



# Cours de Modélisation et Bio-informatique

## Partie 1: Modélisation

**Dr ALILI Dahmane**

Cours pour M1 Amélioration des plantes



## ***Classification en fonction de la forme***

### **a) Modèle conceptuel**

Les modèles conceptuels ou verbales sont des modèles basés sur l'utilisation d'un langage naturel pour la description et le diagnostic d'un système et/ou sa dynamique.

**Par exemple**, la description d'un plan expérimental lors de la réalisation d'une expérience en plein champs est considérée comme un modèle conceptuel.

Dans ce cas, la planification des facteurs expérimentaux, les niveaux de chaque facteur, ainsi que l'ensemble des témoins constituent les différentes parties de ce modèle.

## •Modèle physique

C'est une représentation physique d'un système étudié, qui projette le fonctionnement réel de l'objet étudié. Les modèles physiques sont caractérisés par leurs structures dimensionnelles définissant les relations entre les différentes parties du modèle.

L'ensemble des structure moléculaires biochimiques (ADN, acides aminées, protéine, sucres...etc.) sont considérées comme des modèles physiques.

## •Modèle diagrammatique

Le modèle diagrammatique est un modèle basé sur des représentations graphiques, schéma (Sketch)...qui illustre des relations et des tendances entre plusieurs objets du système. Il se répartie en plusieurs modules. Chacun de ces derniers représente une composante du système étudié.

## •Modèle mécaniste

Dans ce cas, le fonctionnement du système biologique est contrôlé par des processus mécanistes caractérisés par une variation spacio-temporelle (Ex. la croissance de la plante, la photosynthèse, l'évapotranspiration...etc.).

De plus, ces modèles décrivent les mécanismes physiques, chimiques et biologiques qui déterminent le fonctionnement du système.

## •Modèle descriptif

•On parle des modèles descriptifs lorsque les processus du fonctionnement du **système biologique sont contrôlés par un paramètre unique** (Ex. variation de la densité d'une population de bactéries dans un milieu contrôlé sous l'effet de température).

• **Modèle dynamique et modèle statique :**

- **Le modèle dynamique** représente le changement continu du système au cours du temps.
- Cependant, **le modèle statique** décrit les variations temporaires qui affectent le fonctionnement du système biologique.

• **Modèle déterministe et modèle stochastique:**

Quand certains paramètres varient de façon aléatoire le modèle est stochastique et à chaque tournée peut donner des résultats différents.

Quand tous les paramètres sont constants le résultat est toujours le même. Un modèle stochastique est un modèle qui contient une (ou plusieurs) variable aléatoire. L'équation de base des modèles stochastiques est la suivante:

$$Y = a_0 + a_1 X_1 + a_2 X_2 + a_3 X_3 + a_4 X_4 + \varepsilon$$

# Mise en œuvre d'un modèle

## 2.1.1. Formulation qualitative : Diagramme de Forrester

Les diagrammes de Forrester ont été inventés par Jay Forrester et sont un outil de base pour la formulation qualitative de modèles dynamiques. Ce diagramme ne contient pas des équations mais montrent les objets et ses interrelations entre les différents compartiments du système étudié, selon les hypothèses posées. Ils servent comme base pour la formulation quantitative.

Tous les transferts d'énergie et de matière entre les différents compartiments du système doivent être représentés lors de la formulation qualitative.

## Explication:

### Formulation qualitative : Diagramme de Forrester

Les diagrammes de Forrester ont été inventés par Jay Forrester et sont un outil de base pour la formulation qualitative de modèles dynamiques. Ce diagramme ne contient pas des équations mais montrent les objets et ses interrelations entre les différents compartiments du système étudié, selon les hypothèses posées. Ils servent comme base pour la formulation quantitative.

Tous les transferts d'énergie et de matière entre les différents compartiments du système doivent être représentés lors de la formulation qualitative.

Les diagrammes de Forrester permettent de représenter graphiquement des modèles à base d'équations différentielles,

Il est possible par exemple de modéliser dans le cadre d'un diagramme de Forrester, un modèle représentant **les naissances et les décès de prédateurs et de proies.**

De manière générale, les diagrammes de Forrester sont utilisés pour étudier comment **des écosystèmes fonctionnent.**

**« Modélisation du cycle du carbone et de l'azote au moyen du modèle *MO MO S* »**

**(*Micro-Organismes* et *Matière Organique* du *Sol*)**

## **Explication:**

Les transformations de C et de N dans les sols sont en grande partie assurées par des microorganismes. Ce sont donc ces microorganismes qui déterminent la cinétique de décomposition et qui sont responsables du couplage entre les dynamiques de C et N.




Diagramme relationnel de la Modélisation des Transformations Organiques par les Microorganismes du Sol: MOMOS, (Pansu *et al.*, 2010).

## Explication:

Les matières organiques du sol (MOS) désignent l'ensemble des substances et des composés carbonés d'origine végétale et animale. Elles se localisent surtout dans l'horizon superficiel (0-20 cm).

La nature des MOS se répartit en 3 catégories :

- La matière organique vivante** (vers de terre, insectes, champignons, bactéries,...).
- La matière organique fraîche** principalement **d'origine végétale**.
- La matière organique labile** (glucides simples, acides aminés) et **la matière organique stable** (l'humus) issues de **la décomposition de la matière organique végétale**.

## Explication:

Le modèle couplé visera à prédire simultanément **les flux du C et de N de l'atmosphère**, respectivement par les stomates des plantes et les rhizobiums, et leur translocation vers les tiges et les racines, les flux de C et N restitués par les plantes aux microorganismes du sol, le flux de C vers atmosphère par la respiration microbienne, les flux de N entre les microorganismes et la phase minérale (minéralisation et immobilisation microbienne), l'absorption de l'azote minéral par les racines et sa translocation vers les parties aériennes pour chaque plante.

Il intégrera les entrées N par restitution et fertilisation ainsi que les pertes éventuelles par les agrosystèmes vers l'atmosphère et les eaux souterraines.

# *Application de modèle MOMOS dans le système légumineuse-céréales*


La validation du modèle MOMOS a pour but de répondre à plusieurs questions de recherche sur le système légumineuses-céréales, à savoir:

- Les légumineuses et les céréales en monoculture ou en association, sont-ils des sources des puits de carbone ?
- Les légumineuses fixatrices peuvent-elles constituer des sources suffisantes d'azote pour les céréales en association ou rotation? Dans quelle mesure le phosphore limite-t-il la fixation d'azote ?
- A quelle échelle de temps, les sources en N et C sont-elles disponibles ? Comment assurent-elles la fertilité et la durabilité des systèmes ?

# Développement d'un modèle mécaniste de succession végétale (FAPROM)

Le modèle **FAPROM**

*Fallow Production Model (Martineau & Saugier 2004)*



*Fig. 1 - Processus simulés dans le modèle Faprom.*

## Explication de la figure 1:

**La végétation est décrite comme un mélange d'espèces en compétition pour la lumière et l'azote.** Les parties aériennes occupent plusieurs strates horizontales dans lesquelles les feuilles sont distribuées au hasard.

Chaque espèce comporte **quatre organes: feuilles, tiges, racines et organes reproducteurs.** Le modèle prédit la croissance et la **production de biomasse** de chaque espèce, et prend **en compte les cycles du carbone et de l'azote à travers le sol et les plantes.** Il utilise un pas de temps **journalier**, avec comme entrées des variables **météorologiques.** Il simule divers processus : photosynthèse, respiration de croissance et d'entretien, allocation du carbone, absorption, fixation et remobilisation d'azote, exsudation racinaire, sénescence des tissus, et dispersion et germination des graines

# Partie 2: Bioinformatique



"La bioinformatique fournit des **bases de données** centrales, **accessibles mondialement**, qui permettent aux scientifiques de présenter, rechercher et analyser de l'information.

Elle propose des **logiciels** d'analyse de données pour les études de données et les comparaisons et fournit des outils pour la modélisation, la visualisation, l'exploration et l'interprétation des données", selon une définition de l'Institut Suisse de Bioinformatique.

## *La bioinformatique. C'est quoi ?*

- *Ensemble de méthodes, de logiciels et d'applications en ligne qui permettent de gérer, manipuler, et analyser des données biologiques.*
- *La bioinformatique met en jeu plusieurs champs disciplinaires :*

**Informatique**

**Mathématiques  
formelles**

**Statistiques**

**Biologie**

# *Biologie «in silico»*

Traitement automatisé d'informations biologiques

«*in vivo*» (dans le vivant, cobaye; souris blanche, rat,...),


«*in vitro*» (dans le verre, tube à essai),

«*in silico*» (dans la silice, composant des «puces» des ordinateurs)

«*in silico*» Terme apparu dans «A. Danchin, C. Médigue, O. Gascuel, H Soldano, A Hénaut - From data banks to data bases - Research in Microbiology (1991) 142: 913-916»



# Ressemblance ou similitude entre séquences



Nucléotide à **Adénine**

Nucléotide à **Thymine**

Nucléotide à **Cytosine**

Nucléotide à **Guanine**


L'adénine est toujours associée à la thymine.



Les bases azotées sont complémentaires deux à deux: **les deux chaînes de l'ADN sont donc complémentaires l'une de l'autre.**



La cytosine est toujours associée à la guanine.



(Image obtenue à partir du logiciel RasTop).

# Chapitre 2.

## Banques et bases de données biologiques

### ➤ Harmonisation des fiches de données

#### Exemple de la fiche GENBANK d'un plasmide d'E .faecalis

LOCUS KC297657 673 bp DNA linear BCT 18-MAR-2013  
DEFINITION Enterococcus faecalis strain 493/96 plasmid OrfC gene, partial cds;  
RNAI (rnaI) and RNAII (rnaII) genes, complete sequence; and OrfD  
gene, partial cds.  
ACCESSION KC297657  
VERSION KC297657.1 GI:460758767  
KEYWORDS .  
SOURCE Enterococcus faecalis  
ORGANISM Enterococcus faecalis  
Bacteria; Firmicutes; Bacilli; Lactobacillales; Enterococcaceae;  
Enterococcus.  
REFERENCE 1 (bases 1 to 673)  
AUTHORS Wardal,E., Sadowy,E. and Hryniewicz,W.  
TITLE Diversity of plasmid-associated genes among Enterococcus faecalis  
clinical isolates  
JOURNAL Unpublished  
REFERENCE 2 (bases 1 to 673)  
AUTHORS Wardal,E. and Sadowy,E.  
TITLE Direct Submission  
JOURNAL Submitted (10-DEC-2012) Molecular Microbiology, National Medicines  
Institute, Chelmska 30/34, Warsaw 00-725, Poland  
COMMENT ##Assembly-Data-START##  
Sequencing Technology :: Sanger dideoxy sequencing  
##Assembly-Data-END##

# ➤ Harmonisation des fiches de données

En résumé, **une fiche** comporte de nombreuses informations :

<b>Locus (lieu)</b>	Identificateur (nom et taille de la séquence)
<b>Definition</b>	Description de la séquence
<b>Accession / version</b>	Numéro d'accès dans la base
<b>Keyword / Source / Organism / Reference / Authors / Title / Journal</b>	Informations diverses (taxonomie, publications...)
<b>Features (caractéristiques)</b>	Caractéristiques de la séquence / produits d'expression
<b>Origin (origine)</b>	Séquence (par blocs de caractères / par lignes)
//	Fin de l'entrée dans la base

**Chaque séquence de GenBank** possède deux identifiants : le numéro **Accession** et le **Gi** (prononcé ji-aïe !).

## **1. Le numéro Accession**

C'est un identifiant unique à chaque séquence. Il est composé de lettres et de chiffres (parfois d'un underscore '\_'). Il **n'est jamais modifié**, même si l'enregistrement est corrigé à la demande de l'auteur. Pour une combinaison 'accession.version' existe un numéro **Gi unique**.

## **2. Le Gi (GenInfo Identifier)**

**Le Gi est un nombre** qui est spécifique à une séquence.

**GenBank** contient l'ensemble des **séquences nucléiques**, quelle que soit leur nature (**ADN génomique, ARN messenger, ...**). Les séquences produites dans les laboratoires du monde entier à partir de plus de **100 000 organismes différents** sont régulièrement **soumises au NCBI**.



National  
Center for  
Biotechnology  
Information

GenBank croît ainsi de manière exponentielle, doublant de taille tous les dix mois. En **2006** elle contenait **plus de 65 milliards de nucléotides** dans plus de **61 millions de séquences**.

La banque se construit soit par **des dépôts directs** en provenance des **laboratoires**, soit par des dépôts en masse des **centres de séquençage** à grande échelle.

# Le format FASTA

➤ **Format commun de manipulation des données :**  
le format **FASTA** (**Fast** – **alignment**) (**Alignement rapide**)

**Objectif :** *manipuler facilement des séquences dans les bases de données, à l'aide d'un format universel, compatibles avec les traitements de texte (sous forme de fichier texte), ou par copier – coller.*

**Exemple de la fiche précédente du plasmide d'E.faecalis en format FASTA :**

```
>gi|460758767|gb|KC297657.1| Enterococcus faecalis strain 493/96 plasmid OrfC  
gene, partial cds; RNAI (rnaI) and RNAII (rnaII) genes, complete sequence; and  
OrfD gene, partial cds
```

```
AGTATAAATGTTTCCTGGTGTAAACGAGTTTACACGCTTAGAAAAGATCATAAAACAGCTAGATAAATTGT  
TGAAGGTTTTATTATTGAATTGGCAGAATTTCAATCTATGCTATAATTAATACGGCAGCTCGCCTCGATT  
GGAGGTGTGTTATTTGTGAAAGATTTAATGTCGTTGGTTATCGCACCAATCTTTGTAGGATTGGTTCTGG  
AAATGATTTCTCGTGTGTTGGACGAGGAAGACGATAGCCGAAAGTAAGCTGCTATCAACACACACGCTAG  
AAGTCGCAACTAGTGTAAAAAAAAGCAATCCTATTCGCCGTAGGATTGCTTTTTGTGTTATCTGTACGAT  
TTAATGTCGTTTTCGCACTTTTAGTATAGCATATTTTTATTTTGGGTCAAGTTTTGTGACTATGCAGGAAT  
TGGTAAAGAATACAGTGGTAGCAATTTTCATCGATGCTATTTTATTAATAAAAATAGTAGTAGAAAAATAT  
ATTTATTGATAAACTTATAGTTATGAATCTGTATAGTTAGTTATAATAATTGGTATTTTTTTTAGGAAAAT  
TTGAGCTTTTGAATTGAATAAGAAGGAGTGATTTTATGGATTTAAAGTACAATGTTTTTGGTAATTC AAT  
GTATTCTTTGAAAGAAATGGAGCTAATTC AACTAGCTTCACAA
```

FASTA est à l'origine un programme **d'alignement de séquences d'ADN et de protéine** développé par **William R. Pearson en 1988**. Un des héritages de ce programme est le format de fichier FASTA qui est devenu un format standard en bioinformatique.

Des programmes d'alignement **"FAST-P"** (pour protéine)

et **"FAST-N"** (pour nucléotide)

Organism and Sequences

File Edit

Nucleotide Organism Proteins Annotation

Create Alignment

Click on 'Import Nucleotide FASTA' to read a formatted FASTA file or 'Add/Modify Sequences' to create the file here. The FASTA definition line must be in the following form:

```
>SeqID [organism=scientific name]
```

where the [ and ] brackets are actually in the text. Properly formatted modifiers and a title can also be included in the FASTA definition line.

Import Nucleotide FASTA Add/Modify Sequences Clear Sequences

Specify Molecule Specify Topology

<< Prev Form Next Page >>

Query Sequences

FASTA format

```
>Query1
ATGTCCTTTTCTGTTCTATCTCCGPGSACCTCTCAGGACCTGTGCTGT
CTTCGAGTCCGPGCATGTTATGAGGGAGGCTCATCCTGAGTACATCAGGAAATGGGACGGACCC
AATTACTGGGATAAGTTGGAGGAGGGAGACCTATAACCTGAAAGCA
>Query2
ACCCAAAASCAG
GRCGCGCGCGCGCCAAATGCGAGTCCATCCCTGCGCTCTCCAAACCTCCAAAATGAATGGGACGC
GGCTATGCTCGAGACTTTTGGCTCAARGAGCAATAAATCCCTCGTCAAGGACTCAATATGCGCTC
TAGCGCAAGAGCGCGCGCAACGCGTGTGCGCGCTCATCAGGAGCGTGGCCAGCACGGA
```

or load genes from file:

+ Add

Une séquence au format FASTA commence par **une ligne de titre (nom, définition ...)**, suivie par **les lignes de la séquence**.

La ligne de titre se distingue de la séquence par un symbole plus grand que ("**>**") en début de ligne. La longueur de cette ligne ne doit pas excéder 200 caractères. Il est recommandé de mettre la séquence sous forme de lignes de 80 caractères maximum. Un exemple de séquence au format fasta

```
>gi|532319|pir|TVFV2E|TVFV2E envelope protein  
ELRLRYCAPAGFALLKCNDADYDGFKTNCSNVSVVHCTNLMNTTVTTGLLLNGSYSENRTQIWQKHRTSNDSALIL  
LNKHYNLVTCKRPGNKTVLPVTIMAGLVFHSQKYNLRLRQAWCHFPSNWKGAWKEVKKEEIVNLPKERYRGTNDP  
KRIFRQRQWGDPEANLWFNCHGEFFYCKMDWFLNYLNNLTVDADHNECKNTSGTKSGNKRAPGPCVQRTYVAC  
HIRSVIIWLETISKKTYAPPREGHLECTSTVTGMTVELNYIPKNRTNVTLSQPQIESIWAAELDRYKLVEITPIGFAPTEVR  
RYTGGHERQKRVPFVXXXXXXXXXXXXXXXXXXXXXXXXXXVQSQHLLAGILQQQKNLLAAVEAQQQMLKLTIWGVK
```

# Où trouver les outils de bioinformatique ?

## Le portail EBI

EMBL-EBI 

Services Research Training Industry About us

## The European Bioinformatics Institute

Part of the European Molecular Biology Laboratory

L'Institut européen de bio-informatique (en anglais European Bioinformatics Institute, EBI) est une organisation à but non lucratif qui constitue une sous-division du Laboratoire européen de biologie moléculaire (European Molecular Biology Laboratory, EMBL). Il propose un certain nombre de bases de données d'acides nucléiques, de séquences protéiques et de structures macromoléculaires. Il est en quelque sorte le pendant européen du National Center for Biotechnology Information (NCBI) américain.

# Où trouver les outils de bioinformatique ?

## Le portail NCBI

NCBI  
National Center for  
Biotechnology Information

All Databases ▾

- NCBI Home
- Resource List (A-Z)
- All Resources
- Chemicals & Bioassays
- Data & Software
- DNA & RNA
- Domains & Structures
- Genes & Expression
- Genetics & Medicine
- Genomes & Maps
- Homology
- Literature
- Proteins
- Sequence Analysis
- Taxonomy
- Training & Tutorials
- Variation

### Welcome to NCBI

The National Center for Biotechnology Information advances science and health by providing access to biomedical and genomic information.

[About the NCBI](#) | [Mission](#) | [Organization](#) | [Research](#) | [RSS Feeds](#)

### Get Started

- [Tools](#): Analyze data using NCBI software
- [Downloads](#): Get NCBI data or software
- [How-To's](#): Learn how to accomplish specific tasks at NCBI
- [Submissions](#): Submit data to GenBank or other NCBI databases

### Genomic Structural Variation

dbVar archives large scale genomic variation data and associates defined variants with phenotypic information.



|| 1 2 3 4 5 6 7 8

### Popular Resources

- PubMed
- Bookshelf
- PubMed Central
- PubMed Health
- BLAST
- Nucleotide
- Genome
- SNP
- Gene
- Protein
- PubChem

### NCBI Announcements


Now Available: NCBI Insights

NCBI has just released a new *NCBI Insights*. Blog posts

Come to the NCBI Discover

# Le programme d'alignement BLAST

*Le logiciel BLAST accessible  
depuis le portail*



Le programme d'alignement **BLAST** (**B**asic **L**ocal **A**lignment **S**earch **T**ool)

Les programmes BLAST effectuent une recherche rapide dans les banques de séquences nucléiques et protéiques combinée avec une estimation rigoureuse des statistiques pour apprécier la signification des similitudes.

Bases de séquences

Adresse

- **Bases génériques (multi-organismes)**

EMBL / trEMBL

<http://www.ebi.ac.uk/embl/>

Genbank / GenPept

<http://www.ncbi.nlm.nih.gov/entrez>

DDBJ (DNA Data Bank of Japan)

<http://www.ddbj.nig.ac.jp/>

SwissProt

<http://www.expasy.org/sprot/>

- **Bases spécialisées (organisme)**

GenoList

<http://genolist.pasteur.fr>

Cyanobase

<http://www.kazusa.or.jp/cyano/>

TAIR (The Arabidopsis Information Resource)

<http://www.arabidopsis.org>

FlyBase (Database of the Drosophila Genome)

<http://flybase.bio.indiana.edu/>

MGD (Mouse Genome Database)

<http://www.informatics.jax.org/>

GDB (Human Genome data Base)

<http://gdbwww.gdb.org/>

- **Bases spécialisées (thématique)**

PROSITE

<http://www.expasy.org/prosite>

eMOTIF

<http://fold.stanford.edu/motif>

EPD (Eukaryotic Promoter Database)

<http://www.epd.isb-sib.ch/>