

11. Bioinformatika a proteiny II

David Potěšil

Core Facility – Proteomics

CEITEC-MU

Masaryk University

Kamenice 5, A2

phone: +420 54949 7304

email: david.potesil@ceitec.muni.cz

Obsah přednášky

1. Co je to bioinformatika?
2. Evoluce proteinů, proteinové domény
3. Biologické sítě
4. Příklad využití bioinformatických nástrojů

1. Co je to bioinformatika?

1. Co je to bioinformatika?

Co představuje „bioinformatika“?

- vícero názorů...¹
 - Bioinformatics is conceptualizing biology in terms of macromolecules (in the sense of physical-chemistry) and, then, applying “informatics” techniques (derived from disciplines such as applied math, computer science, and statistics) to understand and organize the information associated with these molecules, on a large scale. (Luscombe, 2001, p. 346)
 - The mathematical, statistical and computing methods that aim to solve biological problems using DNA and amino acid sequences and related information. (Tekaia, n.d.)
 - Bioinformatics is the field of science in which biology, computer science, and information technology merge to form a single discipline. The ultimate goal of the field is to enable the discovery of new biological insights as well as to create a global perspective from which unifying principles in biology can be discerned. (National Center for Biotechnology Information, n.d.)
 - Computational biology is not a “field”, but an “approach” involving the use of computers to study biological processes and hence it is an area as diverse as biology itself. (Schulte, n.d.)
 - Biomedical informatics is the science underlying the acquisition, maintenance, retrieval and application of biomedical knowledge and information to improve patient care, medical education and health sciences research. (Friedman, n.d.)

1. Fenstermacher, D. Introduction to bioinformatics. *Journal of the American Society for Information Science and Technology* **56**, 440–446 (2005).

Co představuje „bioinformatika“? (2)

- „The enormous amount of data gathered by biologists – and the need to interpret it – requires tools that are in the realm of computer science. Thus, bioinformatics.“²
- studium metod pro uchování, zpětné vyvolání a analýzu biologických dat
 - sekvence nukleových kyselin (NK) a proteinů
 - proteinové struktury
 - funkce proteinů
 - metabolické a regulační dráhy („pathways“)
 - molekulární interakce (např. protein-protein, protein-NK, NK-NK)



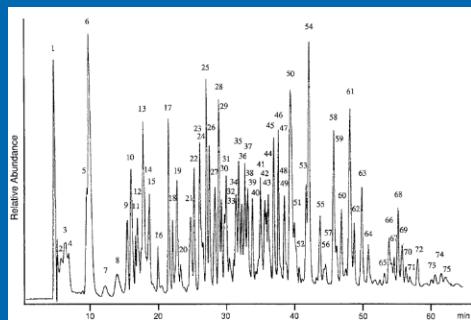
Příbuzné disciplíny

- „**data mining**“
 - analýza dat z různých perspektiv a „dolování“ shrnujících (zobecněných) informací
- **matematická a teoretická biologie**
 - matematická reprezentace, zpracování a modelování biol. procesů
- **lékařská informatika**
 - tvorba databáze medicínských informací a jejich další využití
- **biostatistika**
 - aplikace a vývoj statistických metod pro řešení biologických a klinických problémů
- **častý překryv s těmito i s dalšími obory** (záleží na konkrétní aplikaci)

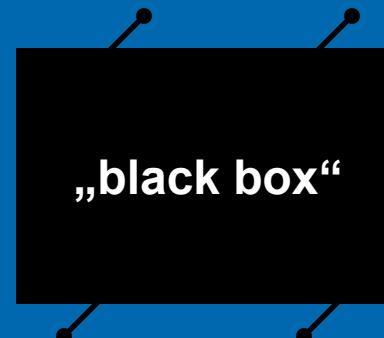
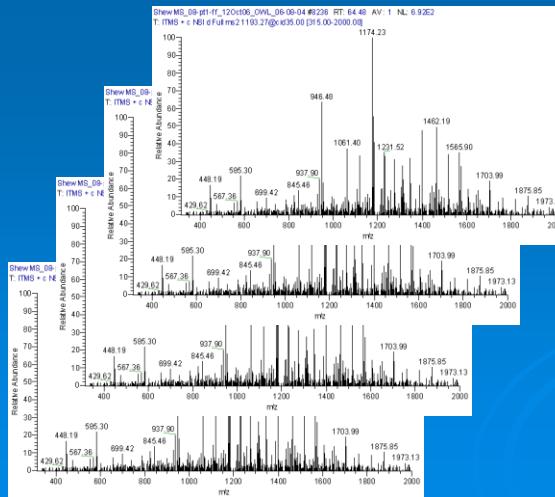
Příklad využití bioinformatických nástrojů

- protein-protein interakce založené na datech z hmotnostní spektrometrie spojené s kapalinovou chromatografií (LC-MS analýza peptidů)

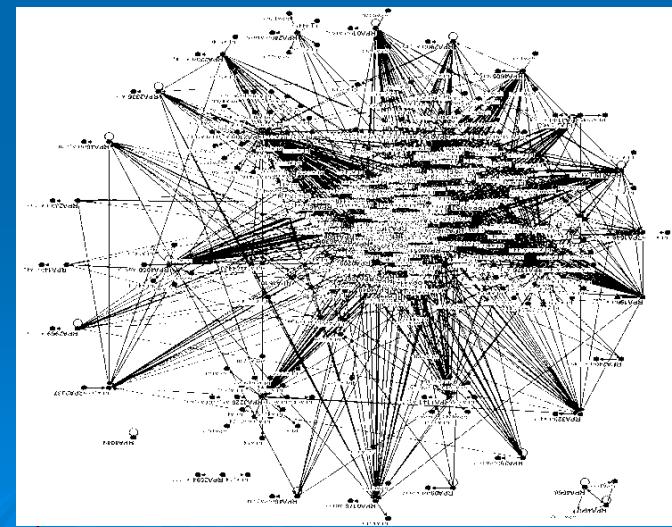
LC-MS záznam



MS/MS spektra



„standardní nastavení“

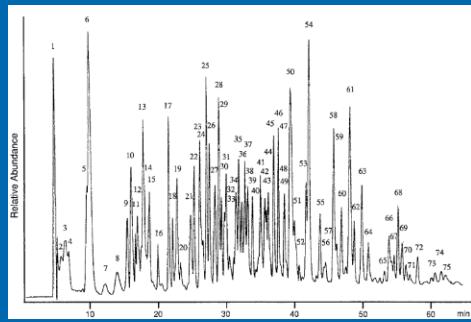


protein-protein interakční síť ?
závěry z analýze této sítě ?

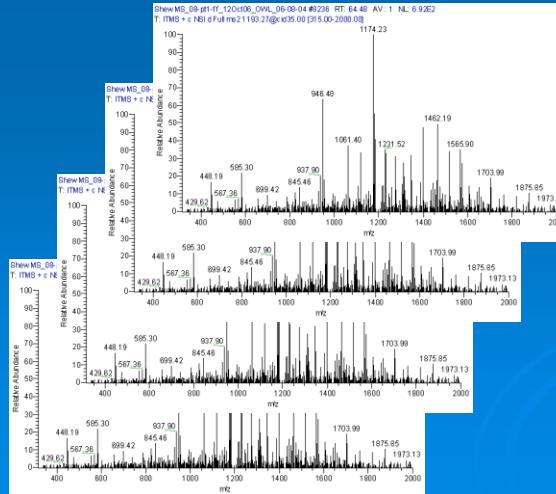
Příklad využití bioinformatických nástrojů

- protein-protein interakce založené na datech z hmotnostní spektrometrie spojené s kapalinovou chromatografií (LC-MS analýza peptidů)

LC-MS záznam



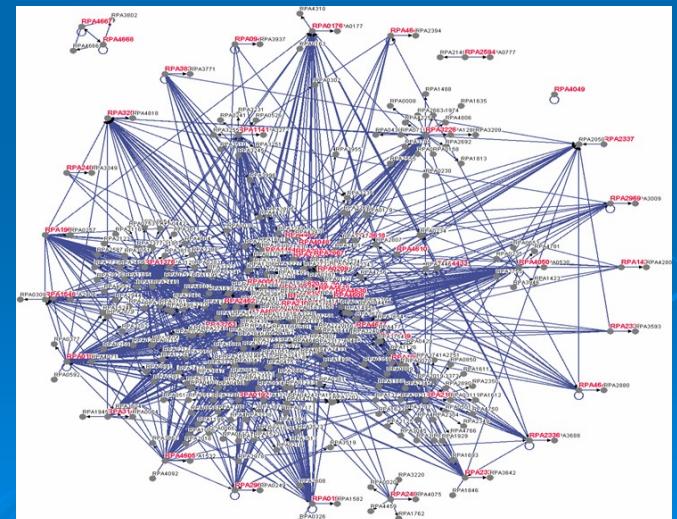
MS/MS spektra



protein-protein interakční síť
analýza sítě: úloha proteinu A z jeho interakcí



vystupům
přizpůsobené
nastavení



2. Evoluce proteinů, proteinové domény

Jedna z prvních aplikací bioinformatiky

– srovnání primárních sekvencí (homologie)

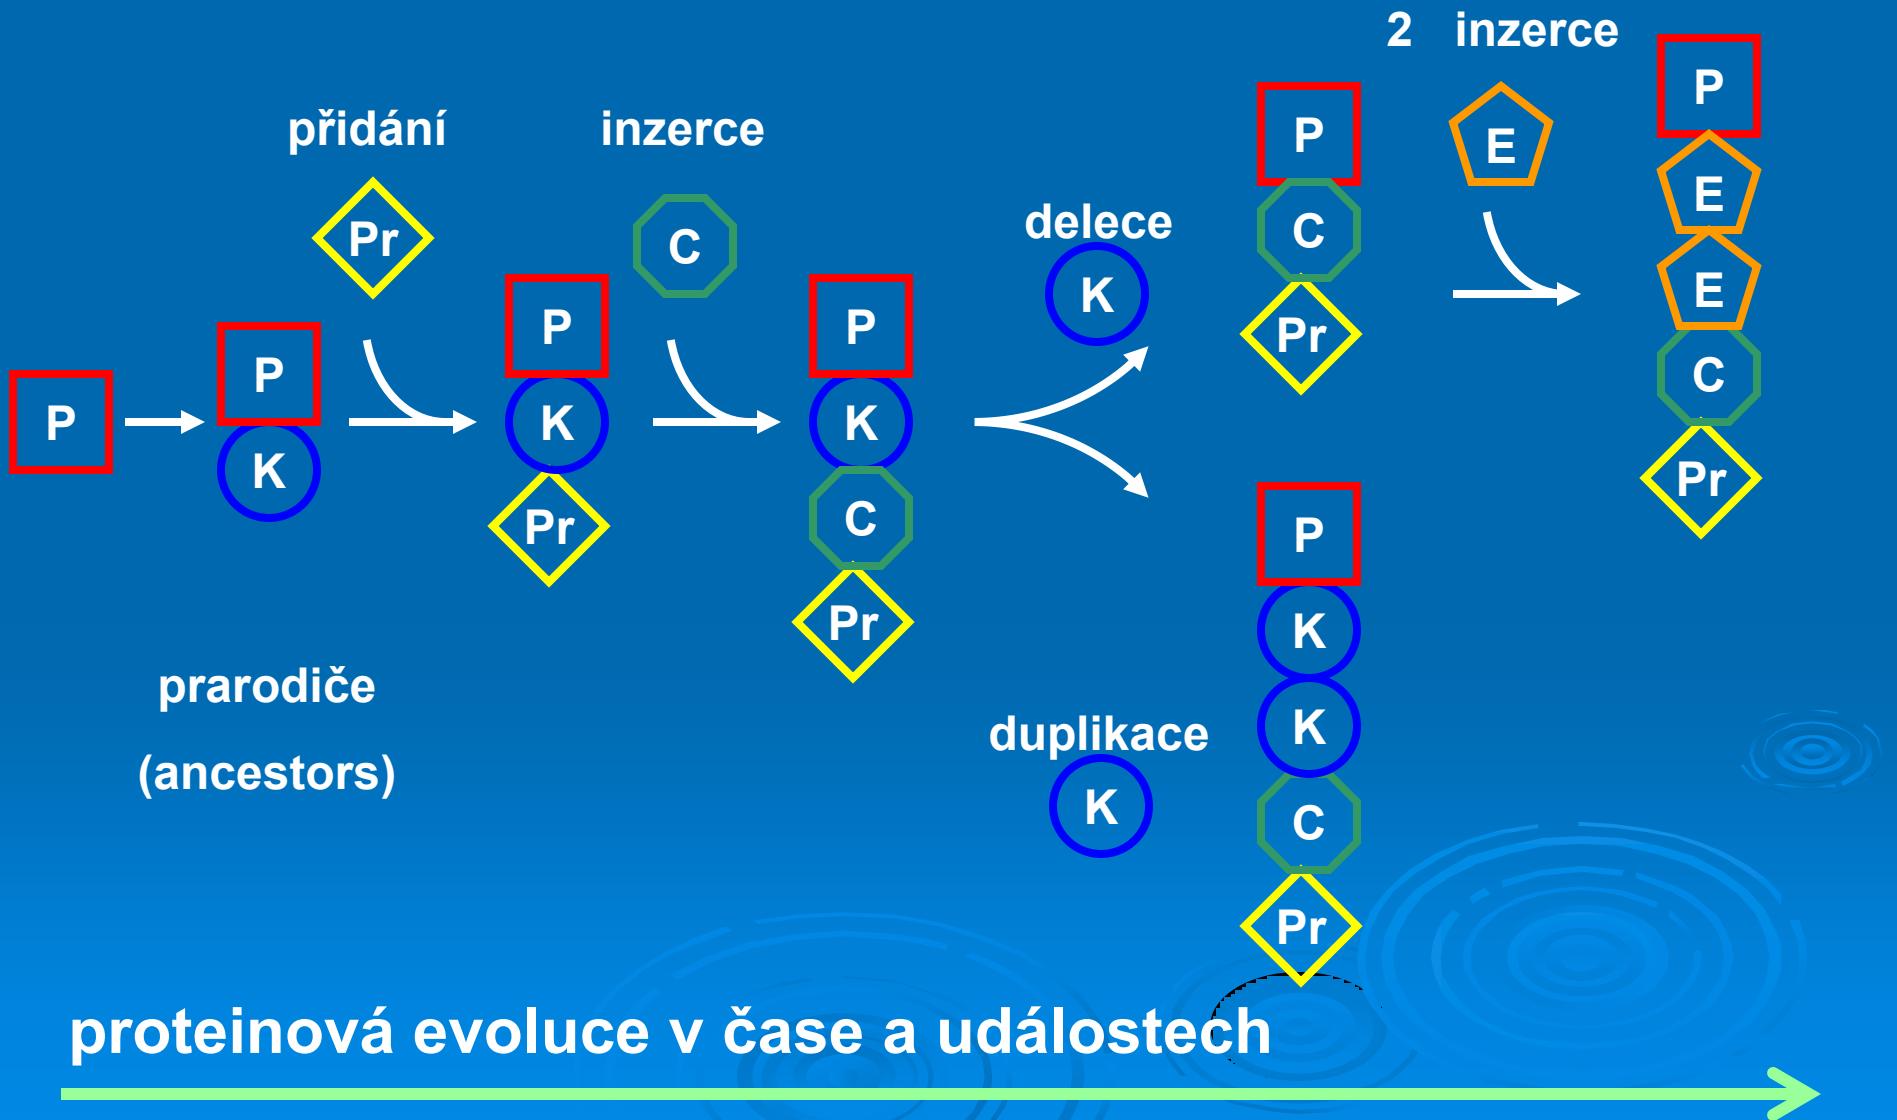
- BLAST – Basic Local Alignment Search Tool
- proč srovnávat primární sekvence?
 - podobnost v primární sekvenči proteinů
 - podobnost ve struktuře proteinů
 - ⇒ podobnost ve funkci proteinů...

Není tak jednoduché...

Proteinová evoluce a proteinové domény

- proteinová doména = nezávislá strukturní, funkční a evoluční jednotka
- 2/3 proteinů jednobuněčných a 80% proteinů mnohobuněčných organizmů je složených z více domén
- vznik „nových“ proteinů (proteinová, molekulární evoluce)
 - kombinace, duplikace, divergence stávajících domén (na úrovni genů)
 - kombinace/duplikace/změna domén ■ často odlišná funkce proteinu
 - změna struktury, spolupráce se sousedními doménami...
 - jednodoménové proteiny, stejná doména: ~67% šance na podobnou funkci
 - dvoudoménový protein, 1 stejná doména: ~35% šance na podobnou funkci
 - v průběhu evoluce dále nastávaly mutace v duplikovaných či zkombinovaných doménách často se zachováním strukturní podobnosti ■ sekvenčně odlišné, strukturně podobné

Proteinová evoluce a proteinové domény – příklad



Doménové superrodiny a rodiny („superfamilies“, „families“)

- proteinové domény je možné **klastrovat** na základě podobnosti
- podobnost možná na více úrovních
 - **sekvenční podobnost** (primární struktura proteinu/domény)
 - **strukturální podobnost** (sekundární a terciární struktura proteinu/domény)
 - **funkční podobnost** (nezávislá na sekvenční a strukturní podobnosti)
- doménové superrodiny a rodiny a podobnost
 - **strukturní, funkční podobnost** ⇒ **doménová superrodina**
 - stejný proteinový prarodiče, evolučně starší (mutace sekvence)
 - **sekvenční podobnost** ⇒ **doménová rodina**
 - evolučně mladší

Hlavní zdroje pro klasifikaci domén

- klasifikace domén do superrodin a rodin
- SCOP („Structural Classification Of Proteins“)
 - <http://scop.mrc-lmb.cam.ac.uk/scop/>
- CATH („Class, Architecture, Topology, Homologous Superfamily“)
 - <http://www.cathdb.info/>
- čerpají známé proteinové sekvence z Protein Data Bank (PDB)
- zpracovávanou jednotkou je proteinová „doména“

Proteinové rodiny a superrodiny

- obdobně jako u proteinových domén
 - častější klastrování na základě „sekvenční podobnosti“ (převážně „multiple sequence alignment“ algoritmy)  **sequence signatures**
 - využití **primárních sekvencí proteinů** ve zvolené databázi
- při klastrování je možno zvažovat různé části proteinu
 - funkční místa proteinu
 - funkční konzervativní motivy
 - funkční domény
 - strukturní domény
- **proteinová rodina** = „sekvenčně podobné“ proteiny
- **proteinová superrodina** = evolučně spjaté proteinové rodiny (není nutná sekvenční podobnost) – souhrn proteinů v evolučně spjatých prot. rodinách

Proteinové rodiny a superrodiny – online zdroje

- různé databáze proteinových rodin a superrodin (viz. dále)
 - používají různé cílové proteinové databáze (primární sekvence)
 - UniProtKB (SwissProt a TrEMBL)
 - NCBI RefSeq
 - proteinové databáze pro vybrané kompletně osekvenované organizmy
 - ...
 - používají různé části proteinu pro predikci rodin/superrodin
- integrální zdroje
 - sbírají informace z více zdrojů a prezentují na jediném místě
 - InterPro
 - CDD

| Bioinformatic tool/URL | Database source | Clustering method | Cluster information based on | Protein families or signatures |
|---|---|-----------------------|---|--------------------------------|
| Signature databases | | | | |
| ProtClustDB Dec 2 2010/ http://www.ncbi.nlm.nih.gov/proteinclusters | NCBI RefSeq | Clique based | Functional domains | 627757, 10885 (curated) |
| Pfam 25.0/ http://pfam.sanger.ac.uk/ | UniProtKB | HMMs | Functional domains | 12273 (Pfam-A) |
| PROSITE 20.68/ http://expasy.org/prosite/ | UniProtKB | Patterns, profiles | Functional sites | 1598 |
| PRINTS 41.1/ http://www.bioinf.manchester.ac.uk/dbbrowser/PRINTS/index.php | UniProtK | Fingerprints | Functional conserved motifs | 2050 |
| ProDom 2006.1/CG267/ http://prodom.prabi.fr/prodom/current/html/home.php | UniProtKB/267 completed genomes (one from plants) | MKDOME2 | Functional domains | 574656/301126 |
| SMART 6.1/ http://smart.embl-heidelberg.de/ | UniProtKB/760 completed genomes (one from plants) | HMMs | Functional domains | 895 |
| TIGRFAMs 10.0/ http://www.jcvi.org/cms/research/projects/tigrfams/overview/ | UniProtKB | HMMs | Functional domains | 4025 |
| PIRSF 2.74/ http://pir.georgetown.edu/pirwww/dbinfo/pirsf.shtml | UniProtKB | HMMs | Functional domains | 3248 (curated) |
| SUPERFAMILY 1.75/ http://supfam.cs.bris.ac.uk/SUPERFAMILY/ | 1452 completed genomes (27 from plants)/UniProtKB/PDB | HMMs | SCOP domains | 2019 |
| GENE3D 10.0.0/ http://gene3d.biochem.ucl.ac.uk/Gene3D/ | 1867 completed genomes | HMMs | CATH domains | 2549 |
| PANTHER 7.0/ http://www.pantherdb.org/ | 48 completed genomes (three from plants) | HMMs | Functional domains | 6594 |
| Integrative signature databases | | | | |
| InterPro 31.0/ http://www.ebi.ac.uk/interpro/ | UniProtKB | Signature integration | Gene3D, HAMAP, PANTHER, Pfam, PIRSF, PRINTS, ProDom, PROSITE, SMART, SUPERFAMILY, TIGRFAMs signatures | 21185 |
| CDD 2.26/ http://www.ncbi.nlm.nih.gov/Structure/cdd/cdd.shtml | NCBI Database | PSSMs | NCBI-curated domains, Pfam, SMART, COGs, ProtClustDB signatures | 41593 |

A4

Fylogenetická podobnost

- fylogenetika
 - studuje evoluční vztah organismů
 - používá molekulární sekvenování a morfologická data

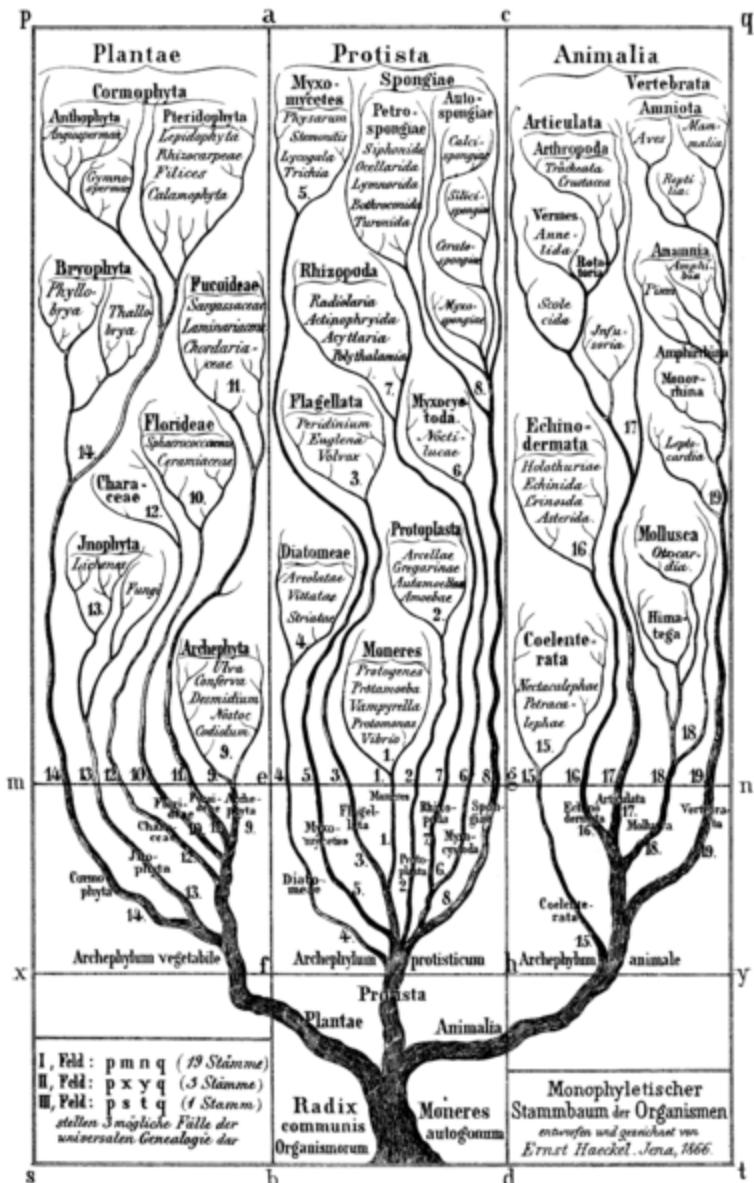
■ voluční vývoj organismů

⇒ fylogenetický strom

- změny v dědičné informaci v průběhu evoluce

■ organizmy evolučně blíže

⇒ proteiny sekvenčně blíže



fylogenetický strom - Haeckel (1866)

Fylogenetická podobnost – organizmy s nezveřejněným genomem

- použití dostupných informací pro evolučně co nejbližší organizmy
- při studiu pomocí hmotnostní spektrometrie (MS)
 - MS běžně vychází ze známých proteinových sekvencí pro organizmy se známým genomem...
 - použití **EST databáze** („expression sequence tags“)
 - většinou nekompletní úseky cDNA/mRNA (exprimovaných genů)
 - sekvenční data relativně nízké kvality („single pass“ sekvenace)
 - lze přepsat do aminokyselinové sekvence
 - **de novo sekvenace/identifikace peptidů** (z MS/MS spektra se přímo určí možný peptid)
 - **Blast de novo peptidů** proti zvolené databázi (omezená taxonomie)

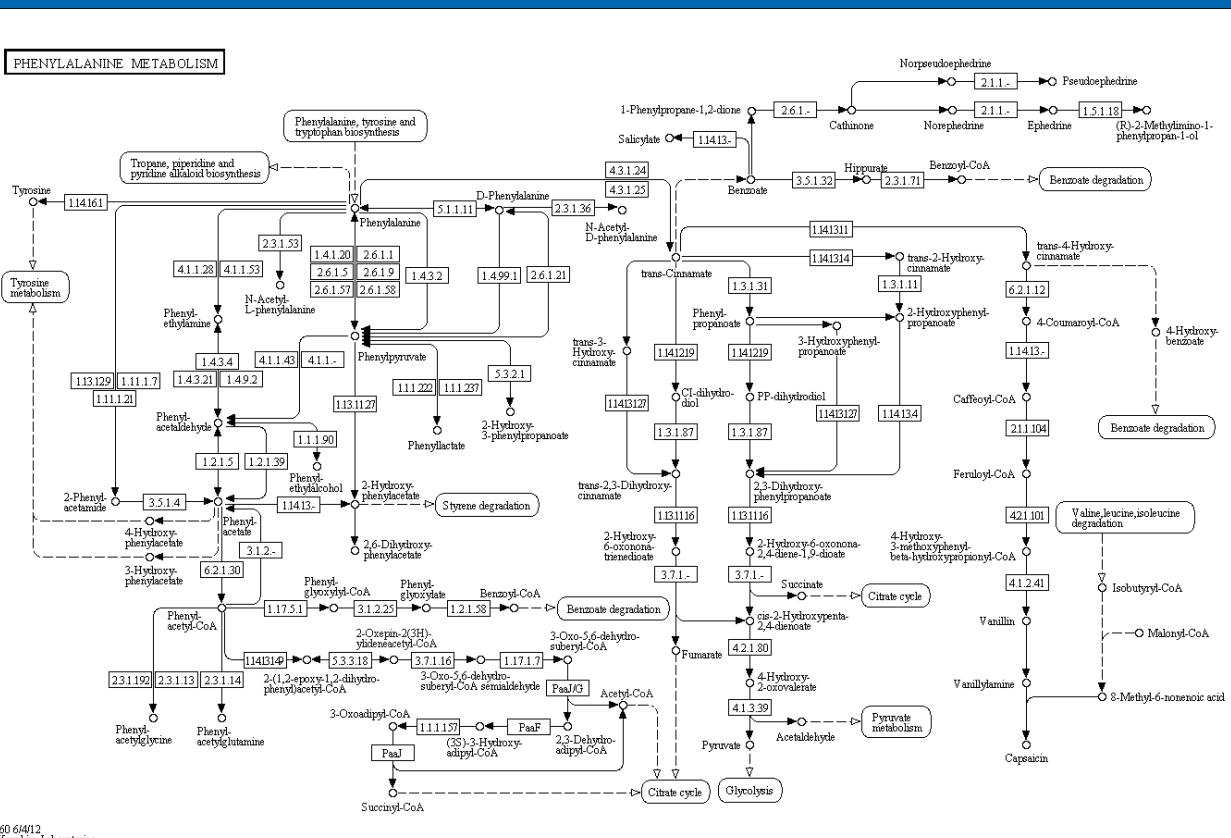
3. Biologické sítě

Biologické sítě

- snaha o zachycení celého světa pomocí jeho jednotlivých složek („nodes“) a vztahů mezi nimi („edges“) – vytváření sítí („networks“)
 - prvopočátky již v 18. století...
- biologická síť = sada molekul (např. proteinů, geny, metabolity = „nodes“) propojených pomocí definovaných, funkčních vztahů (např. protein-protein interakce = „edges“)

Biologické sítě – příklady

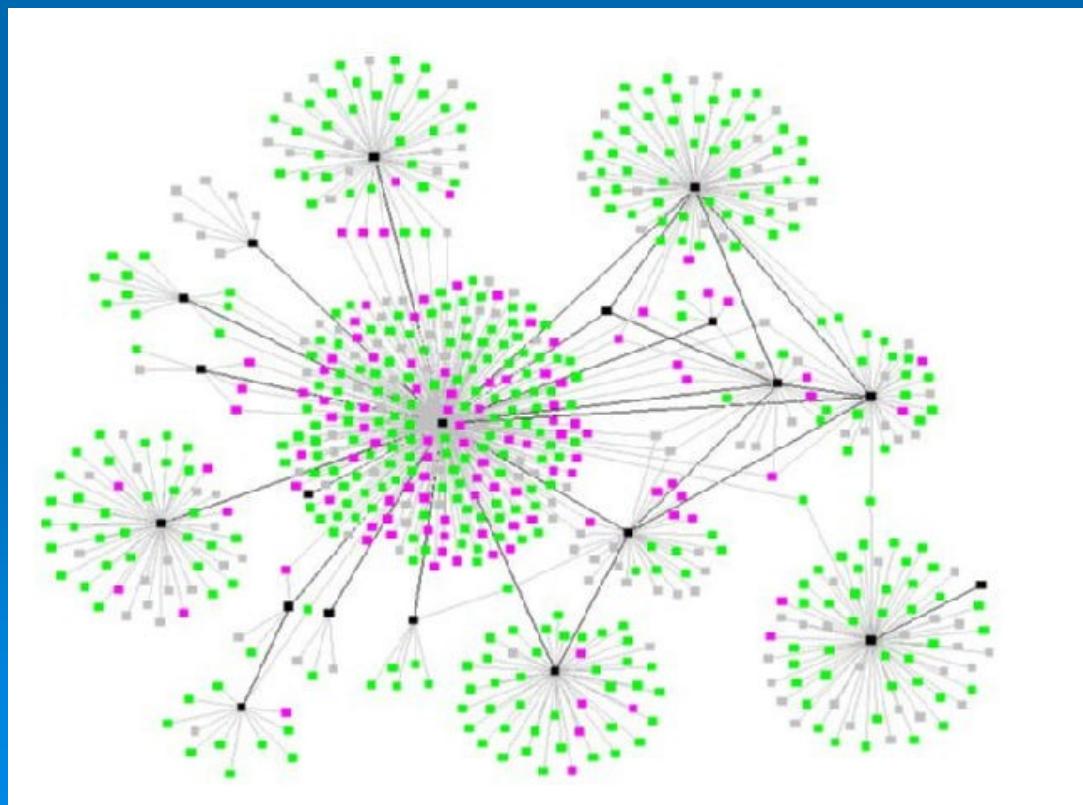
- metabolické dráhy („metabolic pathways“)
 - spojují proteiny skrze produkty a reaktanty
 - produkt jednoho = substrát druhého**
 - např.; např. KEGG; WikiPathways



část metabolické sítě –
metabolismus Phe (KEGG)

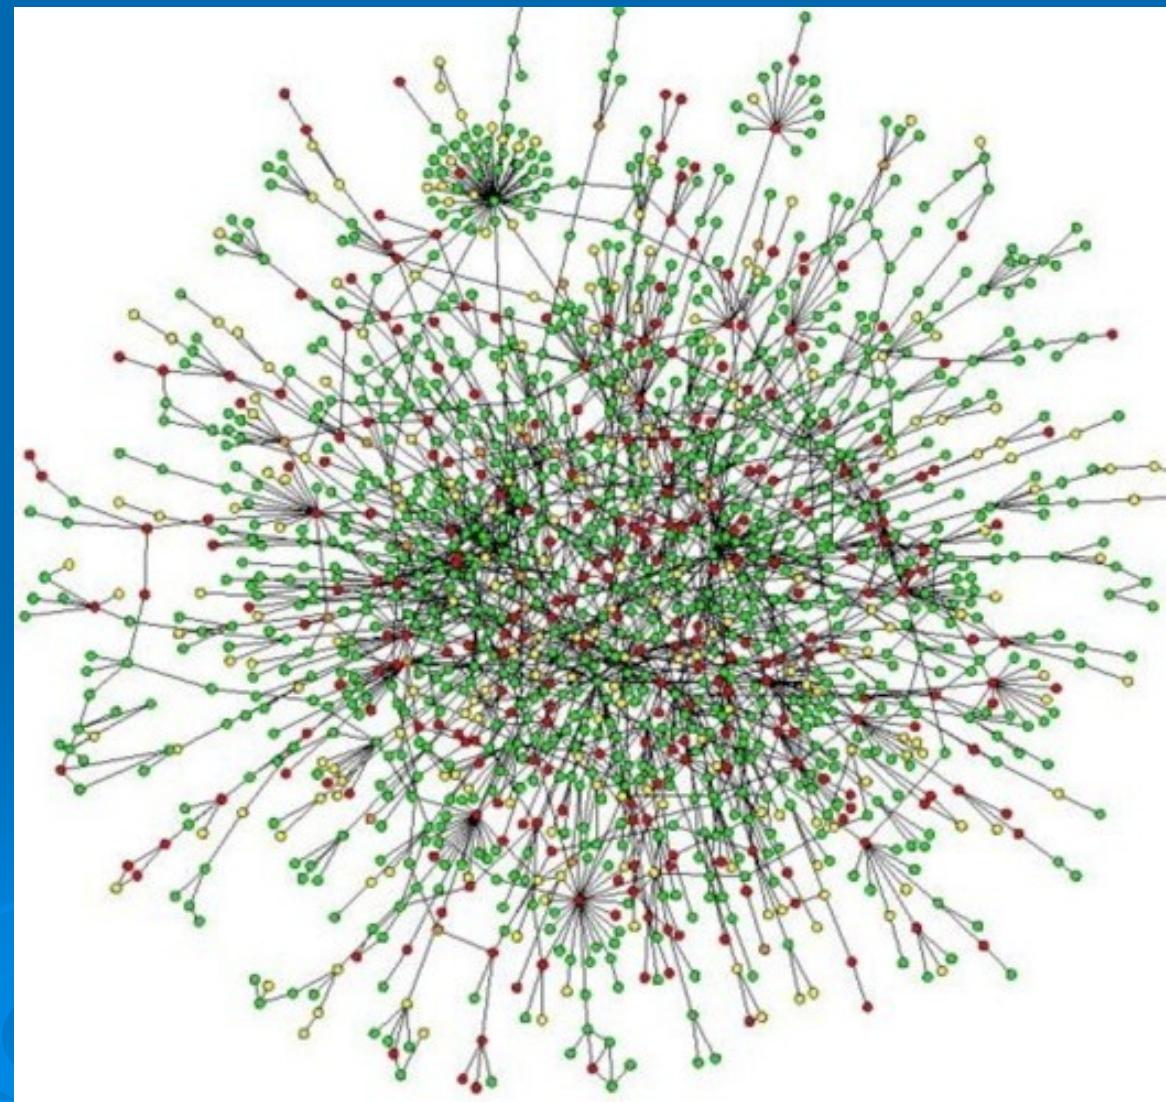
Biologické sítě – příklady (2)

- sítě regulace genů („gene regulatory networks“; „DNA-protein interaction networks“)
 - transkripční vztah mezi dvěma proteiny
 - jeden protein ovlivňuje expresy genu druhého proteinu



Biologické sítě – příklady (3)

- protein-protein fyzické interakce – ze sítě samotné není přímá informace o významu dané interakce...
 - příklady databází
 - MINT
 - DIP
 - BioGRID
 - STRING
 - ...



Biologické sítě – příklady (4)

- proteiny anotované do stejné kategorie genové ontologie (GO) – viz. dále
 - proteiny přítomné ve stejně GO kategorii mají společné
 - a) lokalizaci v buňce (např. jaderná membrána)
 - b) molekulární funkci (např. vazba iontů Ca)
 - c) biologický proces, ve kterém participují (např. metabolismus Ca)

(dle příslušného GO termínu, vysvětleno dále...)

3. Biologické sítě

Biologické ontologie, KEGG

Biologické ontologie

- ontologie = systém kategorií (termínů; „terms“) do kterých jsou zařazeny jednotlivé informační jednotky, spolu s jejich vlastnostmi a vztahy
- biologické ontologie – příklady
 - proteiny („gene products“) – genová ontologie (GO)...
 - průběh buněčného dělení („Cell Cycle Ontology“)
 - vývoj rostliny *A. thaliana* („Arabidopsis development“)
 - stále živý proces úprav/oprav/doplňení ontologií; není statické
- OLS – „Ontology Lookup Service“
 - <http://www.ebi.ac.uk/ontology-lookup/>
 - jednotný přístup k více ontologiím
 - možnost procházet celé ontologie, případně vyhledávat termíny

Genová ontologie (GO)

- nejvíce rozpracovaná biologická ontologie
 - jak co do počtu termínů, tak co do počtu anotovaných položek (proteinů)
- společné termíny pro všechny organizmy
- <http://www.geneontology.org/> + AmiGO prohlížeč (online, offline)
- tři GO domény
 - buněčná komponenta („cellular component“)
 - informace o buněčné lokalizaci proteinu
 - molekulární funkce („molecular function“)
 - informace o funkci proteinu
 - biologický proces („biological process“)
 - informace o procesech, kterých se protein účastní
- GO Slims (podmnožina GO termínů; organizmus, specifická aplikace, ...)

Genová ontologie (GO) (2)

- kde se berou data pro GO?
 - každá anotace obsahuje informaci o svém původu – „evidence code“
 - A) manuálně přiřazené správcem/kurátorem („curator“)
 - „experimental evidence codes“ [] reálného experimentu
 - „computational analysis evidence codes“ [] *in silico* analýzy
 - „author statement evidence codes“ [] výrzení autora + citace
 - „curatorial statement codes“ [] výrzení správce, nepatří výše...
(všechny kategorie se dále dělí...)
 - B) automaticky přiřazené (bez zásahu správce)
 - „automatically-assigned evidence code“
 - „Inferred from Electronic Annotation“ (IEA)

Společné znaky anotovaných proteinů

- srovnání biologických entit na základě jejich anotace v rámci dané ontologie – **sémantická podobnost**
- srovnání biologických entit na základě jejich funkce – **funkční podobnost**
- např. proteiny se stejnou funkcí lokalizované v jiné části buňky

KEGG

- KEGG = „Kyoto Encyclopedia of Genes and Genomes“
- manuální katalogizace znalostí biologických systémů v počítačově zpracovatelné podobě
- čerpá z dosavadních znalostí v dané problematice
- z informací na nízké biologické úrovni nám umožní odvodit informace na vyšší biologické úrovni
 - například ze seznamu regulovaných genů/proteinů odvodí informaci o ovlivněných metabolických drahách – KEGG Pathway

3. Biologické sítě

Příklady použití

Biologické sítě – použití („network analysis“)

- sledujeme vliv nízkomolekulární látky na rostlinu a identifikovali jsme sadu rozdílně exprimovaných proteinů...
 - jsou tyto proteiny zahrnuty v příslušné metabolické dráze? (KEGG)
 - jaké metabolické dráhy byly „významně“ zastoupeny? (test na statistickou významnost „identifikace“ (= pokrytí) dráhy v našem proteinovém listu) – „+“ i „–“ regulace
 - jsou známy proteinové komplexy mezi nalezenými proteiny?
 - je mezi proteiny zastoupeno více proteinů z konkrétního GO termínu?
- studujeme interakční partnery zvoleného proteinu...
 - vidíme již známé interakční partnery?
 - možno predikovat potencionální protein-protein interakce; následuje studium společných vlastností – GO termíny, metabolické dráhy?

Biologické sítě – použití („network analysis“) (2)

- pozorujeme protein, který má vztah k onkologickému onemocnění...
 - interaguje tento protein s dalšími proteiny?
(zvýšená pravděpodobnost, že se tyto proteiny aktivně účastní daného onemocnění ■■■ potencionální cíle dalšího studia a nové léčby)
- „zdraví versus nemocní“ – rozdílné proteiny
 - kterých metabolických drah se účastní? vysvětluje to důsledky nemoci?
 - jsou rozdílné proteiny převážně lokalizované v některé z organel?

Biologické sítě – použití („network analysis“) (3)

- na co si dát pozor?
 - falešně pozitivní i negativní informace v biologických sítích
(nedostatečná citlivost současných přístupů pro studium)
 - mnoho dat v databázích z predikčních studií
(i přes kontrolu nemusí zcela odpovídat)
 - stále víme málo...
 - volba vhodných otázek, na které nám sítě dokážou dat odpověď

Biologické sítě – použití („network analysis“) (4)

- jak se postavit k výstupům?
 - manuální validace výstupů
 - ověřením původních zdrojů
- pochybovat a ptát se
- experimentální ověření našich závěrů
- není důležité jak to vypadá, ale co se z toho dá vyčíst...

4. Příklad využití bioinformatických nástrojů

Zavedení problému

- studium proteinových komplexů vybraného proteinu
- imunoprecipitace proteinových komplexů (IP experiment)
 - protilátku proti proteinu, u kterého chceme zjistit jeho partnery („bait“)
 - dva hlavní přístupy
 - protilátku imobilizovaná např. na kuličkách (magnetické, v kolonkách)
 - protilátku se přidá do volného roztoku a následně „lovíme“ protilátku
 - nutno opakovat experiment s různými protilátkami (epitopy, stérické zábrany, potvrzení předchozích experimentů)
 - nativní prostředí při experimentech
 - paralelně experimenty bez „bait“ – „bead proteome“

LC-MS/MS analýza „pull-down“ vzorků

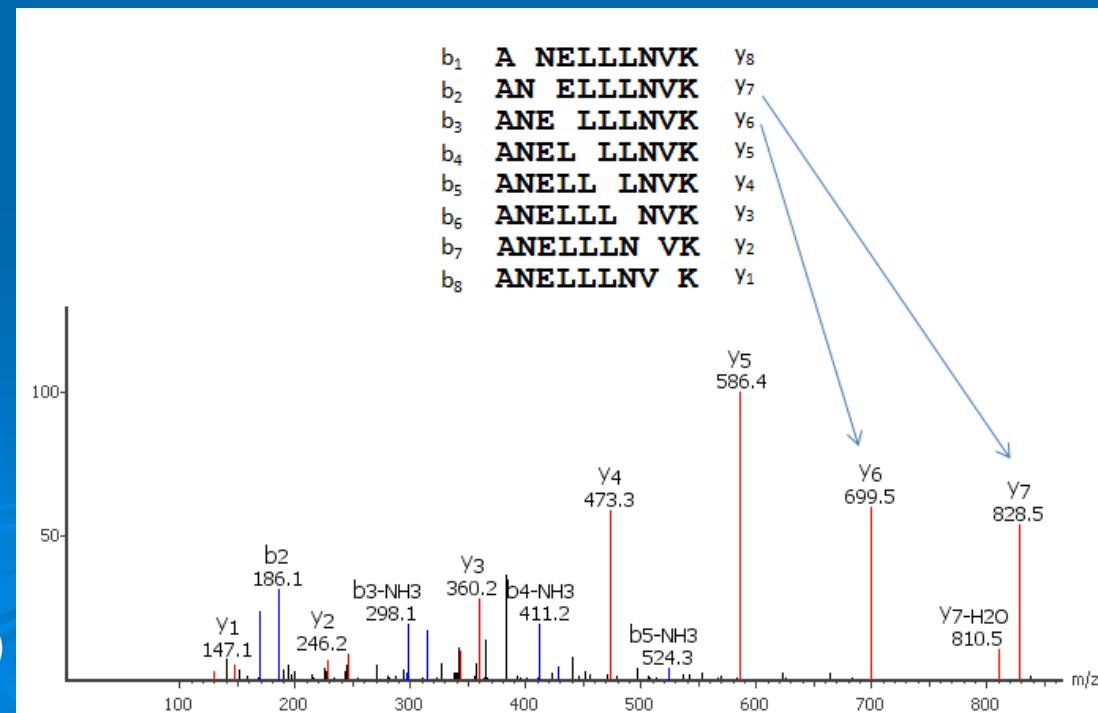
- digesce proteinů → peptidy
- LC-MS/MS analýza směsi peptidů
 - peptidy vstupují do MS v pořadí rostoucí hydrofobicity (LC separace)
- MS zjistí MW peptidů a získá MS/MS spektra
(fragmentační spektrum vybraného peptidu)

např. peptid **ANELLNVK**

(MW 1012.5917 Da)

1. MW_{exp} = 1012.5923 Da
(0,6 ppm chyba)

2. změřené fragmentační
(MS/MS) spektrum →
(CID; „collision induced dissociation“)

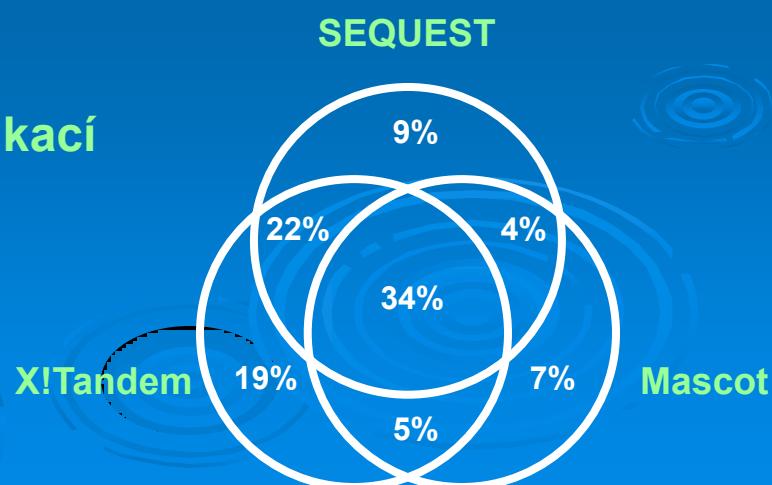


Zpracování LC-MS/MS dat

- LC-MS/MS data z analýz „pull-down“ vzorků po digesci = MS/MS spektra
- řádově 1 000 – 100 000 MS/MS spekter
- identifikace peptidů
 - vycházíme z proteinové databáze, např. UniRef100, *Homo sapiens*
 - *in silico* se vytvoří seznam možných peptidů
 - >20 algoritmů pro automat. přiřazení MS spektra možným peptidům (Sequest, Mascot, XTandem!, OMSSA, Phenyx, Andromeda, ...)
 - jiný algoritmus ■■■ný přístup ■■■uzná citlivost ■■■dlišné výsledky

kombinace algoritmů ⇒

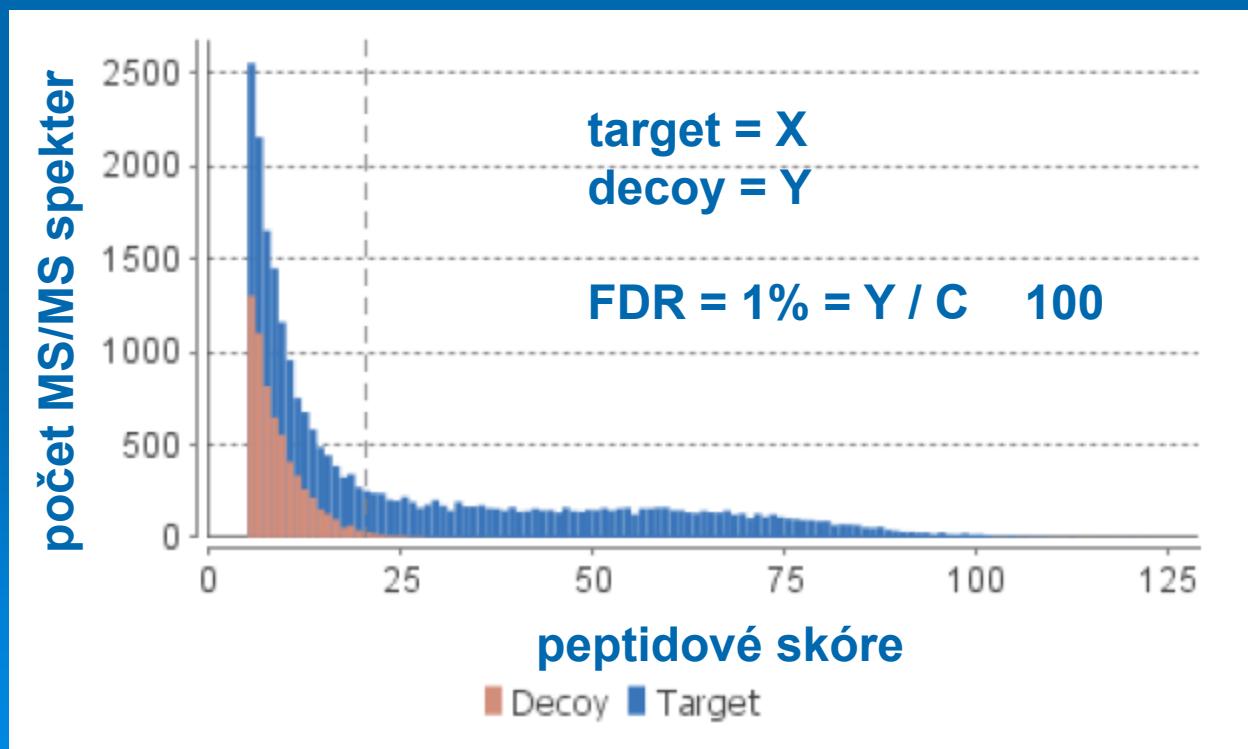
zvýšení počtu identifikací



Zpracování LC-MS/MS dat (2)

- „decoy“ proteinová databáze a FDR („false discovery rate“)
 - „decoy“ databáze – např. obrácené sekvence, náhodné sekvence proteinů
 - identifikace peptidů v cílové i „decoy“ proteinové databázi

⇒ jeden z možných přístupů jak určit FDR – peptidová úroveň



Zpracování LC-MS/MS dat (3)

- z identifikovaných peptidů k proteinům
 - problém u „**bottom-up**“ přístupu
 - v MS analýze **vidíme jen malou část** z např. tryptických **peptidů** proteinů a navíc nevíme ze kterých proteinů původně pochází...

⇒ **problém s určením seznamu proteinu**

(sadě peptidů může odpovídat více proteinů – isoformy, sekv. homology; proteiny identifikované jen na jeden peptid?)

Pohled na seznamy identifikovaných proteinů

- dva seznamy identifikovaných proteinů v našem IP experimentu
 - vzorek po IP experimentu s naším proteinem – Proteiny A
 - slepý vzorek; „bead proteome“ – Proteiny B
- co nás zajímá v našem IP experimentu nejvíce?

Pohled na seznamy identifikovaných proteinů (2)

- proteiny „navíc“ v A
 - 1) kvalitativní změny (A: „ano“, B: „ne“) – citlivost použitého přístupu...
 - 2) kvantitativní změny (A: „více“, B: „méně“)
 - možno pracovat pouze s intenzitami A a B peptidů – „label-free“
 - přesnost, správnost?
 - vzorky A a B byly zpracovány tak, že jsme pomocí MS schopni rozlišit mezi A a B (**SILAC** – „**S**table **I**sotope **L**abeling by **A**mino acids in **C**ell **C**ultures“ – komplikované u rostlin, nekompletní inkorporace značených AA; **dusík** ^{15}N)

Co se seznamem proteinů „navíc“?

- 1) manuální prohledání dostupných informací v literatuře
- 2) www.UniProt.org (ID mapping, informace a odkazy na další databáze)
- 3) DAVID <http://david.abcc.ncifcrf.gov/home.jsp>
- 4) ANAP http://gmdd.shgmo.org/Computational-Biology/ANAP/ANAP_V1.0/
 - doplnění k přednášce
 - jen pro At
 - Source database – čerpá známé informace z databáze interakcí
 - Detection method – predikce možných protein-protein interakcí
(u predikované interakce uvádí důvod pro predikci)
- 5) Cytoscape
-

Děkuji za pozornost