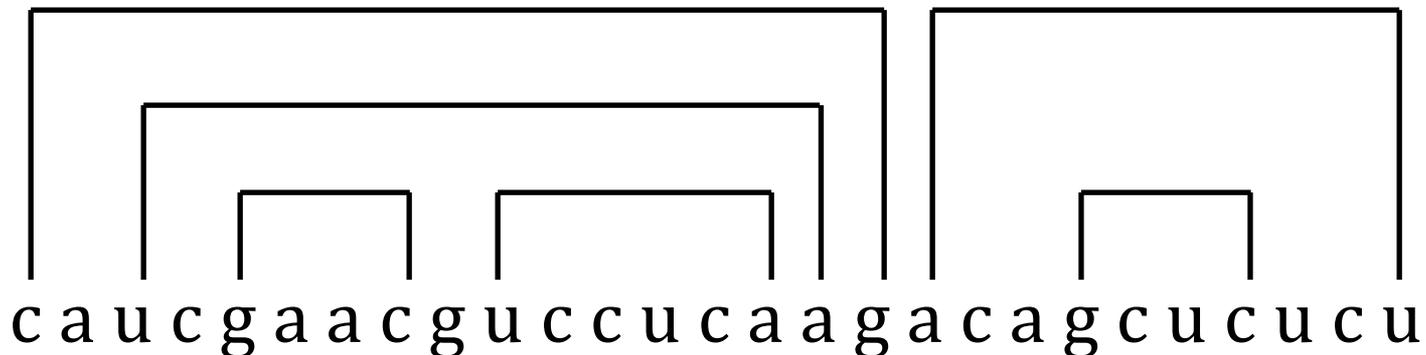
Modélisation du problème

- **Hypothèse 1**: chaque nucléotide est apparié 0 ou 1 fois.



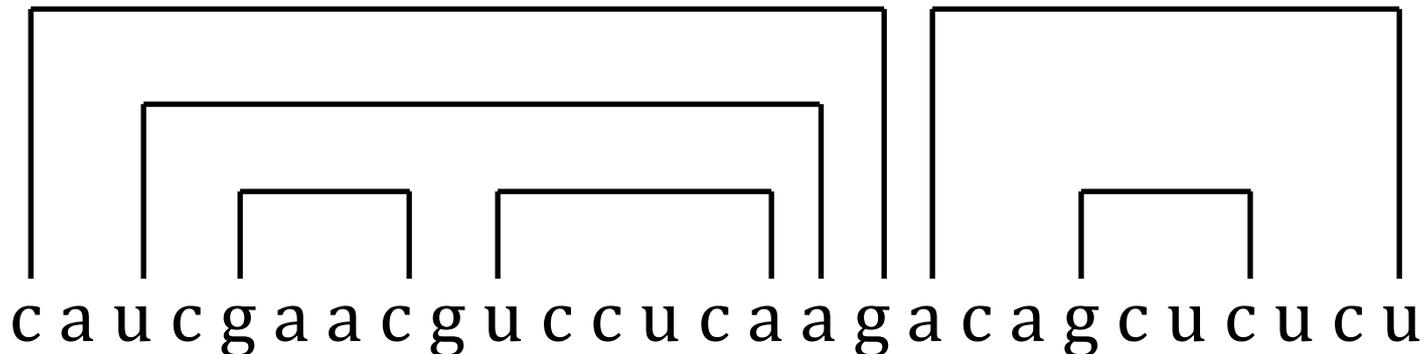
Modélisation du problème

- **Hypothèse 1**: chaque nucléotide est apparié 0 ou 1 fois.
- **Hypothèse 2**: les appariements se font de façon "planaire" dans l'espace
 - Pas de croisement entre les appariements



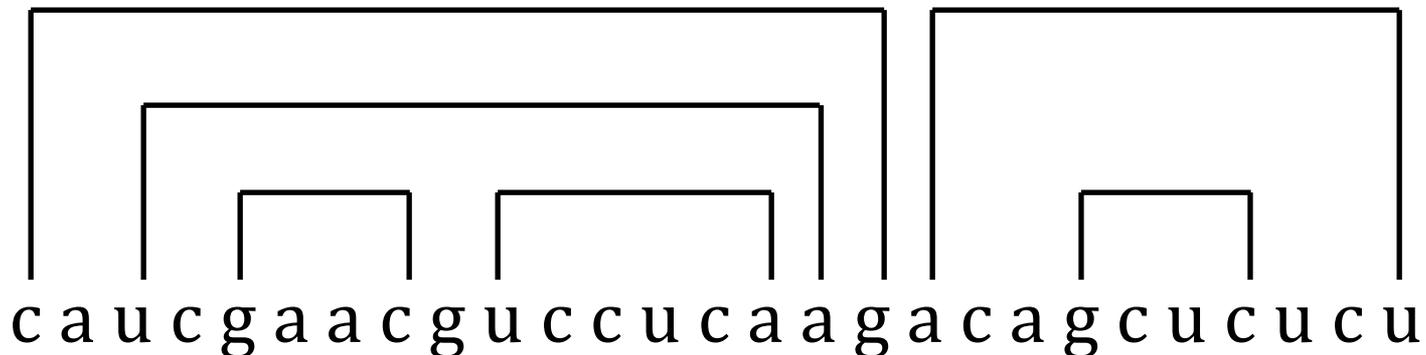
Modélisation du problème

- **Hypothèse 1**: chaque nucléotide est apparié 0 ou 1 fois.
 - ▣ *Pas toujours vrai (triplets de bases existent)*
- **Hypothèse 2**: les appariements se font de façon "planaire" dans l'espace
 - ▣ Pas de croisement entre les appariements
 - ▣ *Pas toujours vrai (croisement = pseudo-noeud)*



Modélisation du problème

- **Hypothèse 1**: chaque nucléotide est apparié 0 ou 1 fois.
- **Hypothèse 2**: les appariements se font de façon "planaire" dans l'espace
 - Pas de croisement entre les appariements

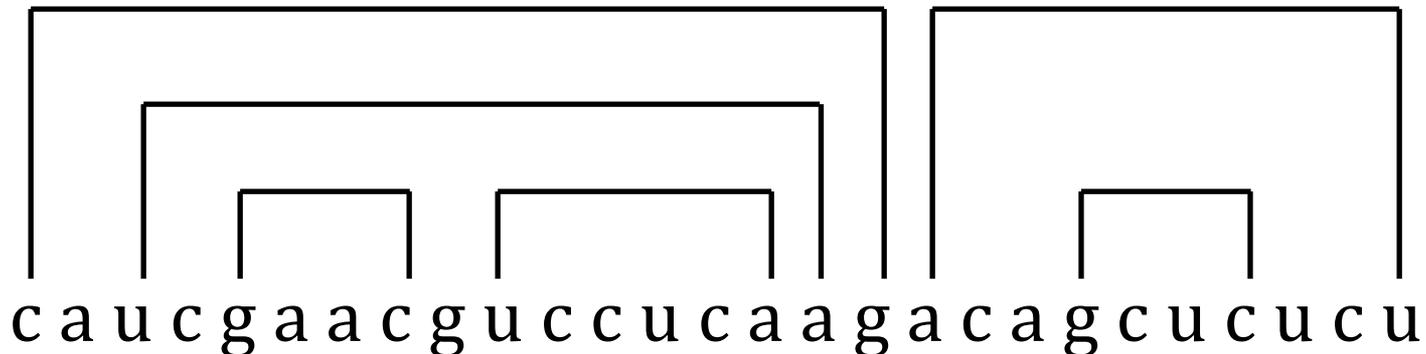


Modélisation du problème

- L'hypothèse du non-croisement donne une condition d'emboîtement sur les appariements

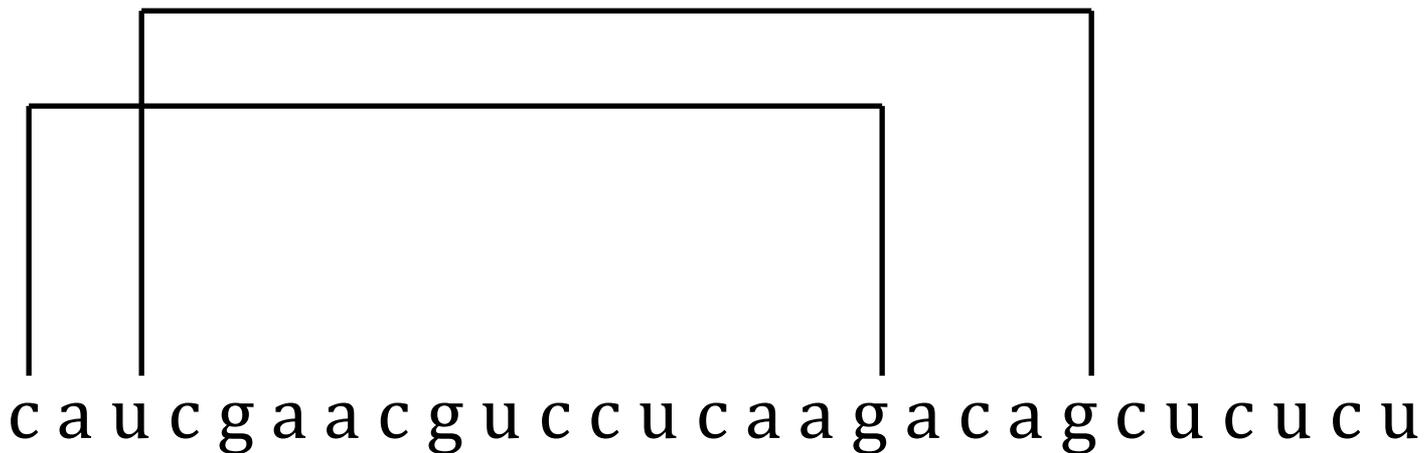
$$A = \{ (s_1, t_1), (s_2, t_2), \dots, (s_k, t_k) \}$$

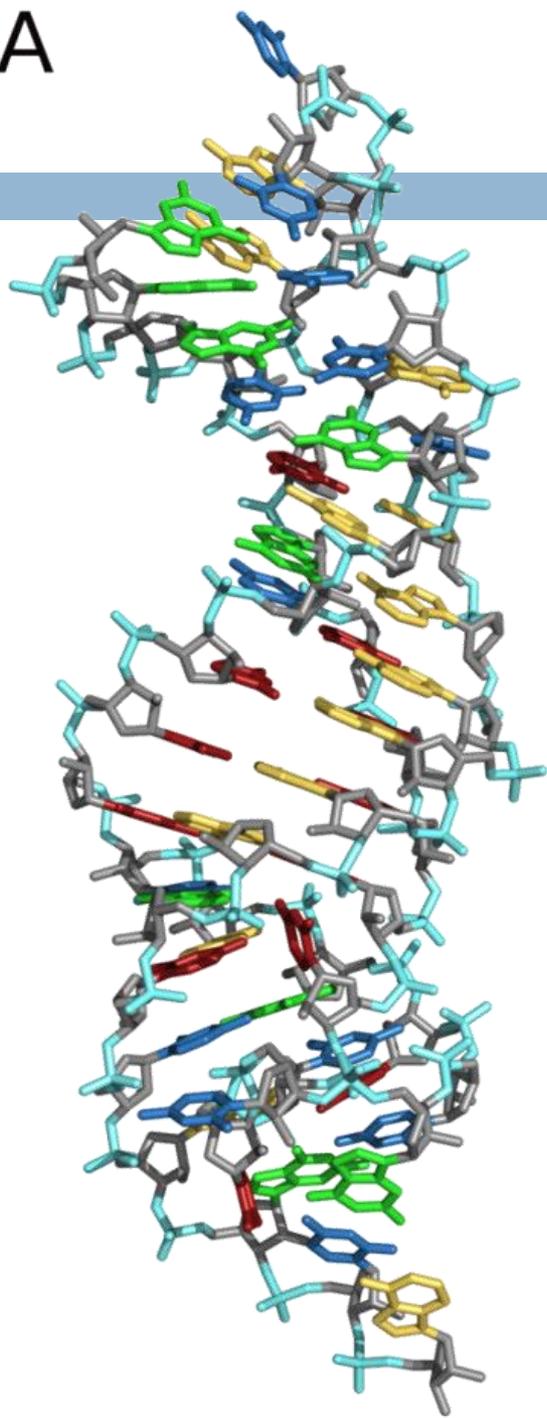
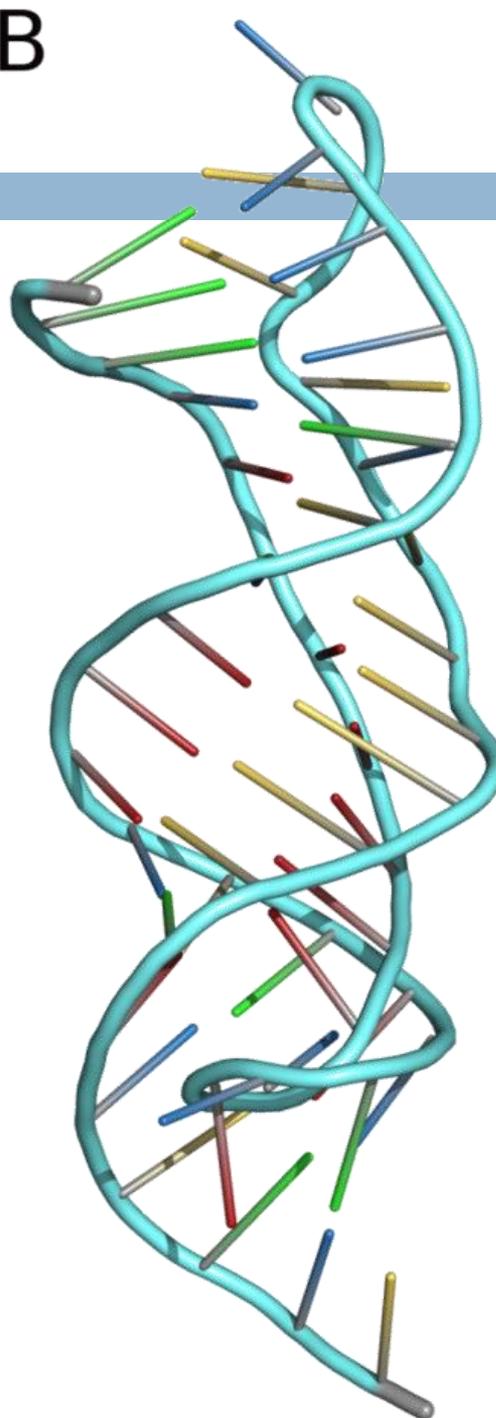
- Pour tout (s_i, t_i) et (s_j, t_j) dans A , on a $s_i < s_j < t_i$ si et seulement si $s_i < t_j < t_i$



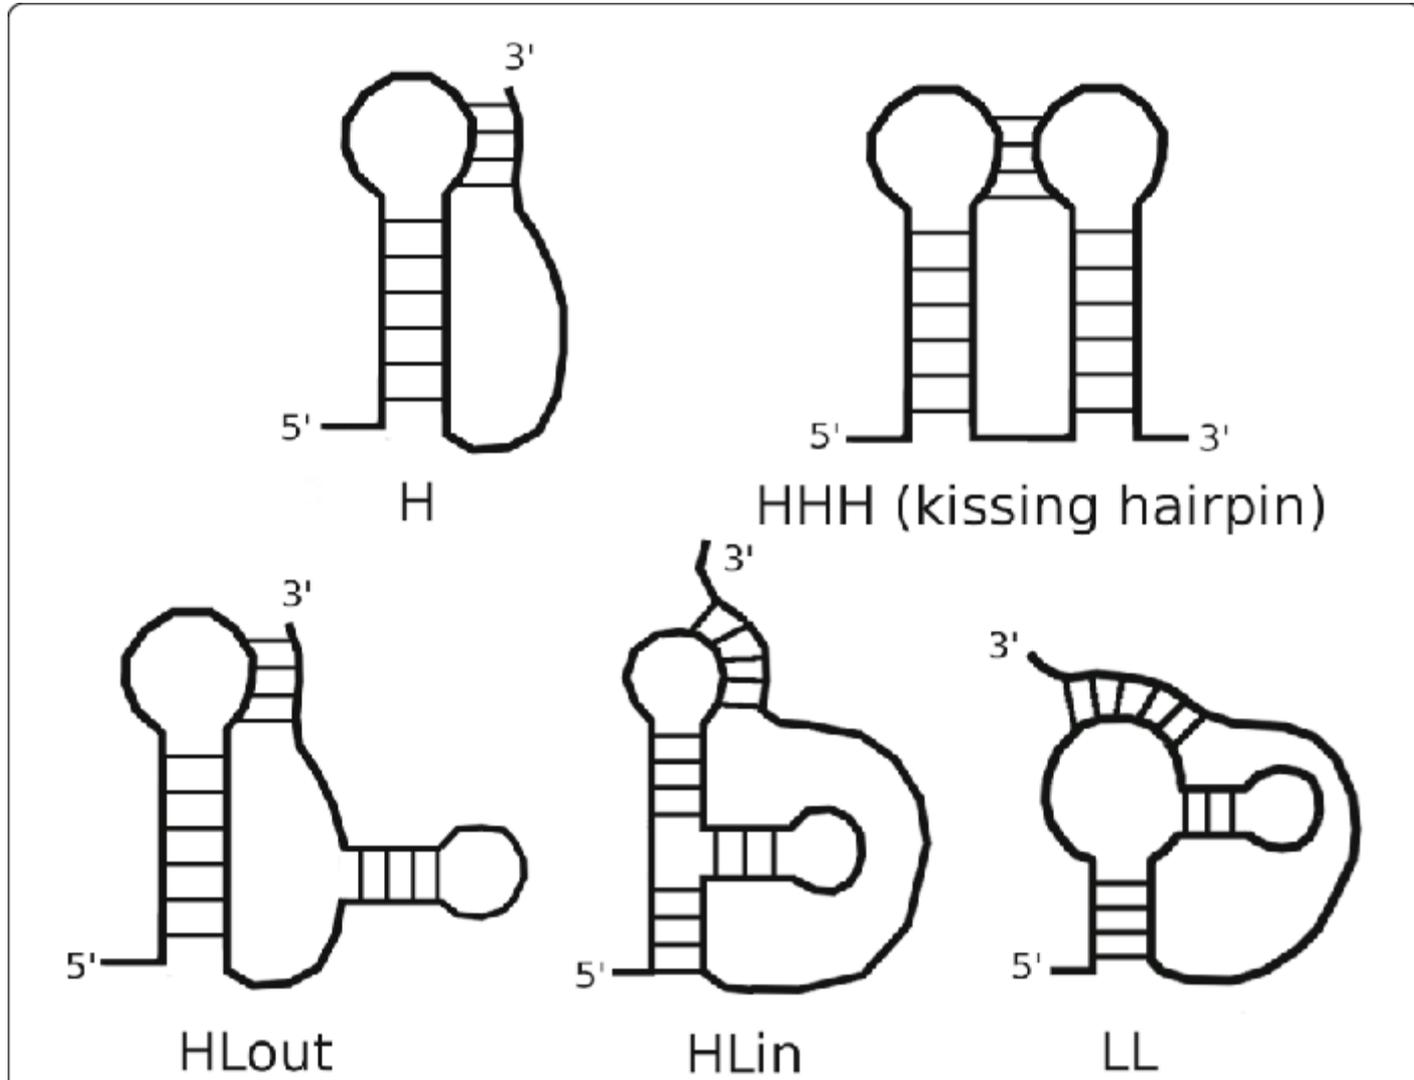
Modélisation du problème

- Pour tout (s_i, t_i) et (s_j, t_j) dans A , on a $s_i < s_j < t_i$ si et seulement si $s_i < t_j < t_i$
- Si cette condition n'est pas respectée, on a ce qu'on appelle un *pseudo-noeud*.



A**B**

Pseudo-noeuds

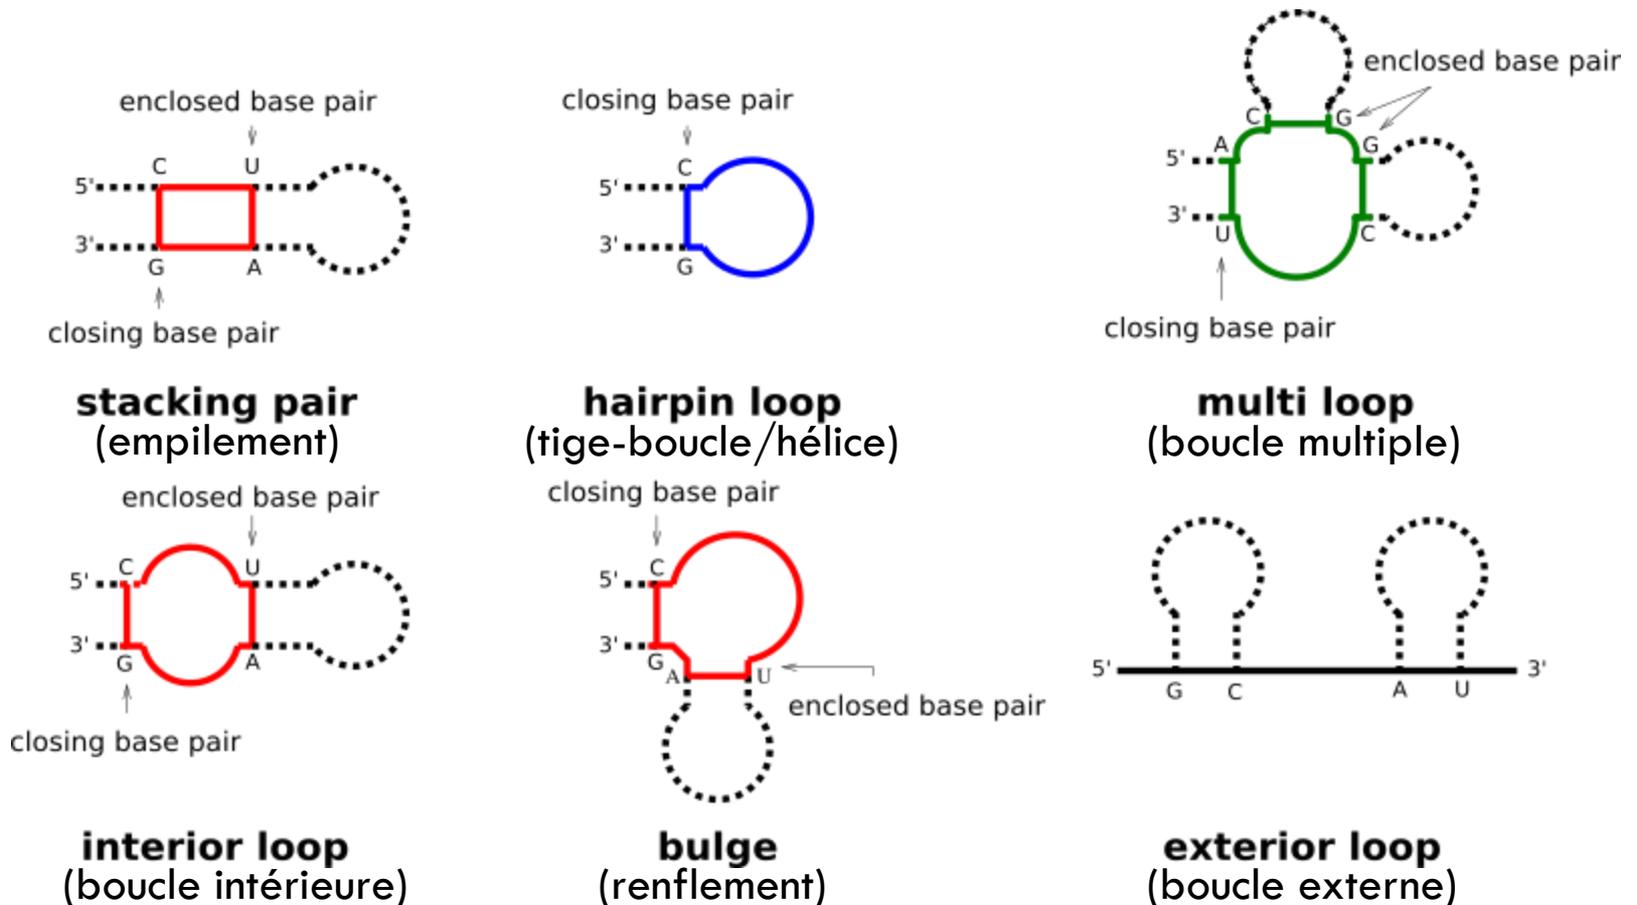


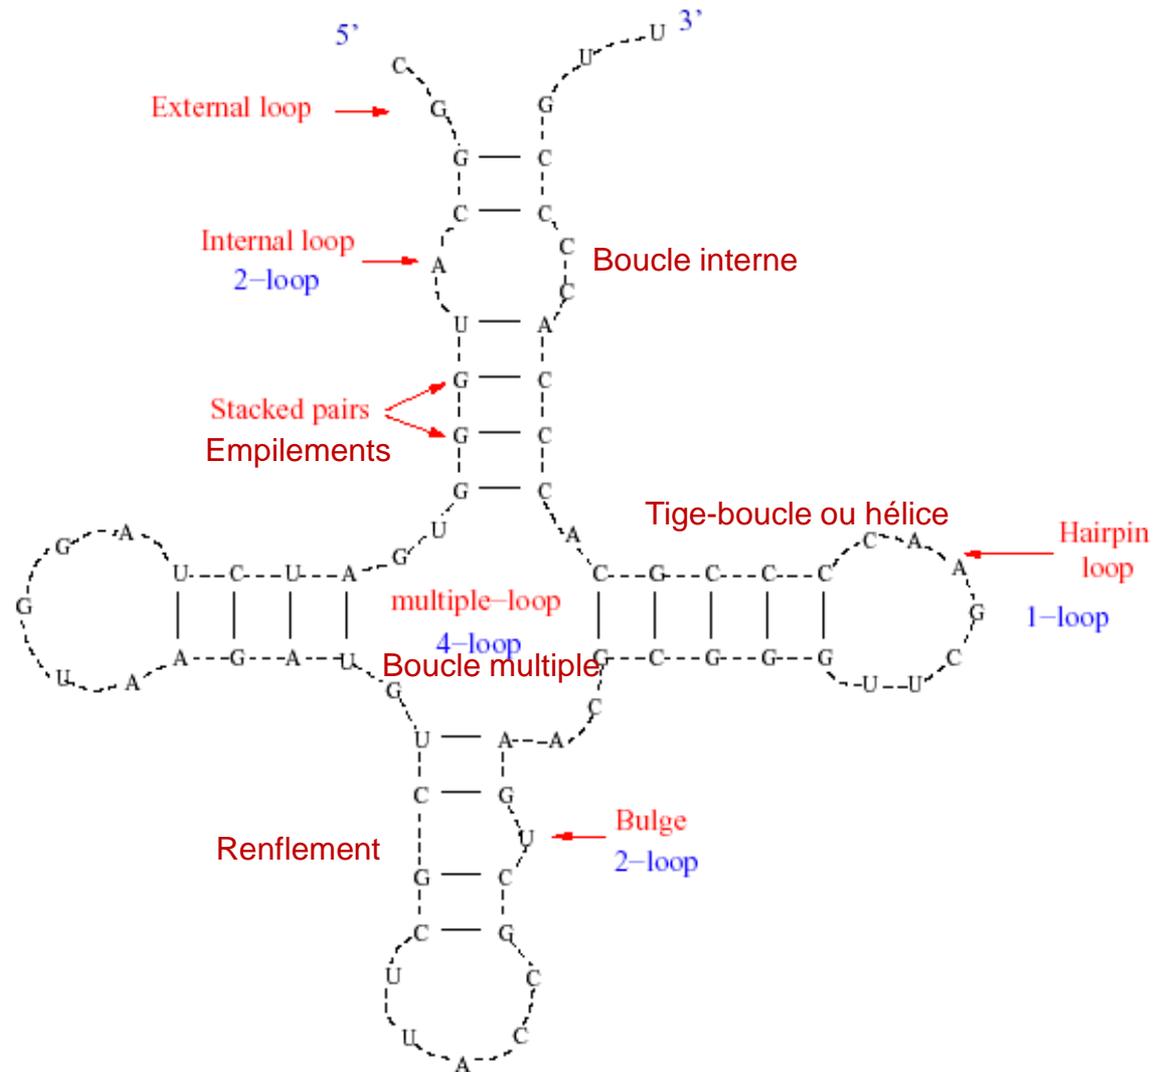
Modélisation du problème

- Pour tout (s_i, t_i) et (s_j, t_j) dans A , on a $s_i < s_j < t_i$ si et seulement si $s_i < t_j < t_i$
- Si cette condition n'est pas respectée, on a ce qu'on appelle un *pseudo-noeud*.
- L'hypothèse 2 implique "pas de pseudo-noeuds".
 - ▣ Relativement rare (mais bien existant), et compliqué!

Modélisation du problème

- Même sans pseudo-noeuds, il y a plusieurs sous-structures, chacune avec ses implications en énergie libre.





Modélisation du problème

- Pour l'instant, version simple du problème: maximiser les paires de bases sous nos hypothèse.
- Entrée: séquence S d'ARN
- Sortie: nombre **maximum** de paires de positions $(s_1, t_1), (s_2, t_2), \dots, (s_k, t_k)$ de paires de bases avec condition $s_i < s_j < t_i$ si et seulement si $s_i < t_j < t_i$

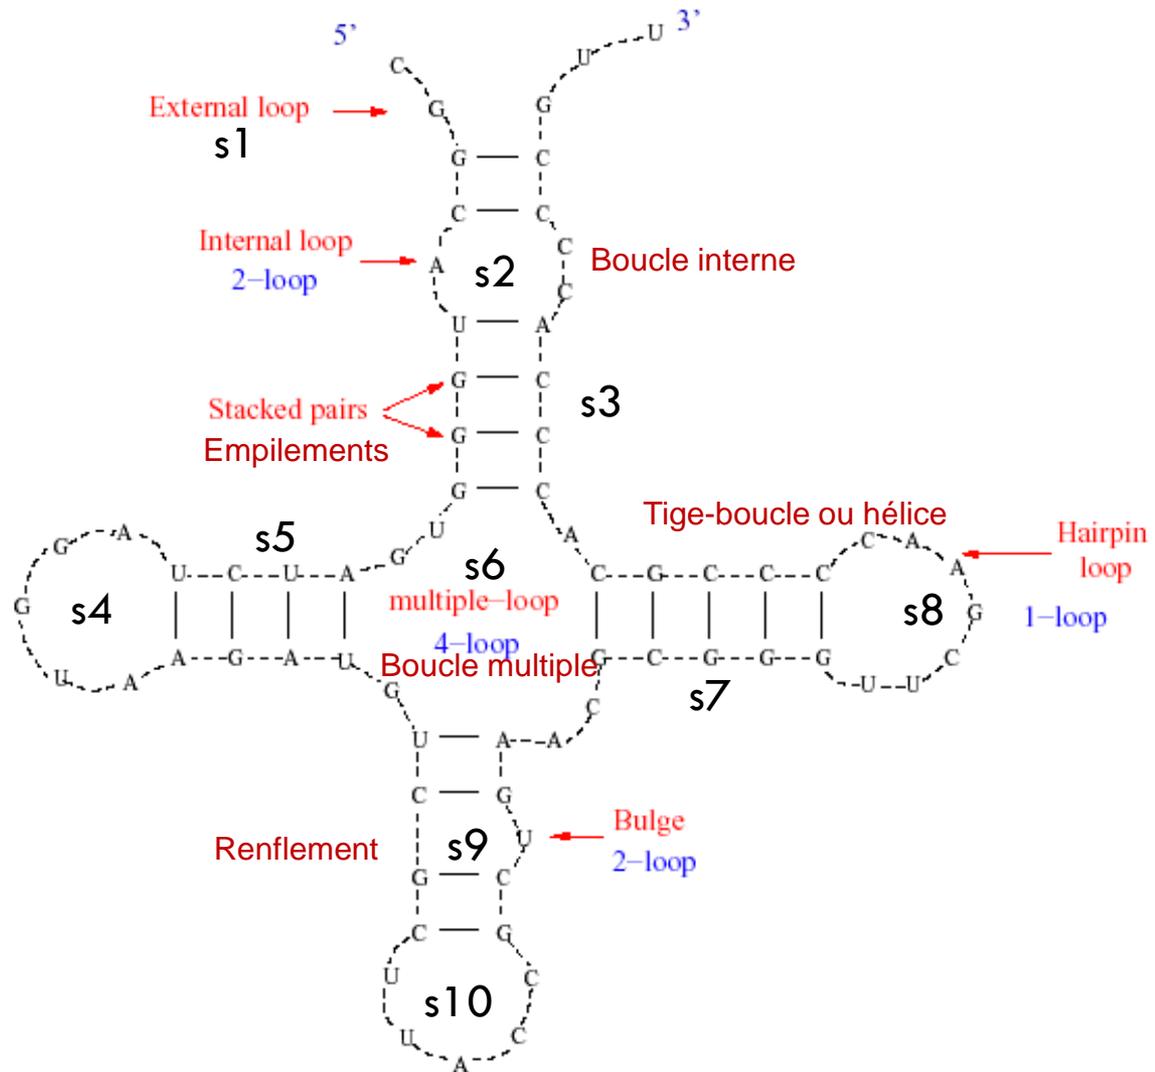
Modélisation du problème

- Pour l'instant, version simple du problème: maximiser les paires de bases sous nos hypothèse.
- Entrée: séquence S d'ARN
- Sortie: nombre **maximum** de paires de positions $(s_1, t_1), (s_2, t_2), \dots, (s_k, t_k)$ de paires de bases avec condition $s_i < s_j < t_i$ si et seulement si $s_i < t_j < t_i$

Algorithme de Nussinov (1978)

Modélisation du problème V2

- Formulation simpliste: ignore le fait que chaque sous-structure a son propre apport en énergie libre.



Modélisation du problème V2

- Formulation simpliste: ignore le fait que chaque sous-structure a son propre apport en énergie libre.
- Soient s_1, s_2, \dots, s_k les sous-structures de l'ARN. Son énergie libre est

$$E(S) = e(s_1) + e(s_2) + \dots + e(s_k)$$

Modélisation du problème V2

- Formulation simpliste: ignore le fait que chaque sous-structure a son propre apport en énergie libre.
- Soient s_1, s_2, \dots, s_k les sous-structures de l'ARN. Son énergie libre est

$$E(S) = e(s_1) + e(s_2) + \dots + e(s_k)$$

- Fonction e évaluée expérimentalement sur de petits ARN synthétiques.

Modélisation du problème V2

Énergie d'empilement de paires de base (kcal/mole à 37degC):

	A/U	C/G	G/C	U/A	G/U	U/G
A/U	-0.9	-1.8	-2.3	-1.1	-1.1	-0.8
C/G	-1.7	-2.9	-3.4	-2.3	-2.1	-1.4
G/C	-2.1	-2.0	-2.9	-1.8	-1.9	-1.2
U/A	-0.9	-1.7	-2.1	-0.9	-1.0	-0.5
G/U	-0.5	-1.2	-1.4	-0.8	-0.4	-0.2
U/G	-1.0	-1.9	-2.1	-1.1	-1.5	-0.4

Turner, Sugimoto (1988)

Énergie de destabilisation pour les autres boucles:

Nombre de bases	1	5	10	20	30
Boucle interne	-	5.3	6.6	7.0	7.4
Bulge	3.9	4.8	5.5	6.3	6.7
Épingle à cheveux	-	4.4	5.3	6.1	6.5

Serra, Turner (1995)

- 
- Désolé pour les amateurs de slides - elles s'arrêtent ici.