

Université Mohamed KHEIDER Biskra
Faculté des Sciences Exactes et Sciences de la Nature et de le Vie
Département des Sciences de la Nature et de la Vie
1ère Année mastère : Biochimie Fondamentale et Appliquée, Microbiologie et Biologie
végétale.

Module : Bioinformatique
TP05 : Annotation des gènes et conception des amorces

Introduction

Dans ce TP vous allez prédire la présence éventuelle de gènes dans la séquence étudiée et, si vous en trouvez, caractériser leur structure exons-introns. On distingue deux types d'approches pour prédire des gènes :

-les approches comparatives : elles prédisent des gènes dans une séquence en cherchant des similarités avec des gènes déjà connus le programme "Blast" plus loin) ;

-les approches *ab initio* : elles ne comparent pas la séquence à des gènes connus, mais recherchent des éléments caractéristiques des gènes : cadre ouvert de lecture (=ORF), séquence promotrice consensus, séquences d'épissage... Cela nécessite de bien connaître ces éléments a priori.

1. La prédiction des exons et des introns

La séquence à analyser sera récupérée de la banque de données "Nucleotide" (nous choisissons la séquence de l'insuline de l'espèce : *Octodon degus*, sous format FAST).

```
>M57671.1 Octodon degus insulin mRNA, complete cds
GCATTTCTGAGGCATTCTCTAACAGGTTCTCGACCCCTCCGCCATGGCCCCGTGGATGCATCTCCTCACCGT
GCTGGCCCTGCTGGCCCTCTGGGGACCCAACCTCTGTTTCAGGCCTATTCCAGCCAGCACCTGTGCGGCTCC
AACCTAGTGGAGGCACTGTACATGACATGTGGACGGAGTGGCTTCTATAGACCCACGACCCGCGAGAGC
TGGAGGACCTCCAGGTGGAGCAGGCAGAACTGGGTCTGGAGGCAGGCGGCCTGCAGCCTTCGGCCCTGGA
GATGATTTCTGCAGAAAGCGGCATTGTGGATCAGTGCTGTAATAACATTTGCACATTTAACCAGCTGCAG
AACTACTGCAATGTCCCTTAGACACCTGCCTTGGGCCTGGCCTGCTGCTGCCCTGGCAACCAATAAAC
CCCTTGAATGAG
```

-Pour utiliser le logiciel "GENSCAN" afin de prédire le nombre d'exons d'un gène, il faut taper l'URL suivant : <http://argonaute.mit.edu/GENSCAN.html>

- Dans la case vide, on va insérer notre séquence à analyser.

- On laisse tous les paramètres par défaut (sélectionnez l'organisme "Vertebrate", ensuite nous cliquons sur "Run GENSCAN")

S : le brin d'ADN (+/-)

BEGIN: le début de l'exon

END: la fin de l'exon

LEN : longueur de l'exon

FR : signifie (le cadre ouvert de lecture)

2. Conception d'amorces

Primer3 est un outil très utilisé pour dessiner des amorces pour PCR. Cette technique est utilisée pour de nombreux objectifs différents. Par conséquent, primer3 a de nombreux paramètres d'entrée différents que vous contrôlez et qui indiquent exactement à primer3 quelles caractéristiques constituent de bonnes amorces pour vos objectifs.

-Pour utiliser le logiciel "Primer3" afin de créer un couple d'amorces pour la PCR, il faut taper l'URL suivant : <http://primer3.ut.ee>

The screenshot shows the Primer3web interface. At the top, it says "Primer3web version 4.1.0 - Pick primers from a DNA sequence." There are links for "disclaimer", "code", and "cautions". Below this, there is a dropdown menu for "select the Task for primer selection" set to "generic". A section titled "Template masking before primer design (available species)" contains fields for "Select species" (Example: Mus musculus), "Nucleotides to mask in 5' direction" (1), and "Nucleotides to mask in 3' direction" (0). There is also a "Primer failure rate cutoff" field set to "< 0.1". A text area for "paste source sequence below" is present, with a note about FASTA format. Below the text area are three checkboxes: "Pick left primer, or use left primer below" (checked), "Pick hybridization probe (internal oligo), or use oligo below" (unchecked), and "Pick right primer, or use right primer below (5' to 3' on opposite strand)" (checked). At the bottom, there are buttons for "Pick Primers", "Download Settings", and "Reset Form". A list of options is shown with their descriptions: "Sequence Id" (A string to identify your output), "Targets" (E.g. 50,2 requires primers to surround the 2 bases at positions 50 and 51. Or mark the source sequence with [and]: e.g. ...ATCT[CCCC]TCAT.. means that primers must flank the central CCCC), "Overlap Junction List" (E.g. 27 requires one primer to overlap the junction between positions 27 and 28. Or mark the source sequence with -: e.g. ...ATCTAC-TGTCAT.. means that primers must overlap the junction between the C and T), "Excluded Regions" (E.g. 401,7 68,3 forbids selection of primers in the 7 bases starting at 401 and the 3 bases at 68. Or mark the source sequence with < and >: e.g. ...ATCT<CCCC>TCAT.. forbids primers in the central CCCC), and "Pair OK Region List" (See manual for help).

Suite :

Toujours on va analyser la séquence de l'insuline de l'espèce : *Octodon degus*, sous format FAST. C-à-d on va créer un couple d'amorces pour amplifier cette séquence (PCR), donc on insère la séquence, puis on clique sur le bouton (**Pick Primers**).

TH: Max Primer Hairpin 24.00

Thermodynamic Template Alignments		Old Template Alignments	
<input type="checkbox"/> Use Thermodynamic Template Alignment			
TH: Max Template Mispriming	40.00	Max Template Mispriming	12.00
TH: Pair Max Template Mispriming	70.00	Pair Max Template Mispriming	24.00

Max #N's accepted	0	Max Poly-X	4	
Inside Target Penalty	-1.0	Outside Target Penalty	0	Note: you can set Inside Target Penalty to allow primers inside a target.
First Base Index	1	CG Clamp	0	
Max GC in primer 3' end	5			
3' End Distance Between Left Primers	3	3' End Distance Between Right Primers	3	
5 Prime Junction Overlap	7	3 Prime Junction Overlap	4	(Distance of the primer ends to one overlap position.)
Concentration of Monovalent Cations	50.0	Salt Correction Formula	SantaLucia 1998	
Concentration of Divalent Cations	1.5	Concentration of dNTPs	0.6	
Annealing Oligo Concentration	50.0	(Not the concentration of oligos in the reaction mix but of those annealing to template.)		
Sequencing Spacing	500	Sequencing Interval	250	
Sequencing Lead	50	Sequencing Accuracy	20	
<input checked="" type="checkbox"/> Liberal Base	<input type="checkbox"/> Show Debugging Info	<input type="checkbox"/> Treat ambiguity codes in libraries as consensus		
<input type="checkbox"/> Lowercase masking	<input type="checkbox"/> Pick anyway	<input checked="" type="checkbox"/> Print Statistics		

Pick Primers Download Settings Reset Form

Objective Function Penalty Weights for Primers

Size	Lt 1.0	Gr 1.0
Tm	Lt 1.0	Gr 1.0

Primer3web version 4.1.0 - Pick primers from a DNA sequence. [disclaimer](#) [code](#)
[cautions](#)

Select the Task for primer selection generic

Template masking before primer design (available species)	
Select species (Example: Mus musculus)	Nucleotides to mask in 5' direction 1
Primer failure rate cutoff < 0.1	Nucleotides to mask in 3' direction 0

Paste source sequence below (5' to 3', string of ACGTnacgtn -- other letters treated as N -- numbers and blanks ignored). FASTA format ok. Please N-out undesirable sequence (vector, ALUs, LINEs, etc.) or use a [Mispriming Library \(repeat library\)](#) NONE

```
>M57671.1 Octodon degus insulin mRNA, complete cds
GCATTCGAGGCACTTCTAAACAGGTTCTCGACCTCCGGCATGGCCCGTGGATGCATCTCCTCACCGT
GCTGGCCCTGCTGGCCCTCTGGGGACCAACTCTGTTCAAGCCTATTCAGCCACGACCTGTGCGGCTCC
AACCTAGTGGAGCACTGTACATGACATGTGGACGGAGTGGCTTCTATAGACCCACGACCCGCGAGAGC
TGGAGACCTCCAGGTGGAGCAGGACGACTGGTCTGGAGCAGGCGCCCTGCAGCCTTCGGCCCTGGA
GATGATTCGAGGAGCGGCATTGTGGATCAGTGTGTAATAACATTTCACATTTAACAGCTGAG
```

<input checked="" type="checkbox"/> Pick left primer, or use left primer below	<input type="checkbox"/> Pick hybridization probe (internal oligo), or use oligo below	<input checked="" type="checkbox"/> Pick right primer, or use right primer below (5' to 3' on opposite strand)
--	--	--

Pick Primers Download Settings Reset Form

Sequence Id		A string to identify your output.
Targets		E.g. 50,2 requires primers to surround the 2 bases at positions 50 and 51. Or mark the source sequence with [and]: e.g. ...ATCT[CCCC]TCAT. means that primers must flank the central CCCC.
Overlap Junction List		E.g. 27 requires one primer to overlap the junction between positions 27 and 28. Or mark the source sequence with -: e.g. ...ATCTAC-TGTCAT. means that primers must overlap the junction between the C and T.
Excluded Regions		E.g. 401,7 68,3 forbids selection of primers in the 7 bases starting at 401 and the 3 bases at 68. Or mark the source sequence with < and >: e.g. ...ATCT<CCCC>TCAT. forbids primers in the central CCCC.
Pair OK Region List		See manual for help.

Le résultat :

Un couple d'amorces apparait (l'amorce gauche et droite) aux niveaux de 2 extrémités de la séquence à amplifier. Aussi, les différentes caractéristiques de chaque amorce (TM, %GC, longueur, début, fin...).

