

Prédiction et validation des codons d'initiation :

approches croisées bioinformatique et protéomique

O. Lecompte, M. Argentini, C. Schaeffer, J-M Reyrat, O. Poch & A. Van Dorsselaer


- *Laboratoire de Bioinformatique et Génomique Intégratives, IGBMC, Strasbourg*
- *Unité de Pathogénie des Infections Systémiques, Paris*
- *Laboratoire de Spectrométrie de Masse Bio-organique, Strasbourg*

Bioinformatique et génomique intégratives

Etude de protéines informationnelles


Validation et analyse des données issues de la biologie à “haut-débit”

Développements algorithmiques



<http://www-igbmc.u-strasbg.fr/PipeAlign/>

Plate-forme logicielle GScope



Contexte du projet

biologie à haut débit



Accumulation
d'erreurs

Erreurs de prédiction des gènes :

- 50 % des gènes de *Caenorhabditis elegans* (Reboul *et al.*, 2003)
- ~ 20 % des codons initiateurs prédits chez les bactéries

Conséquences :

- L'analyse des génomes *in silico*
 - régions régulatrices des gènes
 - signaux de localisation...
- Études expérimentales
 - Clonage et expression des gènes...

Thréonyl-ARNt synthétases

```
MRVLLIHS DYIEYEVKDKALKNPEPIS--EDMKRGRME EVLVAFISVEKVDI
MRILLIHS DYIEYEVKDKAIKNPEPIS--EEEKKGRMDEV LVAFISVEKVDI
MRMLLIHS DYIEYEVKDKAIKNPEPIS--EEEKKGRMDEV LVAFISVEKVDI
MKLLLIH ADYMEYEVK-KKTKLAEP----FDGKGERVEEVLVAF TSVEKVDI
MQLLLIHS DYIEYETK-KQTPVAEKI--EESLKSCRLEEALTA FMAVESVDI
MQLLLIHS DYIEYETK-KQTPVAEKI--EESLKSGRLEEALTA FTAVESVDI
MQLLLIHS DYIEYETK-KQTPVAEKI--EESLKSGRLEEALTA FTAVESVDI
MRILLIHS DYLYKYETK-NKTGLAEEIP--EDKMQGDFRESL VVETA VEABDI
MKMLLIHS DYLEFEAK-EKTKIAEET---ENLKGKLD ECLACFI AVEREDI
MRLLF IHADEMSFEAR-QKTKIAEEEP---IKEAEVEDCLV VFAAVQ EADI
MRVLY IHAERFNWEPRDPALDIRDEP-----TSGNANNAL VVETS VERGDI
MIILFIH ASDFSFNVK--ERAIKEPE--EAKLKSIELKNTL VCFTT VEKGD
Q9YFY3 -----V--KPALKNPPDPP---GEASFGEALVVETT VEDGDI
```

Validation/correction des codons initiateurs

Conservation des séquences protéiques


Alignement multiple de séquences complètes




Classification des séquences



Clustering hiérarchique des positions
Définition de blocs




Analyse des régions N-terminales



extension ↑


Reference position

Etude du contexte génomique



Tests et optimisation

Mycobacterium smegmatis




croissance rapide

Proche de bactéries pathogènes

- *M. tuberculosis*
- *M. leprae*
- *M. ulcerans*

Annotation du génome



prédictions des codons initiateurs

Détermination expérimentale
des séquences N-terminales

DETERMINATION DES SEQUENCES N-TERMINALES DES PROTEINES DE *Mycobacterium Smegmatis*

5000-10000 PROTEINES EXPRIMEES

DIFFERENTES CULTURES BACTERIENNES

**PLANCTONIQUE
SOUS AGITATION**

**STATIQUE
EN BIOFILM**

**EN CONDITION
DE STRESS**

DIFFERENTES FRACTIONS PROTEIQUES

PROTEINES SOLUBLES

PROTEINES MEMBRANAIRES

**(Unité de Pathogénie des Infections Systémiques,
UMR570, Responsable J.M. Reyrat)**

STRATEGIES D'ANALYSE DES SOUS-PROTEOMES DE *Mycobacterium Smegmatis*

APPROCHE CLASSIQUE

- SEPARATION DES PROTEINES SOLUBLES ET MEMBRANAIRES PAR GEL DE POLYACRILAMIDE
- DIGESTION ENZYMATIQUE « IN GEL »
- ANALYSE SPECTROMETRIQUES MALDI ET/OU LC-MS-MS

**RAPIDITE ET
SIMPLICITE TECHNIQUE**

**PERTE SIGNIFICATIVE D'INFORMATIONS
LIEE A L'UTILISATION DES GELS**

**OBTENTION D'UN NOMBRE ELEVE ET REDONDANT
DE PEPTIDES POUR CHAQUE PROTEINE ANALYSEE
(5-10 peptides = 1 proteine)**

**BUT: CONNAITRE LES SEQUENCES DES PEPTIDES N-TERMINAUX
DE L'ENSEMBLE DES PROTEINES BACTERIENNES**

STRATEGIES D'ANALYSE DES SOUS-PROTEOMES DE *Mycobacterium Smegmatis*

APPROCHE COFRADIC (Combined FRActional Diagonal Chomatography)

Nature biotechnology - volume 21 - may 2003

Exploring proteomes
and analyzing protein
processing by mass
spectrometric identification
of sorted N-terminal
peptides

Kris Gevaert, Marc Goethals, Lennart Martens,
Jozef Van Damme, An Staes, Gr goire R. Thomas
and Jo' l Vandekerckhove


ABSENCE DE GEL

SELECTION DES PEPTIDES N-TERMINAUX
(1peptide=1 proteine)

COMPLEXITE TECHNIQUE

APPROCHE COFRADIC

(Combined FRActional Diagonal Chomatography)



L'APPROCHE COFRADIC



**NOMBRE SATISFAISANT DE SEQUENCES
N-TERMINALES DES PROTEINES DU
*Mycobacterium Smegmatis***



**LA VALIDATION DU PROGRAMME
DE PREDICTION/DIAGNOSTIC
DES CODONS D'INITIATION**

PLATE-FORME MULTI-SITES RIO de STRASBOURG
(Recouvrement avec la Plate-forme Cancéropôle et Génopôle)
Responsable scientifique A. Van Dorsselaer

Site Partenaire 1

IGBMC Illkirch

Pôle de protéomique
Génopôle-Cancéropôle
Responsable scientifique:
A. Van Dorsselaer et
D. Moras

Site Principal

LSMBO Cronenbourg

– UMR 7509
Pôle Analytique ECPM
Responsable
scientifique: A. Van
Dorsselaer

Site Partenaire 3

IML Strasbourg

Institut de
Médecine Légale
Responsable scientifique:
B. Ludes

Site Partenaire 2

CHU Hautepierre

Plateforme cancéropôle
U381 Inserm
Responsable scientifique:
Jean-François Launay

LABORATOIRE DE SPECTROMETRIE DE MASSE BIO-ORGANIQUE (A. Van Dorsselaer)

RP-HPLC OFF-LINE



LC-MS-MS



Christine SCHAEFFER