TP: ADN Mining – Expressions Régulières

grep simple pour (re)commencer

http://www.tuteurs.ens.fr/unix/exercices/solutions/grep-sol.html

Grep est une commande particulièrement utile pour « parser » et analyser des documents textuels. Notamment l'usage des expressions régulières est très rapide.
Récupérer le texte pg17489.txt

wget -q http://www.gutenberg.org/cache/epub/17489/pg17489.txt;

Puis essayez :

grep -E '([a-zA-Z]){18}' pg17489.txt --color=always

```
grep -E '([a-zA-Z]){18}' pg17489.txt |wc -l;
```

(Tout ceci peut être pérenisé dans le .bashrc ou par EXPORT color always)

Faire un petit script en shell (bash en l'occurence) pour

wget -q liberation.fr ; grep Femme index.html | wc -l

En python, on peut faire appel aux modulex *os* puis *re* en présentant un peu plus les expression régulières

```
#! /usr/bin/python2
import os
import commands

os.mkdir('Test')
cmd="pwd"
ch=commands.getoutput(cmd)
ch=commands.getoutput("head -n 2 SNP.py")
```

Text Mining avec Python et grep

Exemple 1

```
import os
import sys
import re

#os.system("wget http://www.gutenberg.org/cache/epub/20/pg20.txt")

file = open(sys.argv[1] + ".txt")

for line in file:
    if re.match('people', line):
        print(line) #affiche la ligne

#ou os.system("more " + sys.argv[1] + ".txt | grep -o -E [a-zA-Z]{15} | wc -w")

findall = re.findall("kiki", "Le kiki de mon kiki est mon kiki")
print(findall)

search = re.search("kiki", "Le kiki de mon kiki est mon kiki")
print(search)

file.close()
```

Exemple 2

```
def searchpattern(target, search_string) :
    matches = []
    for i in range(0, len(search_string)) :
        #print("Compare %i and %i-long strings."%(len(target),
len(search_string[i:i+len(target)])))
        if target == search_string[i : i+len(target)] :
            matches.append(i)
    return matches

def searchstop(search_string) :
    rslt = []
    #stoppatterns = ["UAA", "UCA", "UAC"]
    stoppatterns = ["TAA", "TCA", "TAC"]

    for pat in stoppatterns :
        rslt = rslt+searchpattern(pat, search_string)
    return rslt

search_string =
"CCAAATTCTTCGGGACCCTGGGGGGGTTAAATTACCCTGACCCTGATGCATGGTATGTACAGTAGACTAGGACAACCC
TGGGGTAGA"

matches = searchstop(search_string)

print("STOP codons were found at : %s.\nPlease take position in account for
eventual frameshifts."%str(matches))
```

Exemple 3

```
import os
import sys
import re

#os.system("wget http://www.gutenberg.org/cache/epub/20/pg20.txt")
#Si nécessaire ou
file = open(sys.argv[1] + ".txt")
#Ouvre le fichier et  l'appelle file. sys.argv[i]permet de mettre un
#argument après le nom du code lors de son éxécution pour permettre le
#même parsing avec différents textes. Ex:la commande "python3
#ParsingPython.py pg20" va ouvrir pg20.txt

for line in file: #parcourt les lignes du fichier pg20
    if re.match('people', line):
#si le mot "people" est présent dans une ligne.
#On utilise les Regular Expressions (re)
        print(line) #affiche la ligne

os.system("more " + sys.argv[1] + ".txt | grep -o -E [a-zA-Z]{15} | wc
-w")
#autre méthode utilisant les expressions régulières, cette fois avec
#grep, permettant d'afficher le nombre d'occurences de mots de 15
#lettres. Dans ce texte on en a 9.
findall = re.findall("kiki", "Le kiki de mon kiki est mon kiki")
#fonction de la librairie re, qui affiche l'occurence d'un mot (ou
#séquence de mots), ici "kiki"; dans une phrase
search = re.search("kiki", "Le kiki de mon kiki est mon kiki")
#fonction légèrement différente de findall dans son output
print(findall)
print(search)
file.close()
```

Vérifiez la loi de Zipf sur le texte téléchargé.

Exercice 1 . (p. 110 du cours de F. Dardel)

Les bactéries n'ont pas de nucléosomes, mais possèdent néanmoins des protéines qui condensent l'ADN génomique, pour former ce que l'on appelle un nucléoïde. Une de ces protéines, H-NS, se fixe fortement partout à l'ADN, mais plus sélectivement sur certaines séquences contenant un motif d'environ 9 nucléotides de long. Ci-dessous est représenté un «logo» de ces séquences préférées par H-NS, obtenue par une analyse statistique. A la position 8, il n'y a aucune préférence, c'est pourquoi la position du logo est vide.

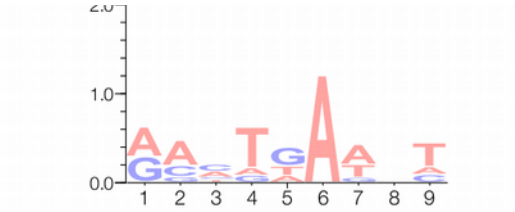

Trouvez puis codez une expression régulière qui puisse reconnaître des séquences qui correspondent à des motifs préférés par H-NS.

Exercice 2 .

Écrire et coder une expression régulière qui reconnaisse simultanément les deux séquences nucléotidiques suivantes CCTCTAAAAAATTATT et CCTCTAAAAAAGTATT (le nucléotide souligné est variable). Essayez d'écrire l'expression la plus compacte possible.

Exercice 3 .

On aligne des séquences d'une famille d'enzymes, des glutathion-S-transférases. Une région de l'alignement des séquences protéiques correspondantes est montrée ci-dessous (les positions conservées ou semi-conservées sont indiquées en gras) :

...**FLQN--KAFLTGPHISLADL**... GST Homme
...**FLQD--KAFIIGSEISLADL**... GST Poulet
...**WLKGNGQYLLGGLRPSIADL**... GST Soja
...**FLEG--QEYAAGNDLTIADL**... GST Drosophile
...**WLRD--REYVCGDEVSYADL**... GST Methylobacterium

Écrire et coder une expression régulière qui reconnaisse le motif conservé ci-dessus ?

Exercice 4.
L'arginine est codée par 6 codons : CGA, CGC, CGT, CGC, AGA et AGG. Écrivez et coder une expression régulière qui reconnaisse exactement ces six codons et seulement ceux-ci. Trouvez une forme concise de cette expression.

Exercice 5.
Le motif suivant reconnaît un type de séquence particulier dans le génome des vertébrés :
CG ([AGT]* ou C C* [AT])* C* CG
Analysez ce motif et expliquez ce qu'il reconnaît exactement.

Remarque tirée du cours: Malgré leur richesse, les expressions régulières ont certaines limites. Elles ne permettent par exemple pas de reconnaître des motifs définis par une règle, comme par exemple des palindromes ou des séquences répétées inversées de longueur quelconque.

ANNEXE

Expressions régulières et Recherche de Motifs

http://www.shellunix.com/regexp.html
http://www.catonmat.net/download/perl1line.txt

▶ codon de démarrage bactérien :	[AG]TG
▶ codon stop :	T(GA ou A[AG])
▶ codon codant (non-stop) :	[ACG]. . ou T(CT. ou G[CGT] ou A[CT])
▶ cadre ouvert de lecture :	[AG]TG ([ACG]. . ou T(CT. ou G[CGT] ou A[CT]))* T(GA ou A[AG])
▶ Shine-Dalagarno (RBS) :	AGGA ou GGAG ou GAGG
▶ Démarrage de la traduction (*E. coli*) :	(AGGA ou GGAG ou GAGG) .{6,12} [AG]TG
▶ ADN courbe :	(AAAA.....){4,} ou (TTTT.....){4,}

p. *109-110 Dardel*

Recherche de motif simple

`$dna =~ /GAATTC/ ;`	
`$dna =~ /GGG[GATC]CCC/ ;`	
`$dna =~ /GAATTC|AAGCTT/ ;`	

Métacaractères (on utilise \ pour indiquer qu'on veut utiliser le symbole d'écriture . par exemple et pas le métacaractère .)

.	Tout caractère sauf nouvelle ligne	\d (tout chiffre) et \D le contraire
^	Le début d'une ligne	\w (tout caractère hors ponctuation et invisible) \W le contraire
$	La fin d'une ligne	\s (tout caractères invisibles) et \S le contraire

Le quantifieur {}. A{2} représente AA. A{2,4} représente AA ou AAA ou AAAA. {2,} signifie un nombre minimum de A accolé de 2 et {,2} au) plus de 2. A+ signifie A répété un nombre indéfini de fois.

?	0 ou 1 occurence
+	1 ou plus d'occurences
*	0 or more occurrences
{N,M}	Entre N et M occurrence
{N,}	Au moins N occurrences
{,M}	Pas plus que M occurences

Exemples :

`$french_postal_code =~ /\d\d\d\d\d/ ;` `$frenc_postal_code =~ /\d{5}/;`	75004
`$sequence_id =~ /\w+\.\d+/ ;`	M588200.2
`$sequence =~ /^[GATCNgatcn]+$/;`	`$sequence =~ /^[GATCN]+$/i;`

/^>\S+\s*.*$/ Cette expression régulière cherche le motif M18580 isolé par un > en début de ligne et un caractère de type espace blanc ensuite, puis n'importe quel chaine jusque fin de ligne. **Usage des parenthèses :** /^>(\S+)\s*(.*)$/ $id=$1 ; $description=$2 ;	>M18580 Clone 305A4,complete sequence « Parse » la ligne pour segmenter en éléments essentiels. **Affecte à des variables :** $id ou $1 valent M18580 $description ou $2 valent «Clone 305A4,complete sequence»

[^...] classe complémentée Tous les caractères sauf ceux énumérés
`1. #!/usr/bin/perl`
`2. #check for non DNA character`
`3. my $string=''CCACATG*CCAT*'' ;`
`4. if ($string =~ /[^AGCT])/i {`
`5. print ''Warning ! Found : $1'' ;`
`6. }`
	Cherche si la chaine de caractères contient des caractères autres que A,G,C,T