


## Partie I

# Des spectres à l'identité des protéines

**Thomas Burger**

--

Etude de la Dynamique  
des Protéomes



- Ingénieur en télécom et mathématique discrète  
*(Ensimag, 2004)*
- Thèse CIFRE en vision par ordinateur  
*(GIPSA-Lab et Orange-labs, 2007)*
- Maître de conférences en informatique décisionnelle  
*(2008-2011, Université de Bretagne Sud)*
- Chargé de Recherche au CNRS  
*(à EDyP, depuis 2011)*


1. Introduction générale
2. Extraction du signal
3. Identification des peptides
4. Inférence de protéines
5. Parenthèse statistique
6. Contrôle de la qualité

- Objectifs questions et enjeux
- Pipe-line d'analyse
- Infrastructure logicielle

# INTRODUCTION GENERALE


- Résumer les étapes “sèches” d’un pipe-line de **quantification relative label-free**
- Présenter les choix algorithmiques ou statistiques possibles
- Insister sur la maîtrise de la qualité des résultats finaux...  
**Cela fait partie de la protéomique !!!**

# Pipe-line d'analyse (humide)




Analyse LC-MS/MS

Nesvizhskii, 2011




Separated peptides









Tandem mass spectrum

# Pipe-line d'analyse (sèche)





Common Data Format



- Stockage et sécurisation des données
- Indexation pour usage ultérieure
- Contrôle qualité (ISO9001) du processus
- Automatisation des différentes étapes

# Notre infrastructure logicielle



- Deisotoping
- Etats de charge
- Débruitage
- Etc.

## EXTRACTION DU SIGNAL


- Beaucoup de traitements invisibles
  - Deisotoping, sélection de l'état de charge
  - Exclusion dynamique
  - Codage du signal (mode profile/centroid)
- Tout cela, dans un logiciel propriétaire
- Influence sur la qualité des résultats ?

- Sur le spectre MS
  - Calcul de la masse du précurseur
  - Vérifications (état de charge, deisotoping)
  
- Sur le spectre MS/MS
  - Deisotoping
  - Extraction de peak-list
  - Denoizing

- Plusieurs suites logicielles incluant
  - Différents traitements modulaires
  - Un “daemon” permettant d’enchâîner les traitements, + synchronisation p.r. production des données
- Mascot Daemon + Mascot Distiller
- TPP, OpenMS, Scaffold, MyProMS, etc.

- Généralité sur les moteurs d'identification
- Principe de fonctionnement

# IDENTIFICATION DES PEPTIDES



- Comment interpréter la sortie ?
  - Liste ordonnée
  - Le premier est souvent le bon... Mais pas toujours

## Output: ranked peptide list

<i>peptide</i>	<i>score</i>
<u>VSTPNVSVVDLTCR</u>	5.6
ISLLDAQSAPLR	1.3
CDVVSNTIIAE	1.1

- Outils ouverts/fermés: prix, complexité de maîtrise, durabilité/maintenance, etc.

- Prophets:
  - recalcule de nouveaux scores
  - On sait interpréter le score
  - Les scores sont cohérents sur le dataset
- Mergers (ou outils de meta-scoring):
  - Combine le résultat de plusieurs moteurs
  - En théorie, plus robuste
  - Usine à gaz, perte de la maîtrise
- Filters:
  - Outils de prise de décision sur les PSM
  - Indispensable pour éviter un traitement manuel



- A l'heure actuelle:
  - Database search avec Mascot
  - Pas de Prophet, pas de Merger
  - Outil de filtrage: IRMa
  - Gestion des contextes expérimentaux: hEIDI
- A l'avenir:
  - Intégration de ces outils dans ProLine
  - Plusieurs outils d'identification possibles
  - Peut-être usage d'un merger...

- Constitution d'une base FASTA de référence

- Mesure de distance:
  - MOWSE score
  - Autocorrelation
  - Produits scalaires

- Un test d'hypothèse sur cette mesure => p-value

- La p-value  $p$  est convertie en un score  $S$ :






$$S = -10 \cdot \log_{10}(p)$$

- Les différentes versions du problème
- Les outils disponibles
- Les enjeux futurs
- Les choix d'EDyP

# INFÉRENCE DE PROTÉINES

# Différentes versions du problème



- Optimisation combinatoires
  - One and two peptides rules
  - DTASelect
  - IDPicker
  
- Méthodes statistiques
  - Iterative : ProteinProphet, Scaffold, EBP, PANORAMICS
  - Various types of Bayesian model (nested, hierachical, etc.)



- Pour l'instant algorithme simple et glouton correspondant au problème le plus simple
- Tentatives d'amélioration en cours
- Incorporation d'outils de visualisation

- Beaucoup de choses atch'compliquées !!!

# **PARENTHÈSE STATISTIQUE: INTRODUCTION AU TEST D'HYPOTHÈSE**

- Un spectre observé est-il suffisamment proche d'un spectre théorique pour considérer que c'est un "match" ?
- On peut répondre OUI (à tort ou à raison) ou NON (aussi à tort ou à raison)
- On peut se tromper de 2 manières différentes


- Dans notre cas:
  - On **peut** accepter un NON A TORT, i.e. oublier un PSM.
  - On **ne peut pas** accepter un OUI A TORT, i.e. considérer un “match” qui n'en est pas un.
- On définit l'**erreur de première espèce** comme l'erreur inacceptable
- *En générale on ne peut pas accepter de définir à tort un écart à la norme.*

- Une erreur de première espèce revient à rejeter à tort l'**hypothèse nulle** (notée  $H_0$ ).
- On peut donc formuler nos hypothèses:
  - **$H_0$** : le couple observation/spectre n'est pas un PSM.
  - **$H_1$** : (**hypothèse alternative**) il est un PSM.
- On appelle **positif** ou **découverte**, un test pour lequel  $H_0$  est fausse (contraire: **négatif**)
- On qualifie de **fausse** une décision prise à tort (contraire: **vraie**)

Est-ce que compte tenu de mes observations, je peux rejeter  $H_0$  ?

- OUI: le rejet de  $H_0$  implique l'acceptation de  $H_1$ .  
**le couple spectre/peptide est donc un “match”**
- NON: Est-ce qu'on peut accepter  $H_0$  alors ? Non plus... On ne peut donc rien dire.  
**Le couple spectre/peptide est donc soit un “match”, soit pas...** (soit  $H_0$  est vraie, soit c'est une erreur de seconde espèce, donc moins grave).

- Définir une mesure de distance entre un peptide et un spectre
- Définir la distribution de cette distance quand  $H_0$  est vraie :  
*Un "histogramme" des mesures pour des "non-match"*
- Pour chaque peptide à tester, calculer la probabilité d'une observation au moins aussi extrême: La **p- value**



## Un petit quizz...

---

Concrètement, une p-value de  $p = 0.02$  pour un PSM donné s'interprète comment ?

- A. Il y a moins de 2% de fausses découvertes parmi tous les PSM ayant une p-value plus faible.
- B. La probabilité que ce PSM soit une fausse découverte vaut 2%.
- C. N'importe quelle fausse découverte à 2% de chance d'avoir un score meilleur que ce PSM qui m'intéresse ?
- D. La réponse D...
- E. Mon PSM est une vraie découverte puisque  $p < 0.05$ .

# La réponse au Quizz:

A. Il y a moins de découvertes fausses parmi tous les PSM ayant un score meilleur que le PSM qui m'intéresse.

**Contrôle du nombre de fausses découvertes**

B. La probabilité **Ce qui nous intéresse :  $P [ H_0 | Obs ]$**  est 2%.

C. **La p-value que le test nous donne :  $P [ Obs | H_0 ]$**  est un score meilleur que ce PSM qui m'intéresse ?

E. Mon PSM est **Règle pifométrique à oublier** faux puisque  $p < 0.05$ .

Comment passer de  **$P [ H_0 | Obs ]$**  à  **$P [ Obs | H_0 ]$**  ?

- Au sein d'EDyP, Sylvain et Véronique ...



- ... sont tous deux nés un 6 Juin !!!  
**C'est fou, non ?**


- Pour chaque humain, la probabilité qu'il passera devant la porte 15 du Terminal 1 de l'AST, le 6 juin 2016 est presque nulle.
- Pourtant, le 6/6/16... on aura ceci:
- **C'est fou, non ?**



- L'anniversaire :
  - Nous voyons deux observations qui “matchent” avec tellement de précision que nous pensons cela difficilement explicable par le hasard
  - En fait, le hasard est la meilleure explication
  - **C'est une fausse découverte**
- L'AST:
  - les phénomènes rares apparaissent avec une proba forte
  - Parmi vos découvertes “fiabiles biologiquement”, et publiées, il y a sur le nombres, quelques erreurs...
  - **Problème des tests d'hypothèse multiples**

- Besoin de MTC : Il faut pouvoir contrôler la **False Discovery Proportion (FDP)**, alors qu'elle est inconnue.
- Les stratégies types FDR proposent:
  - De s'intéresser à l'espérance de la FDP:  $\mathbb{E}(\text{FDP}) = \text{FDR}$
  - D'estimer celle-ci le mieux possible...

- Méthodes classiques:
  - Benjamini-Hochberg
  - Permutation-based FDR
  - Target-Decoy
  - Etc...



- De l'identification des peptides
- De l'identification des protéines

# CONTRÔLE DE LA QUALITÉ

- Méthode classique: Target-Decoy
  - On crée des faux peptides
  - La proportion de faux PSM sélectionnés donne le FDR
- Preuve que cela correspond à une stratégie de type FDR ? Qualité de l'estimateur ?
- Cela correspond à une moyenne sur...  
1 seul individu !!!

- Avoir des bases Decoy gigantesques
- Remonter à la probabilité critique de l'identification (si possible ?) et utiliser BH ?
- Niveau de stabilités des identifications par rapport à l'élargissement des bases FASTA ?

- Contrôle du FDP au niveau des peptides et publication de listes de protéines
- Que représente un FDR au niveau protéique ?  
Quelle est l'hypothèse nulle ?
- A FDP constant:
  - si on augmente le nombre de découverte de peptides,
  - on augmente le nombre de fausses découvertes sur les protéines !!!

- A quoi tout cela sert-il ?
- Le nombre de fausses découvertes n'est pas fiable
- Il s'agit d'un garde fou pour éviter des publications folkloriques