

Exemple d'utilisation de Biopython

Analyse et comparaison de
génomés procaryotes

Jennifer Becq


Chargement des séquences

```
>>> from Bio import Fasta
>>> from Bio.Seq import Seq
>>> from Bio.Alphabet import IUPAC
```

Importation des modules de manipulation des séquences


```
>>> f_parser = Fasta.RecordParser()
>>> filin = open('maseq.fasta', 'r')
>>> lignes = string.join(filin.readlines(),")
>>> mon_fasta = f_parser.parse(filin)
>>> mon_fasta = f_parser.parse_str(lignes)
```

Initialisation du parseur fasta / chargement de l'objet « fasta »



```
>>> mon_fasta.title
'NC_00961'
>>> mon_fasta.sequence
'aaacattcctggatca'
```

Chargement des séquences



IUPACProtein

ExtendedIUPACProtein

IUPACUnambiguousDNA

IUPACAmbiguousDNA

ExtendedIUPACDNA

id pour RNA...

```
>>> myseq =  
Seq.Seq(mon_fasta.sequence,IUPAC.ambiguous_dna)
```

Formatage classe 'Seq' pour
un traitement postérieur

Manipulations des séquences

1. Manipulation classique des séquences :

- fragments
- complémentaire
- transcription
- traduction

```
>>> ma_sous_seq = ma_seq[65:146]
```

```
>>> ma_seq_rev = ma_seq.reverse_complement(ma_seq)
```

```
>>> from Bio import Transcribe
```

```
>>> transcriber=Transcribe.unambiguous_transcriber
```

```
>>> mon_arn=transcriber.transcribe(ma_seq)
```

Manipulations des séquences

1. Manipulation classique des séquences :

- fragments
- complémentaire
- transcription
- traduction

2. Création d'un nouvel objet fasta

```
>>> mon_fasta = Fasta.Record()  
>>> mon_fasta.sequence = mon_arn.data  
>>> mon_fasta.title = 'mon arn 001'
```

Manipulations des séquences

1. Manipulation classique des séquences :

- fragments
- complémentaire
- transcription
- traduction

2. Création d'un nouvel objet fasta

3. Ecriture dans un fichier

```
>>> filout = open('mon_fichier.fasta','w')  
>>> filout.write(str(mon_fasta))  
>>> filout.close()
```

Manipulations des séquences

1. Manipulation classique des séquences :
 - fragments
 - complémentaire
 - transcription
 - traduction
2. Création d'un nouvel objet fasta
3. Ecriture dans un fichier
4. Transformation en chaîne de caractères

```
seq_chaine = ma_seq.tostring()
```

Recherche d'un génome donneur potentiel (1)

des blasts...

Utilisation en ligne du blast du NCBI :

```
>>> from Bio.Blast import NCBIWWW
>>> filin = open('ma_seq.fasta', 'r')
>>> f_parser = Fasta.RecordParser()
>>> mon_fasta = f_parser.parse(filin)
```

Importation du module

Chargement de la séquence
en format fasta

Blast

```
>>> bl_result = NCBIWWW.qblast('blastn',
    'nr', mon_fasta, format_type = 'Text')
```

Utilisation de la fonction

« qblast » du module

NCBIWWW

Les arguments de la fonction qblast :

program	BLASTP, BLASTN, (BLASTX, TBLASTN or TBLASTX)
database	banque de données à utiliser ('nr','refseq',...)
sequence	la séquence à rechercher
ncbi_gi	TRUE/[FALSE] selon si on veut l'identificateur 'gi'
descriptions	nb de descriptions à afficher [500]
alignments	nb d'alignements à afficher [500]
expect	valeur de cutoff de E [10.0]
matrix	matrice de substitution (PAM30/70, BLOSUM80/45)
filter	filtre [None] (à choisir 'seg' ou 'dust')
format_type	sortie ['XML'] ou 'Text', 'ASN.1', 'HTML'

Recherche de fichiers genbank :

```
>>> from Bio.EUtils import HistoryClient
```

```
>>> client = HistoryClient.HistoryClient()
```

Requête NCBI « *search* »

```
>>> liste_id = client.search("Archaea[ORGN] OR Bacteria[ORGN]",  
db="genome")
```

Récupération des informations « *efetch* »

```
>>> for id in liste_id:  
...     seq = id.efetch(retmode = "text", rettype = "gb")  
...     gb = seq.read()  
...     seq = id.efetch(retmode = "text", rettype = "fasta")
```

Parsing des fichiers genbank :

1. Récupération des informations utiles pour la base de données

- identifiant taxonomique `/db_xref=taxon:(num)`
- nom *Genre espèce* `ORGANISM`
- taxonomie complète après ligne `ORGANISM`
- n° d'accession `ACCESSION | VERSION`
- type d'ADN `/plasmid | /organelle=...`
- nom de plasmide / souche `/strain | /plasmid`
- séquence entre `ORIGIN` et `//`

2. Traitement de la séquence (calcul des signatures)

3. Intégration à la base de données

Ma classe genbank :

Variables:

flat
nom
taxonomie
taxon
accession
type
origin
idorigin

Méthodes :

GetSeq
toFasta
__len__
__repr__
_cherche#Pattern

```
>>> from MonModule import *  
>>> mon_gb = genbank(lines=lignes_fic_gb)  
>>> len(mon_gb)  
>>> mon_fasta = mon_gb.toFasta()
```

```
class genbank:  
    def _chercheNom(self):  
        ...  
        return nom  
  
    def __init__(self, lines=None):  
        self.flat = lines  
        self.nom = self._chercheNom()  
  
    def __len__(self):  
        return self._chercheLg()  
  
    def toFasta(self):  
        fasta = Fasta .Record()  
        fasta.title = self.nom  
        fasta.sequence = self.GetSeq()  
        return fasta
```