

Vigrid/MSDA: la grille de calcul au service de l'analyse protéomique

Christine CARAPITO, Jérôme PANSANEL, Patrick GUTERL, Alexandre BUREL, Fabrice VARRIER, Fabrice BERTILE, Stéphane GENAUD, Alain VAN DORSSELAER, Christelle ROY



UNIVERSITÉ DE STRASBOURG

Du génome au protéome



Code à **4 lettres**
A, T, G, C

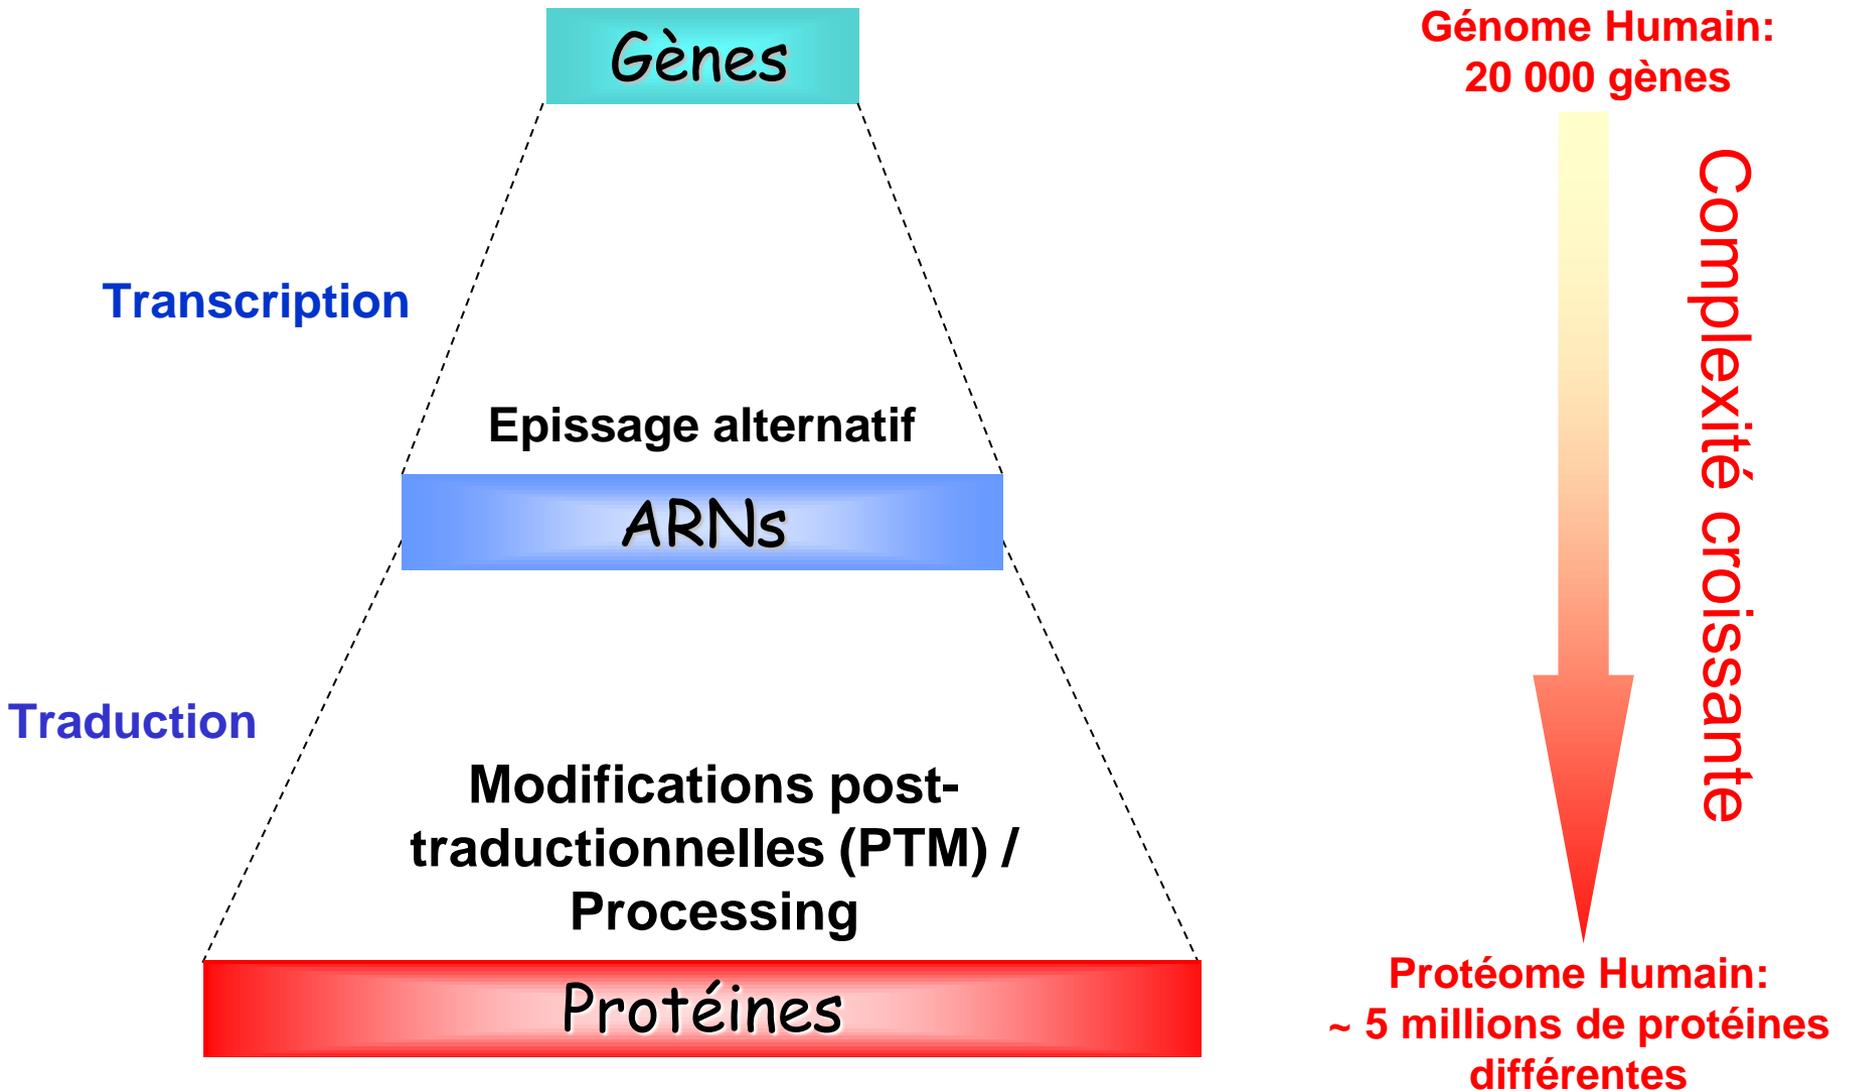


Le code génétique

Code à **20 lettres**
20 acides aminés

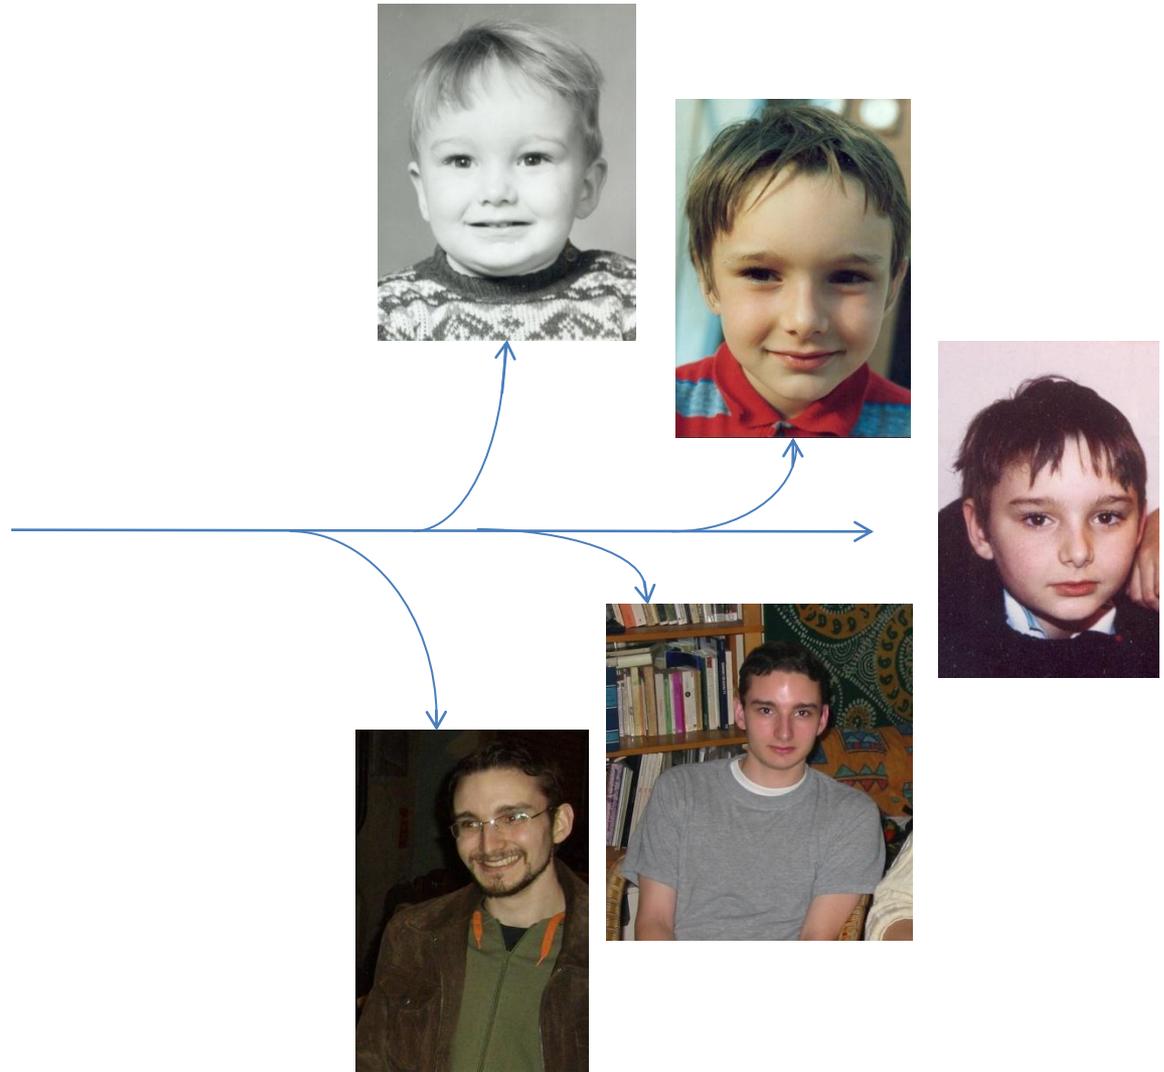
		2 ^e nucléotide					
		T	C	A	G		
1 ^{er} nucléotide	T	TTT	TCT	TAT	TGT	T	
		TTC	TCC	TAC	TGC	C	
		TTA	TCA	TAA	TGA	A	
		TTG	TCG	TAG	TGG	G	
	C	CTT	CCT	CAT	CGT	T	
		CTC	CCC	CAC	CGC	C	
		CTA	CCA	CAA	CGA	A	
		CTG	CCG	CAG	CGG	G	
	A	ATT	ACT	AAT	AGT	T	
		ATC	ACC	AAC	AGC	C	
		ATA	ACA	AAA	AGA	A	
		ATG	ACG	AAG	AGG	G	
G	GTT	GCT	GAT	GGT	T		
	GTC	GCC	GAC	GGC	C		
	GTA	GCA	GAA	GGA	A		
	GTG	GCG	GAG	GGG	G		
		3 ^e nucléotide					

Du génome au protéome



Le protéome est évolutif et dynamique

Un génome ...



... plusieurs protéomes !

L'analyse protéomique

Définition: C'est l'analyse de l'ensemble des protéines exprimées par un type cellulaire, un tissu ou un fluide biologique (sang, urine), à un instant donné et avec un historique donné.

Technique: L'analyse protéomique repose sur l'interprétation des données de Spectrométrie de Masse.



Instruments de type
Quadrupole-TOF

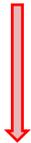
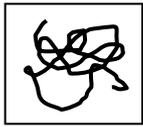


Instruments de type
Trappe ionique

Nature des données: Des tableaux de masses moléculaires très précises (7 digits).

L'analyse protéomique

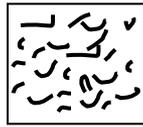
Mélange de protéines



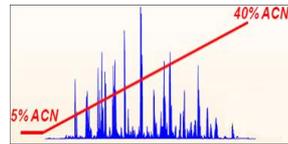
Coupe enzymatique



Mélange de peptides

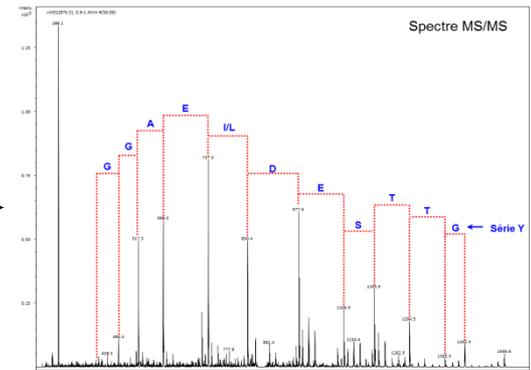


Séparation



Electrophorèse, Chromatographie, ...

Analyse MS/MS



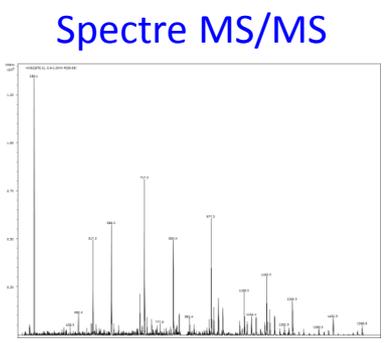
Spectrométrie de masse

10^4 molécules (protéines) de 500 acides aminés



$5 \cdot 10^5$ molécules (peptides) de 10 acides aminés

L'interprétation des données de l'analyse protéomique



Liste de masses expérimentales

MS	MS/MS
546,45	{ 789,67 876,43 999,12 1018,98 1342,34 1597,09 1678,95 2202,22

Banques de données de séquences protéiques

```
>Albumin  
ILPMVCCDEKTIHEDAVFRPMLVC  
KHFDIYTREHPKSDCWATTPMKF  
HLKETIPRHVVCDETR...
```

Séquences connues ou « théoriques »:
Jusqu'à 1Go de fichier texte



Listes de masses théoriques

MS	MS/MS
546,43	{ 789,69 876,41 987,50 999,14 1018,97 1342,30 1597,11 1678,99 1987,60 2202,24

Algorithmes d'identification

←→

Comparaison (confrontation) des listes de masses expérimentales/théoriques

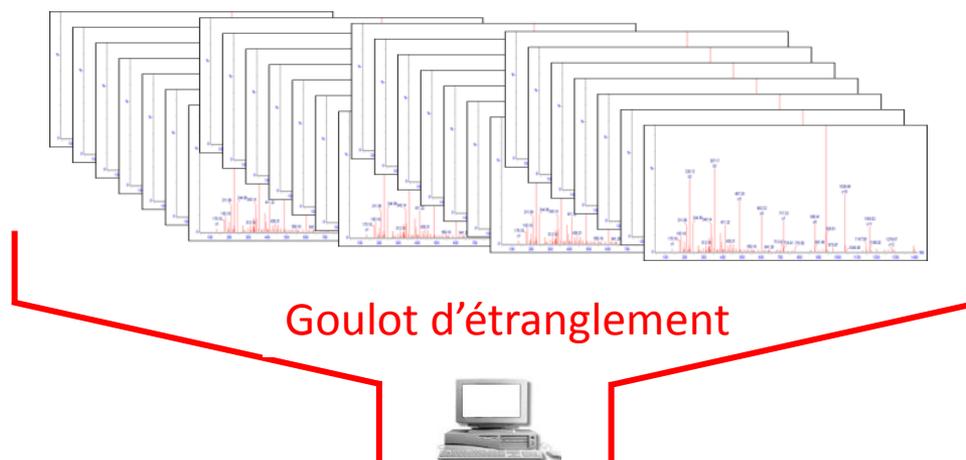
L'interprétation des données de l'analyse protéomique

Quelques chiffres:

Un spectromètre de masse génère 8000 spectres MS/MS par heure

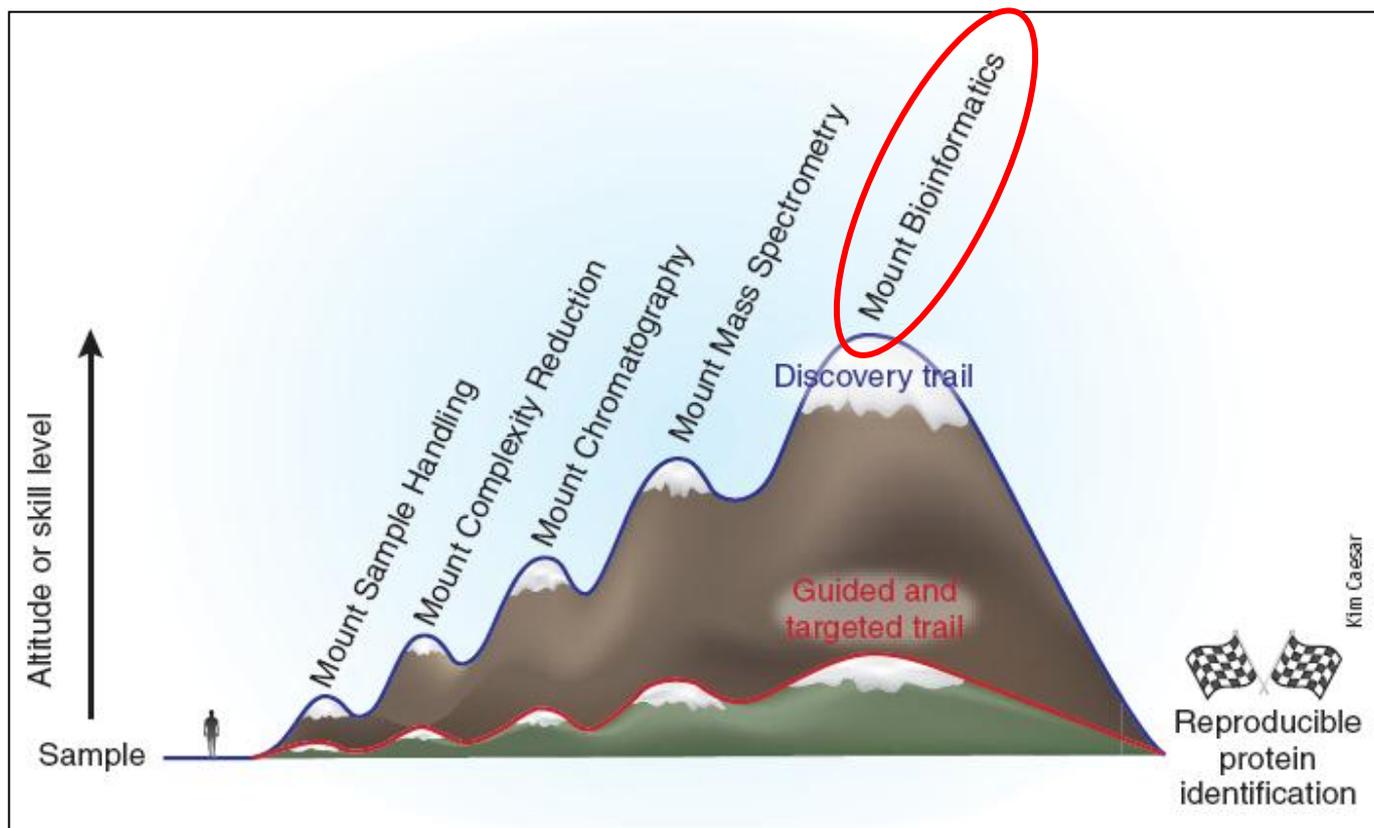
10 instruments au laboratoire travaillant 24h/24h

\cong 2 millions de spectres MS/MS acquis par jour



Interprétation par confrontation des données expérimentales/théoriques

L'interprétation des données de l'analyse protéomique



D'après R. Aebersold, « A stress test for mass spectrometry-based proteomics », Nature Methods, 6 (6), 411-412, June 2009.

L'interprétation des données est reconnue comme un verrou majeur de l'analyse protéomique!

Un avantage:

Chaque spectre MS/MS peut être interprété individuellement dans la banque de données de séquences protéiques choisie.

➤ **Utilisation de la grille adaptée**

Avec néanmoins une exigence:

Un unique spectre MS/MS peut être à l'origine de l'identification de LA protéine d'intérêt (le biomarqueur par exemple).

➤ **Développement de Vigrid et MSDA**

MSDA est une plateforme d'outils d'interprétation des données de protéomique.

Vigrid est une application indépendante développée pour permettre aux outils de MSDA de s'exécuter sur la grille.

Dans la mythologie nordique:

- Vigrid est le dieu des histoires
- Marié à Sága, déesse des contes et des légendes

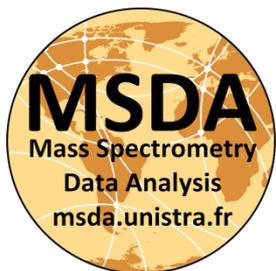
Trois objectifs pour Vigrid:

1. Optimisation des temps de latence des jobs
 2. Supervision des jobs
 3. Tolérance aux pannes
- Utilisation de la librairie JSAGA (développée au Centre de Calcul de Lyon)
Java implementation of the Simple API for Grid Applications
([SAGA](#)) specification from the Open Grid Forum ([OGF](#)).

Pour les détails techniques, voir démo durant la session de poster (Patrick Guterl et Alexandre Burel)

- Vigrid permet d'optimiser le temps d'exécution par une gestion dynamique et de garantir l'interprétation de l'ensemble des données de spectrométrie de masse.

MSDA (Mass Spectrometry Data Analysis)



La suite logicielle MSDA <https://msda.unistra.fr>

MSDA contient déjà 4 modules:

1. Une boîte à outils de génération des banques de données
2. Une interface conviviale de lancement de requêtes OMSSA sur la grille
3. Une boîte à outils d'annotations fonctionnelles
4. Une interface conviviale pour l'interprétation *de novo* des données MS/MS sur la grille

MSDA (Mass Spectrometry Data Analysis)

Depuis sa présentation au congrès de Spectrométrie de Masse et d'Analyse Protéomique en Avignon en Septembre 2011, MSDA compte :

≅ 30 utilisateurs internes à l'IPHC

et ≅ 50 laboratoires extérieurs autorisés

(laboratoires et plateformes de protéomique français et européens, industriels)



Répartition des utilisateurs de
MSDA en juillet 2012,
Et depuis de nouveaux utilisateurs
en Allemagne et au Brésil.

MSDA (Mass Spectrometry Data Analysis)

L'utilisation de la grille nous a permis:

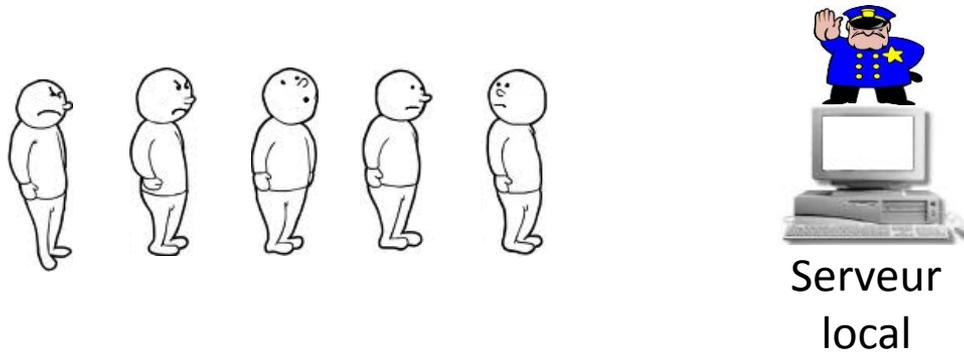
Un gain de temps net

Type d'expérience de spectrométrie de masse	Lancement sur un serveur local (h)	Lancement sur la grille (h)	Facteur de gain de temps
1.Spectrométrie de masse à haute résolution et spécificité enzymatique complète	0,3	0,2	1,5
2.Spectrométrie de masse à haute résolution et semi-spécificité enzymatique	5,8	0,5	12
3.Spectrométrie de masse à basse résolution et spécificité enzymatique complète	3,6	0,7	5
4.Spectrométrie de masse à basse résolution et semi-spécificité enzymatique	74,6	0,95	79

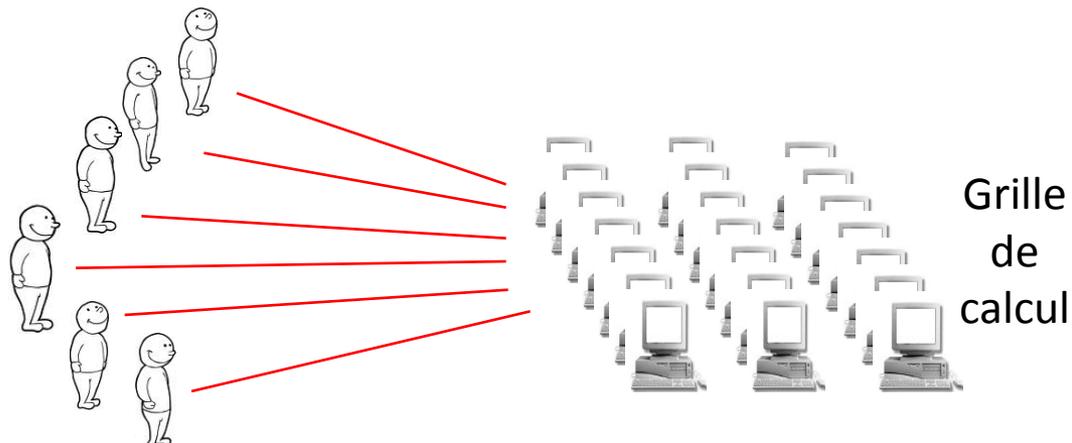
MSDA (Mass Spectrometry Data Analysis)

L'utilisation de la grille nous a permis:

Un gain de temps global



- Plus de file d'attente
- Plus il y a d'utilisateurs, plus le gain de temps est important
- Des études trop gourmandes en ressources auparavant deviennent envisageables



Conclusions

- La grille de calcul est adaptée pour l'interprétation des données de protéomique.
- Le goulot d'étranglement de l'interprétation des données de protéomique est désengorgé.
- L'utilisation de la grille ouvre de nouvelles possibilités d'interprétation des données de protéomique, non envisageables jusqu'ici: des projets censurés auparavant deviennent possibles!

Merci!

