


Automatisation d'Analyses de Données Biologiques

Objectifs pédagogiques :


- Aperçu des données et connaissances biologiques actuellement disponibles
- Distinction entre le protocole d'analyses et les données
- Organisation rationnelle des données
- Outils pour l'automatisation
- Mise en œuvre d'un protocole
- Sélection, synthèse et présentation des résultats

Roland Barriot
Elodie Gaulin

(Quelques) données et connaissances disponibles



- **Génome**
 - ♦ séquence(s) nucléique(s) de l'ensemble des chromosomes d'un organisme
 - ♦ ensemble des gènes d'un organisme
- **Transcriptome**
 - ♦ ensemble des ARNm ou transcrits présents dans une cellule ou une population de cellules dans des conditions données
- **Protéome**
 - ♦ ensemble des protéines présentes dans une cellule ou une population de cellules dans des conditions données
- **Interactome**
 - ♦ ensemble des interactions moléculaires pouvant survenir *in vivo*
 - ♦ ensemble des interactions moléculaires dans des conditions données
 - ♦ ensemble des interactions au sein d'un organisme : moléculaires, physiques, génétiques, fonctionnelles, ...
- **Métabolome**
 - ♦ ensemble des métabolites présents dans une cellule ou une population de cellules dans des conditions données
- Exome, lipidome, phénome, régulome, sécrétome, ...



source : Wikipedia


Growth of the International Nucleotide Sequence Database Collaboration

Completely Sequenced Genomes ©

January 2000


Genome Sequencing Projects on GOLD

September 2009, 5643 projects



- Annotation
 - ◆ régions codantes, régions régulatrice, ...
 - ◆ prédiction fonctionnelle
- Reconstruction du réseau métabolique
- Analyse des relations génotype/phénotype
- Analyses évolutives
- Conception de puces d'expression
- Identification de protéine
- Prédiction de structure

Assemblage d'un génome




L'analyse manuelle d'une séquence peut s'avérer laborieuse

TCCTGGCCTACATGTTCTTTGGCAAAGGATCTTCAAATCAACGGCTCCCGGTGCGGCGATCATCCATTTCTTCGGAGGGATTACAGAGATT
TACTTCCCGTACATTCTGATGAAACCTGGCCCTGATTCTCGCAGCCATTGCCGGCGGAGCAAGCGGACTCTTAACATTACGATCTTTAATGC
CGGACTTGTTCGCGGCAGCGTCACCGGGAAGCATTATCGCATTGATGGCAATGACGCCAAGAGGAGGCTATTTTCGGCGTATTGGCGGGTGTAT
TGGTCGCTGCAGCTGTATCGTTCATCGTTTTACAGCAGTGATCCTGAAATCCTCTAAAGCTAGTGAAGAAGACCTGGCTGCCGCAACAGAAAA
ATGCAGTCCATGAAGGGGAAGAAAAGCCAAGCAGCAGCTGCTTTAGAGGCGGAACAAGCCAAAGCAGAGAAGCGTCTGAGCTGTCTCTGAA
AGCGCGAACAAAATTATCTTTTCGTGTGATCCGGGATGGGATCAAGTGCCATGGGGGCATCCATCTTAAGAAACAAAGTGAAAAAGCGGAGC
TTGACATCAGTGTGACCAACACGGCCATTAACAATCTGCCAAGCGATGCGGATATTGTCATCACCCACAAAGATTTAACAGACCGCGCGAAA
GCAAAGCTGCCGAACCGGACGCACATATCAGTGGATAACTTCTTAACAGCCCCGAAATACGACGAGCTGATTGAAAAGCTGAAAAGTAATCT
TATAGAAAGAGAGTATTGTCATGCAAGTACTCGCAAAGGAAACATTAACCTCAATCAAACGGTATCATCAAAGAAGAGGCTATCAAATTGG
CAGGCCAGACGCTGATTGACAACGGCTACGTGACAGAGGATTACATTAGCAAAATGTTTGACCGTGAAGAAACGTCTTCTACGTTTATGGGG
AATTTTATTGCCATTCCACACGGCACAGAAGAAGCGAAAAGCGAGGTGCTTCACTCAGGAATTTCAATCATAACAGATTCCAGAGGGCGTTGA
GTACGGAGAAGGCAACACGGCAAAAGTGATTTCCGGCATTGCGGGTAAAAATAATGAGCATTTAGACATTTTGTCTAACATCGCCATTATCT
GTTTCAGAAGAAGAAACATTGAACGCCTGATCTCCGCTAAAGCGAAGAAGATTTGATCGCCATTTCAACGAGGTGAACTGACATGATCGCCTT
ACATTTTCGGTTCGGGAAATATCGGGAGAGGATTTATCGGCGCGCTGCTTCACTCCTCCGGCTATGATGTGGTGTTCGCGGATGTGAACGAAA
CGATGGTCAGCTCCTCAATGAAAAAAGAATAACACAGTGGAACTGGCGGAAGAGGGACGTTTATCGGAGATCATTGGCCCCGGTGAGCGCT
ATTAACAGCGGCAGTCAGACCGAGGAGCTGTACCGGCTGATGAATGAGGCGGCGCTCATCACAACAGCTGTCGGCCCCGAATGTCCTGAAGCT
GATTGCCCGTCTATCGCAGAAGGTTTAAGACGAAGAAATACTGCAAACACACTGAATATCATTGCCTGCGAAAAATATGATTGGCGGAAGCA
GCTTCTTAAAGAAAGAAATATACAGCCATTTAACGGAAGCAGAGCAGAAATCCGTCAGTGAAACGTTAGGTTTTCCGAATTTCTGCCGTTGAC
CGGATCGTCCCGATTACAGCATCATGAAGACCCGCTGAAAGTATCGGTTGAACCATTTTTTCGAATGGGTGATTGATGAATCAGGCTTTAAAGG
GAAAACACCAGTCATAAACGGCGCACTGTTTGTTGATGATTTAACGCCGTACATCGAACGGAAGCTGTTTACGGTCAATACCGGACACGCGG
TCACAGCGTATGTCGGCTATCAGCGCGGACTCAAACGGTCAAAGAAGCAATTGATCATCCGGAAATCCGCCGTGTTGTTTATTTCGGCGCTG
CTTGAAACTGGTGAATATCTCGTCAAATCGTATGGCTTTAAGCAAACCTGAACACGAACAATATATTAATAATCAGCGGTGCTTTTTAAATC
CTTTTATTTCGGACGATGTGACCCGCGTAGCGAGGTCACCTCTCAGAAAACCTGGGAGAAAATGTAGACTTGTAGGCCCGGCAAAGAAAATAA
AAGAACC GAATGCACTGGCTGAAGGAATTGCCGAGCACTGCGCTTCGATTTACCGGTGACCCTGAAGCGGTTGAACTGCAAGCGCTGATC
GAAGAAAAGGATACAGCGGCGTACTTCAAGAGGTGTGCGGCATTGAGTCCCATGAACCGTTGCACGCCATTTTTAAAGAAACTTAATCAA
TAACCGACCACCCGTGACACAATGTCACGGGCTTTTTACTATCTCGCAATCTAGTATAATAGAAAGCGCTTACGATAACAGGGGAAGGAGAA
TGACGATGAAACAATTTGAGATTGCGGCAATACCGGGAGACGGAGTAGGAAAGAGGTTGTAGCGGCTGCTGAGAAAAGTGCTTCATACAGCGG
CTGAGGTACACGGAGGTTTGTTCATTCTCATTACAGCTTTTTCCATGGAGCTGTGATTATTACTTGGAGCACGGCAAAAATGATGCCCGAAGA
TGGAATACATACGCTTACTCAATTTGAAGCAGTTTTTGGGAGCTGTCGGAAATCCGAAGCTGGTTCCCGATCATATATCGTTATGGGGCTGC
TGCTGAAATCCGGAGGGAGCTTGAGCTTTCCATTAATATGAGACCCGCCAAACAAATGGCAGGCATTACGTCGCCGCTTCTGCATCCAAATG
ATTTTTGACTTCGTGGTGATTTCGCGAGAACAGTGAAGGTGAATACAGTGAAGTTGTCGGGCGCATTCACAGAGGCGATGATGAAATCGCCAT
CCAGAATGCCGTGTTTACGAGAAAAGCGACAGAACGTGTTCATGCGCTTTGCCCTTCGAATT


- Identification des gènes codant pour :
 - les ARNr
 - les ARNt
 - les protéines
- Identification des unités de traduction
- Identification des unités de transcription (promoteur et terminateur)
- Pour les gènes codant pour les protéines, prédiction fonctionnelle par recherche de similarité de séquences (Blast) et classification en grandes classes fonctionnelles (ex: biosynthèse des acides aminés, métabolisme énergétique....)

Structure secondaire canonique d'une séquence d'ARNt



Génome de *Mycoplasma genitalium*

Distribution des unités de traduction et classification fonctionnelle



Stockage des séquences : Banques de séquences

```

ID   Q8DPI7_STRR6  PRELIMINARY;   PRT;   286 AA.
AC   Q8DPI7;
DT   01-MAR-2003, integrated into UniProtKB/TrEMBL.
DT   01-MAR-2003, sequence version 1.
DT   02-MAY-2006, entry version 10.
DE   DNA processing Smf protein.
GN   Name=smf; OrderedLocusNames=spr1144;
OS   Streptococcus pneumoniae (strain ATCC BAA-255 / R6).
OC   Bacteria; Firmicutes; Lactobacillales; Streptococcaceae;
OC   Streptococcus.
OX   NCBI_TaxID=171101;
RN   [1]
RP   NUCLEOTIDE SEQUENCE [LARGE SCALE GENOMIC DNA].
RX   MEDLINE=21429245; PubMed=11544234;
RX   DOI=10.1128/JB.183.19.5709-5717.2001;
RA   Hoskins J., Alborn W.E. Jr., Arnold J., Blaszczyk
RA   DeHoff B.S., Estrem S.T., Fritz L., Fu D.-J., Gilmour
RA   Gilmour R., Glass J.S., Khoja H., Kraft A.R., LeBlanc
RA   LeBlanc D.J., Lee L.N., Lefkowitz E.J., Lu J., McAhren
RA   McAhren S.M., McHenney M., McLeaster K., Mundy
RA   Norris F.H., O'Gara M., Peery R.B., Robertson C.
RA   Sun P.-M., Winkler M.E., Yang Y., Young-Bellido
RA   Zook C.A., Baltz R.H., Jaskunas S.R., Rosteck and
RA   Glass J.I.;
RT   "Genome of the bacterium Streptococcus pneumoniae
RL   J. Bacteriol. 183:5709-5717 (2001).
CC   -----
CC   Copyrighted by the UniProt Consortium, see http://www.uniprot.org/terms
CC   Distributed under the Creative Commons Attribution 4.0 International License.
CC   -----
DR   EMBL; AE008487; AAK99947.1; -; Genomic_DNA.
DR   PIR; A95147; A95147.
DR   PIR; G98014; G98014.
DR   GenomeReviews; AE007317_GR; spr1144.
DR   BioCyc; SPNE1313:SPR1144-MONOMER; -.
DR   GO; GO:0009294; P:DNA mediated transformation;
DR   InterPro; IPR003488; SMF.
DR   Pfam; PF02481; SMF; 1.
DR   TIGRFAMS; TIGR00732; dprA; 1.
KW   Complete proteome.
SQ   SEQUENCE 286 AA; 31583 MW; CF12DB83AE3663A:MELEFMKITNY
      EIYKLLKKSGL TNQQILKVL EYENVDQELL LGI
      FQDDAHL SK EFQKFP SFSI LDDCY PWDLS EIYDAPVLL F YK
      CSKQGA KSVE KVIQGLE NEL VIVSGLAKGI DTA AHMAAL Q NG
      NKRLQDYIGN DHLV LSEYGP GEQPLKFHFP ARNR IIAGLC RGV
      AMEEGRDVFA IPGSILDGLS DGCHHLIQEG AKLV TSGQDV LAEFFE
  
```

Exemple d'une entrée protéique dans la banque de données UniProt

UniProt > UniProtKB Downloads · Contact · Documentation/Help

Search Blast * Align Retrieve ID Mapping *

Search in Query

Protein Knowledgebase (UniProtKB)

Q8DPI7 (Q8DPI7_STRR6) ★ Unreviewed, UniProtKB/TrEMBL Contribute
Send feedback
Read comments (0) or add your own

Last modified December 14, 2011. Version 39. [History...](#)

Clusters with 100%, 90%, 50% identity | Third-party data [text](#) [xml](#) [rdf/xml](#) [gff](#) [fasta](#)

[Names](#) · [Attributes](#) · [Ontologies](#) · [Sequences](#) · [References](#) · [Cross-refs](#) · [Entry info](#)

Names and origin

Protein names	Submitted name: DNA processing Smf protein EMBL AAK99947.1
Gene names	Name: smf EMBL AAK99947.1 Ordered Locus Names: spr1144
Organism	Streptococcus pneumoniae (strain ATCC BAA-255 / R6)
Taxonomic identifier	171101 [NCBI]
Taxonomic lineage	Bacteria · Firmicutes · Lactobacillales · Streptococcaceae · Streptococcus

Protein attributes

Sequence length	286 AA.
Sequence status	Complete.
Protein existence	Predicted

Ontologies

//

Independent evolution of competence regulatory cascades in streptococci?

Bernard Martin, Yves Quentin, Gwennaele Fichant and Jean-Pierre Claverys

Trends in Microbiology, Volume 14, Issue 8 , August 2006, Pages 339-345

La transformation génétique naturelle

Étapes :

- capture d'ADN exogène
- internalisation
- intégration dans le génome

Processus **largement répandu** chez les bactéries


- > 40 espèces de bactéries, distribuées dans tous les groupes taxonomiques.

Rôles de la transformation

- échanges génétiques (sexualité bactérienne)
- réparation de l'ADN
- nutriments

La compétence : état physiologique permettant la transformation, génétiquement programmé et transitoire

Le transformasome



ComGC
CW
crossing



ComEA
DNA
binding



EndA
DNase




ComEC
Trans-
membrane
channel




ComFA
Helicase
translocase?

Régulation de l'état de compétence, modèle *Streptococcus pneumoniae*



Séquences de référence : protéines ComD et ComE de *S. pneumoniae*



Alignement multiple des séquences des protéines homologues à ComD


ClustalX (1.83)

File Edit Alignment Trees Colors Quality Help


Multiple Alignment Mode

Font Size:

8



Transcriptome : ensemble des ARNm ou transcrits présents dans une population de cellules dans des conditions données.





Accès au niveau d'expression de milliers de gènes simultanément (potentiellement l'ensemble des gènes d'un organisme)
= *instantané* de l'état d'une cellule ou d'une population de cellules

Données d'expression des gènes obtenues par :

- qPCR
- Puces à ADN
- Séquençage ultra-haut débit



Transcriptome : acquisition des données



scan




Transcriptome : analyse et interprétation des données



Transcriptome : gènes co-exprimés


- Motivation : les gènes ayant des profils d'expression similaires sont potentiellement co-régulés et participeraient donc à un même processus biologique
- But : regrouper les gènes impliqués dans un même processus biologique



Protéome : ensemble des protéines exprimées dans une cellule, une partie d'une cellule (membranes, organites) ou un groupe de cellules (organe, organisme, groupe d'organismes) dans des conditions données et à un moment donné.

= *instantané* de l'état d'une cellule ou d'une population de cellules



Séparation des protéines par gels d'électrophorèse (1D, 2D) puis identification des spots par spectrométrie de masse



Réseaux de gènes et de protéines

Réseaux :

- d'interactions protéine - protéine, génétiques, fonctionnelles, ...
- de régulation des gènes
- métabolisme (enzymes – substrats)
- transduction du signal





Séquence protéique

>gi|5524211|gb|AAD44166.1| cytochrome b

```
LCLYTHIGRNIYYGSYLYSETWNTGIMLLLI1TMATAFMGYVLPWGQMSFWGATVITNLFSAIPYIGTNLV
EWIWGGFSVDKATLNRFFAFHFILPFTMVALAGVHLTFLHETGSNNPLGLTSDSDKIPFHPYTIKDFLG
LLILILLILLILLALLSPDMLGDPDNHMPADPLNTP31PLHIKPEWYFLFAYAILRSVPNKLGGVLALFLSIVIL
GLMPFLHTSKHRSMMLRPLSQALFWTLTMDLLTLTWIGSQPVEYPYTIIGQMASILYFSIILAF61LPIAGX
IENY
```





Prédiction ou résolution
de la structure tridimensionnelle



Intégration et synthèse des connaissances

- modélisation d'un système
 - processus biologique (respiration)
 - organite (mitochondrie)
 - cellule
 - population
 - écosystème



À terme : simulation d'une cellule virtuelle et prédiction de son comportement