

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

5. Biologické sítě
6. Biologické sítě – biologické ontologie, KEGG
7. Biologické sítě – příklady použití
8. Vybrané on-line zdroje
9. Několik zamýšlení závěrem
10. Příklad využití bioinformatických nástrojů

5. Biologické sítě

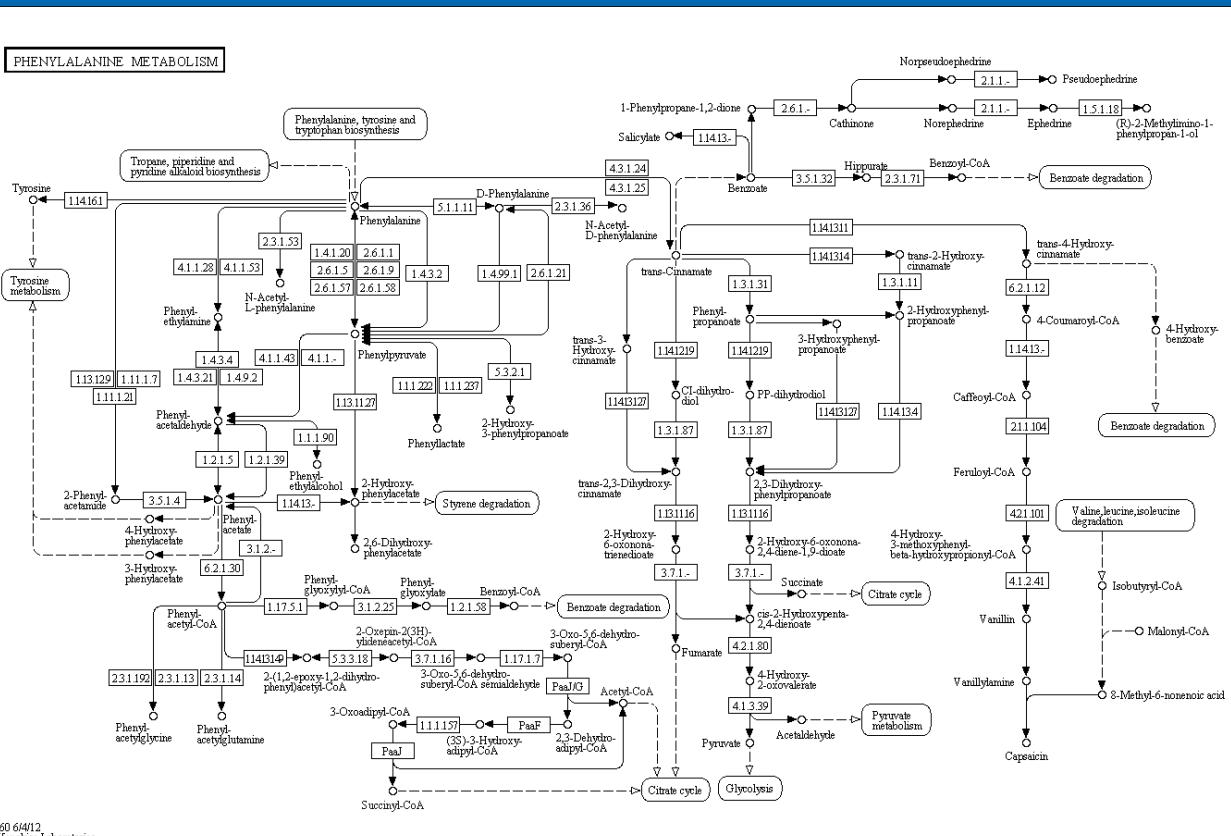
Biologické sítě

- 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*)

5. Biologické sítě

Biologické sítě – příklady

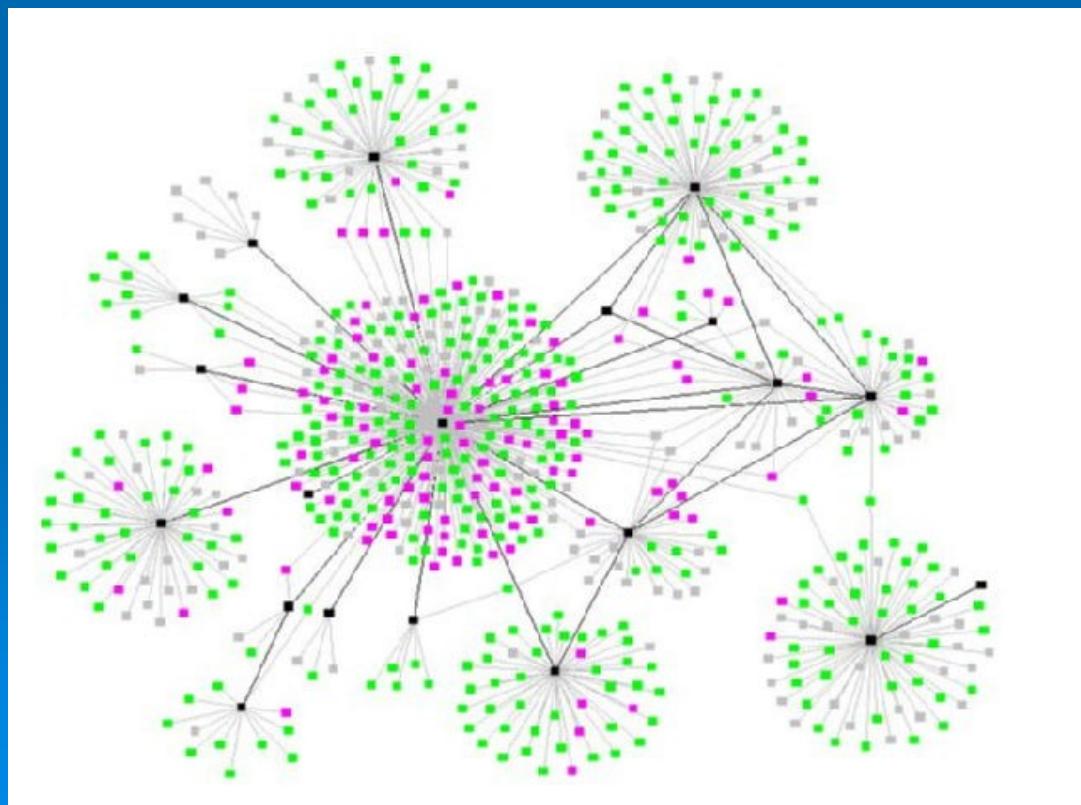
- metabolické dráhy (*metabolic pathways*)
 - spojují proteiny (*nodes*) skrze produkty a reaktanty (*edges*)
 - produkt jednoho = substrát druhého**
 - např. KEGG; WikiPathways



část metabolické sítě –
metabolismus Phe (KEGG)

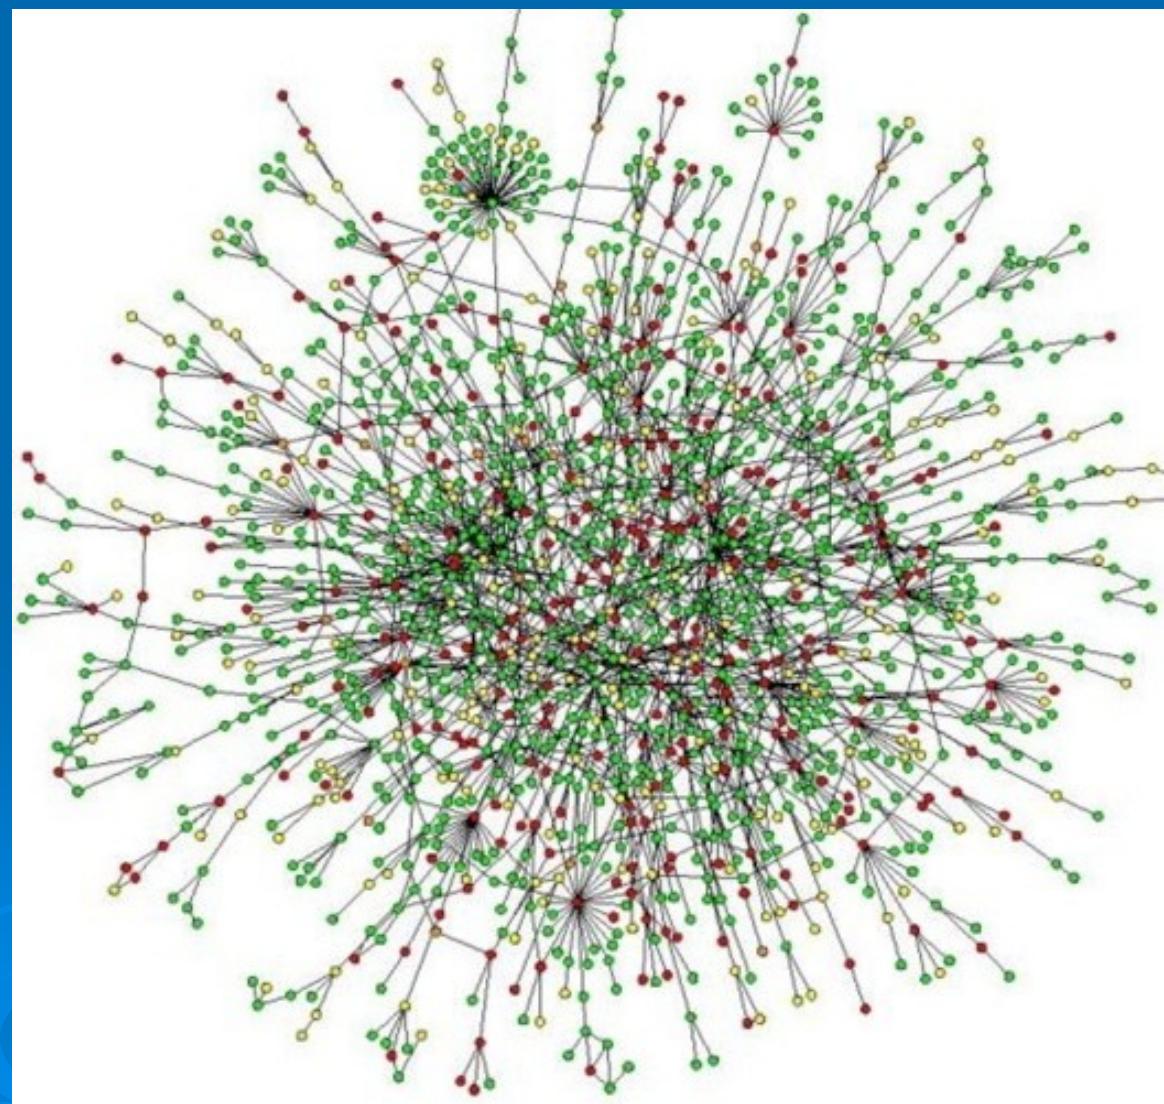
Biologické sítě – příklady (2)

- 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...
 - *nodes* – ?
 - *edges* – ?
 - příklady databází
 - STRING
(www.string-db.org)
 - MINT
 - DIP
 - BioGRID
 - ...



Biologické sítě – příklady (4)

- proteiny anotované do stejné kategorie genové ontologie (GO) – viz. dále
 - proteiny přítomné ve stejné GO kategorii mají společné např.
 - 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...)

6. 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
- 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, ...)
- <http://www.geneontology.org/> + AmiGO prohlížeč (online, offline)

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** ⇒ z reálného experimentu
 - **computational analysis evidence codes** ⇒ z *in silico* analýzy
 - **author statement evidence codes** ⇒ tvrzení autora + citace
 - **curatorial statement codes** ⇒ tvrzení správce, nepatří výše...
(všechny kategorie se dále dělí...)
 - B) automaticky přiřazené (bez zásahu správce)
 - **automatically-assigned evidence code**
 - *Inferred from Electronic Annotation (IEA)*

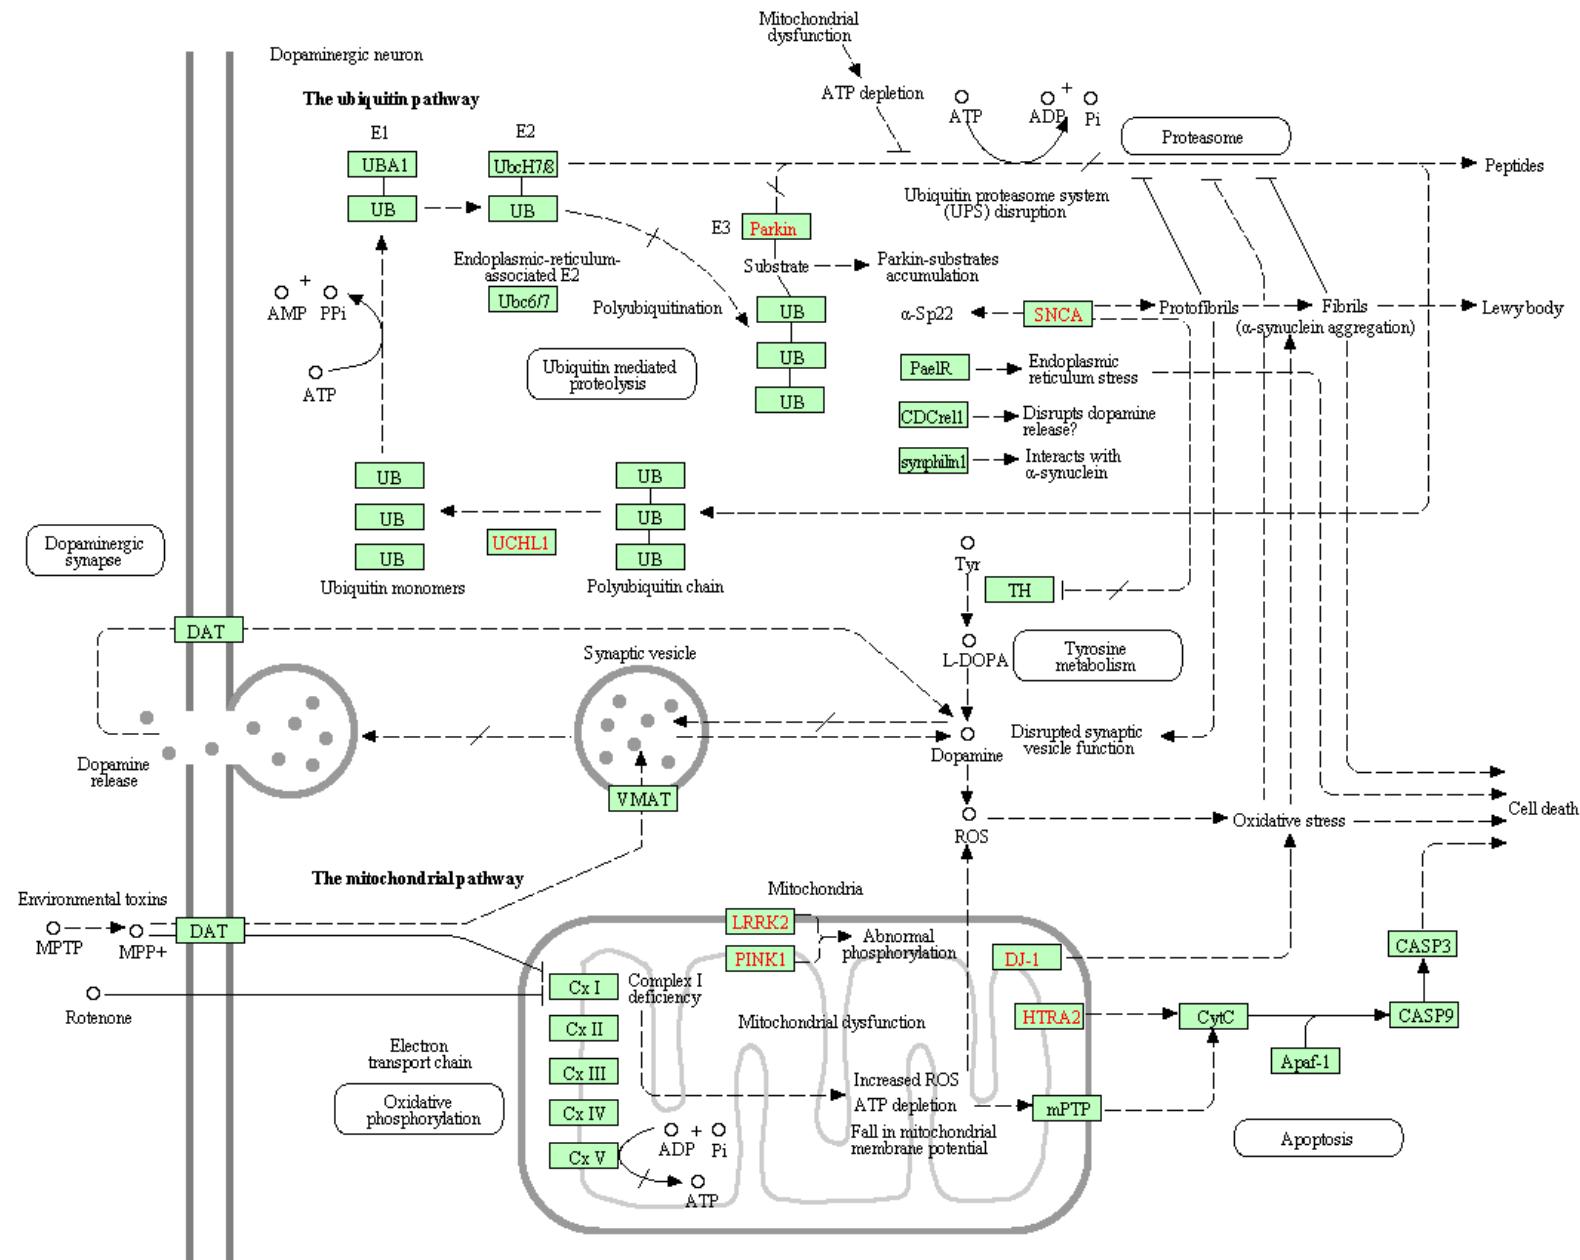
Společné znaky anotovaných proteinů v ontologiích

- srovnání proteinů na základě jejich anotace v rámci dané ontologie, např.
v GO – **sémantická podobnost**
 - jak jsou si proteiny blízké z pohledu jejich zařazení do GO termínů
 - většinou používána
- srovnání proteinů na základě jejich funkce – **funkční podobnost**
 - např. proteiny se stejnou funkcí lokalizované v jiné části buňky
 - z pohledu GO termínů mohou být relativně vzdálené
- stejně jdou srovnávat společné znaky a blízkost i např. GO termínů

KEGG

- KEGG = *Kyoto Encyclopedia of Genes and Genomes*
- <http://www.genome.jp/kegg/>
- 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
- obdobně i např. <http://www.reactome.org>

PARKINSON'S DISEASE



7. Biologické sítě

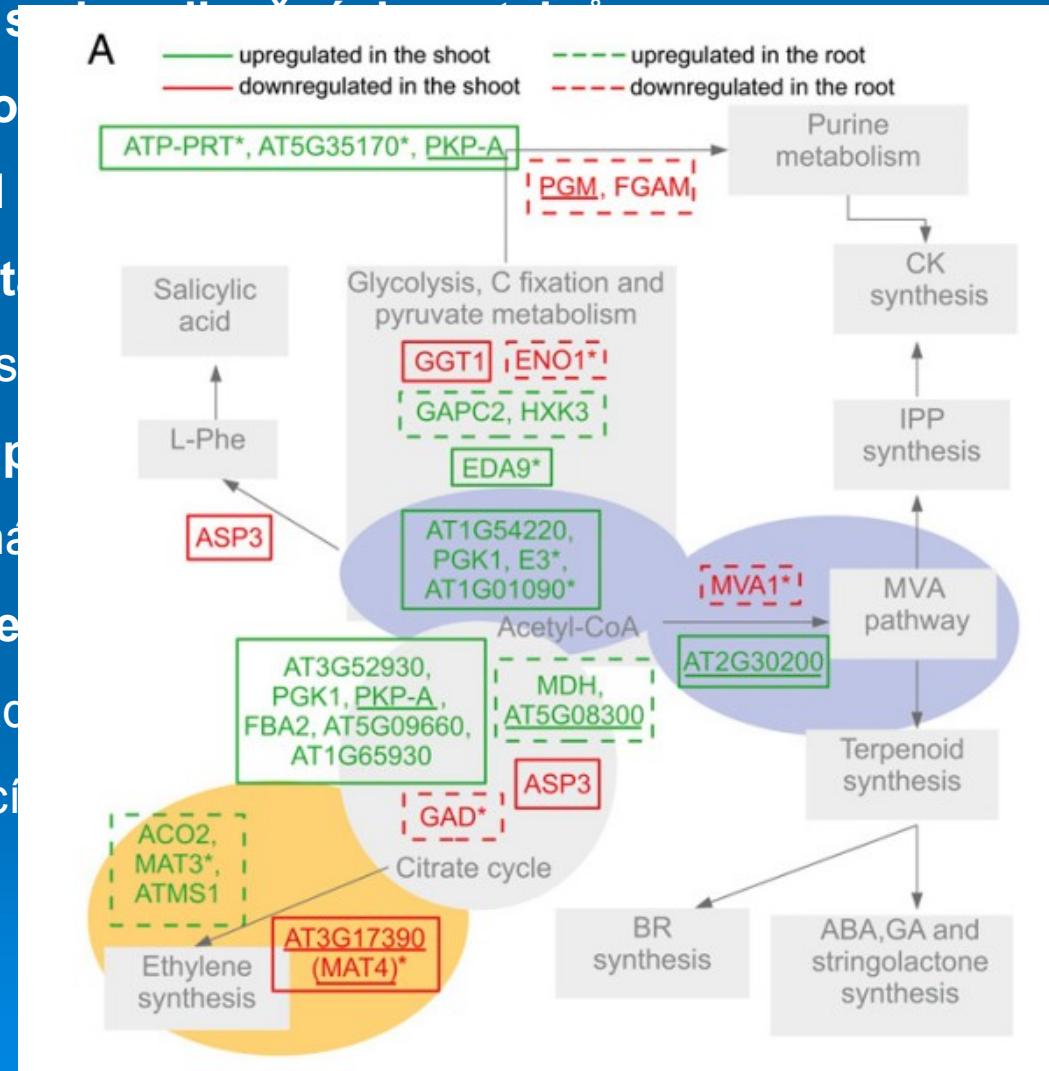
Příklady použití

Vliv nízkomolekulární látky na rostlinu

- identifikace sady ovlivněných proteinů
- jsou tyto proteiny zahrnuty v odpovídající metabolické dráze? (KEGG)
 - fungoval experiment dle předpokladu?
- jaké jiné metabolické dráhy byly „významně“ zastoupeny?
 - objevili jsme i jiné, dosud nepotvrzené, ale související metabolické dráhy?
- jsou známy proteinové komplexy mezi nalezenými proteiny?
 - dokáží nám tyto pomocí při interpretaci vlivu látky na rostlinu?
- je mezi proteiny zastoupeno více proteinů z konkrétního GO termínu?
 - na základě daných GO termínů je možno odvodit souvislosti s funkcí či lokalizací probíhajících (i sekundárních) dějů

Vliv nízkomolekulární látky na rostlinu

- identifikace sítí
- jsou tyto produkty
 - fungovaly
- jaké jiné metody?
 - objevili jsme
- jsou známy podrobnosti?
 - dokáží naše
- je mezi proteinem a funkcií
 - na základě lokality a lokalizací



ze? (KEGG)

abolické dráhy?

?

u?

O termínu?

ti s funkcí či

Interakční partneři zvoleného proteinu

- vidíme již známé interakční partnery?
 - pozitivní kontrola průběhu experimentu
- nově pozorované interakce
 - předpoklad možných interakčních partnerů
 - vhodně provedená negativní kontrola!
 - několik biologických replikátů pro vzorek i kontrolu!
 - studium biologických vlastností možných interakčních partnerů
(GO termíny, metabolické dráhy, ...)
 - zapadají tyto do již známých informací o funkci, lokalizaci aj. zvoleného proteinu?
 - je možné predikovat nepotvrzenou funkci proteinu?
 - jsou patrné souvislosti s lokalizací našeho proteinu?

Studium proteinu, se vztahem k onkol. onemocnění...

- jsou pro tento protein známy proteinové interakce?
 - u interakčních partnerů zvýšená pravděpodobnost, že se tyto proteiny aktivně nebo pasivně účastní daného onemocnění; GO analýza
- je známa lokalizace proteinu v buňce?
 - lokalizace může souviset s funkcí (konkrétní funkce proteinu často vázána na jeho buněčnou lokalizaci)
- je známa úloha proteinu v některé metabolické dráze?
 - možná úloha (i nepřímá, ovlivňující např. „jen“ dostupnost klíčového proteinu) dráhy v onemocnění – její proteinové i neproteinové komponenty

⇒ potencionální cíle dalšího studia a nové léčby

„Zdraví versus nemocní“ – rozdílně exprimované proteiny

- kterých metabolických drah se proteiny účastní?
 - vysvětluje to důsledky, průběh, ... vlastní nemoci?
- jsou rozdílné proteiny převážně lokalizované v některé z organel?
 - má tato informace souvislost se vznikem/průběhem/vznikem nemoci v konkrétním místě organizmu?
- je mezi proteiny „často“ přítomen konkrétní GO termín?
 - má tento termín souvislost se vznikem, průběhem, projevem onemocnění?

Analýza sítí (*network analysis*) – na co si dát pozor?

- falešně pozitivní i negativní informace v biologických sítích
 - častěji falešně negativní – absence příslušných proteinů v sítích
 - důvodem nedostatečná citlivost/specifita současných přístupů pro studium
- mnoho dat v databázích z predikčních studií
 - i přes kontrolu nemusí zcela odpovídat zdrojovým datům a skutečnosti
 - někdy lze vyloučit z analýzy (např. automaticky anotované GO...)
- stále víme velmi málo...
 - důležitost sekvenčních a funkčních homologií u proteinů bez anotace
 - **rychlý vývoj v anotaci proteinů a vývoji bioinformatických nástrojů!**
- **volba vhodných otázek, na které nám biologické sítě dokážou dát odpověď**

Analýza sítí – jak se postavit k výstupům?

- manuální validace výstupů
- ověřením původních zdrojů
- pochybovat a ptát se
- nesnažit se proces analýzy a ověření výsledků urychlit
- experimentální ověření závěrů (např. buněčné linie s mutantní formou genu)
 - drahé a časově náročné ⇒ **důkladné ověření předchozích kroků!**
- není důležité jak to vypadá, ale co a jak se z toho dá vyčíst...

8. Vybrané on-line zdroje

Universal Protein Resource (UniProt)

- <http://www.uniprot.org>
- bohatá anotace proteinů s odkazy na specializované databáze/zdroje
- široké možnosti využití v databázi přítomných informací
 - „mapování“ identifikátorů z různých databází (např. UniProt → KEGG)
 - tabulkový formát s vybranými informacemi o sadě proteinů (stažení...)
 - možný pohled ze strany určité taxonomie, nemoci, buněčné lokalizace...
 - informace o přítomnosti sady proteinů v metabolických drahách, GO

Universal Protein Resource (UniProt) (2)

- odkud bere proteinové sekvence?
 - většina (~98 %) z nukleotidových databází CDS (*coding sequences*)
 - sekvence zadávány jednotlivými výzkumnými skupinami
 - EMBL-Bank/GenBank/DDBJ
 - pod *International Nucleotide Sequence Databases* (INSD)
 - translace na proteinovou sekvenci
 - automatické zpracování za účelem anotace a klasifikace proteinů
 - na základě sekv. homologií
- takto zpracovaný protein je zaveden do **UniProtKB/TrEMBL** databáze
- je-li protein vybrán pro manuální zpracování, provede správce (*curator*) jeho manuální zařazení do **UniProtKB/SwissProt** databáze

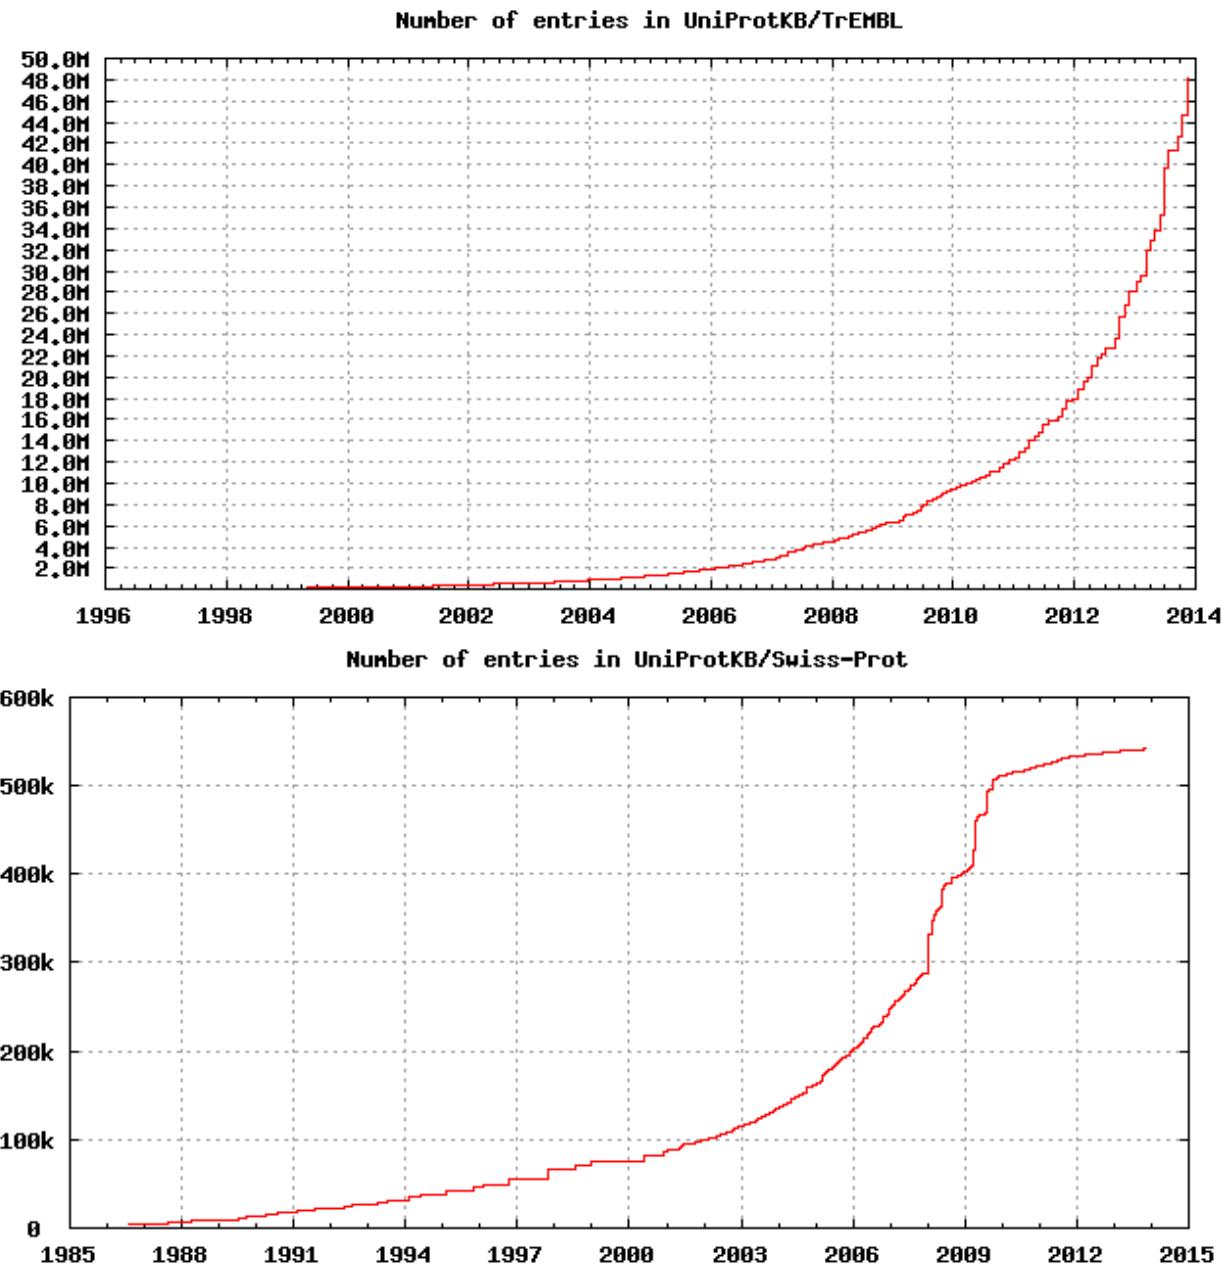
Universal Protein Resource (UniProt) (3)

- UniProtKB/SwissProt – manuální zpracování (*curation*) správcem
 - kontrola sekvence – není-li v původní sekvenci chyba
 - sekvenční analýza – manuálně kontrolované predikce atd.
 - studium literárních zdrojů – dodány biologicky relevantní informace k proteinu na základě dostupných publikací; název genu, funkce proteinu, enz. aktivita, subc. lokalizace, přiřazení GO termínů k proteinu atd.
 - získání informací o proteinové rodině – zjištění případných členů proteinové rodiny a jejich společné zpracování
 - přidání zdrojů – z jakého konkr. zdroje pochází ta které informace; možnost ověření přítomných informací „u zdroje“
 - kontrola kvality, integrace, aktualizace – všechna manuálně přidaná data zkонтrolována a zakomponována do nové verze SwissProt db.

TrEMBL/SwissProt

high-throughput

„závazek“



Universal Protein Resource (UniProt) (5)

- typy proteinových setů v UniProtKB proteinové databázi
 - **UniProtKB/TrEMBL** – automaticky klasifikované a anotované
 - i zde probíhají automaticky řízené opravy...
 - **UniProtKB/SwissProt** – po manuální opravě správcem (*curation*)
 - **Complete Proteome Set** – pro kompletně sekv. organizmy (T+S)
 - **Reference Proteome Set** – vybrané modelové organizmy (T+S)

Universal Protein Resource (UniProt) (6)

- typy proteinových setů v UniProtKB proteinové databázi
 - **UniRef – UniProt Reference Clusters**
 - seskupené primární sekvence do klastrů na základě sekv. podobnosti
 - umožňuje skrýt „redundantní“ proteinové sekvence
 - **UniRef100** – seskupeny sekvence se 100% identitou
 - **UniRef90; UniRef50**
 - snížení počtu sekvencí (o ~58 a 79%) – BLAST aj.
 - seskupováno dle kritérií – SwissProt, jméno, organizmus, délka
 - **UniParc – databáze proteinových sekvencí**
 - unikátní identifikátor pro každou primární sekvenci (**UNI**)
 - identifikátor se nikdy nemění, ani nemaže
 - vedle sekvence informace o zdrojové databázi, identifikátoru atd.

PubMed

- <http://www.ncbi.nlm.nih.gov/pubmed>
- více orientovaná na genomová data, ale...
- Protein Clusters – obdoba UniRef
- RefSeq – obdoba SwissProt; méně informačně „hodnotné“; oproti SwissProt cca 4M RefSeq záznamů
- obdobně informace o jednotlivých organizmech, taxonomiích aj.
 - nenabízí tak široké možnosti filtrování a práce s proteinovými sekvencemi jako UniProt
- mimo to i indexace vědeckých publikací aj.

Expasy

- <http://expasy.org>
- sada nástrojů pro práci s proteiny/geny
- převážně nástroje z dílny *Swiss Institute of BioInformatics* (SIB; <http://www.isb-sib.ch/>)
- původně pouze proteomický portál
- rozšířen (2011) o genomické, transkriptomické aj. informace a nástroje

European Bioinformatics Institute (EBI)

- <http://www.ebi.ac.uk/services>
- opět sada bioinformatických nástrojů a databází pro studium proteinů a souvisejících informací
- např. zmínované InterPro; GeneOntology.org; OLS; ...

bioinformatics.ca Links Directory

- http://bioinformatics.ca/links_directory/
- sady odkazů na různé kategorie on-line zdrojů
- některé nástroje/databáze již nejsou aktualizované, nutno ověřit
- možnost komentovat aj.

Reactome

- <http://www.reactome.org>
- obdoba KEGG
- převážně pro lidské dráhy

Pax-DB

- <http://pax-db.org/#!home>
- databáze abundancí jednotlivých proteinů v organizmech či jejich částech

9. Několik zamyšlení závěrem

Rychlý vývoj bioinformatických aplikací/databází

- **vzniká hodně nástrojů/databází, které nejsou následně používané**
 - nepoužívané nástroje často dále nevyvíjené, neaktualizované (přítomnost chyb, které se objeví až při masivním používání...), používají zastaralé algoritmy, používají starší proteinové databáze...
- **význam „zavedených“ zdrojů bioinformatických nástrojů/databází**
(UniProt, Pubmed, EBI, Expasy)
 - např. anotace proteinů, vytváření biologických sítí – **lidské kapacity**
 - dlouholeté zkušenosti nutné k střednědobému **směřování vývoje**
- **důležitá grafická stránka programu/databáze a první „jednoduchost“**
 - důležité pro rychlé „rozkoukání“, *user friendly* uživatelské prostředí
- **významná předchozí zkušenost s prací v aplikaci/s databází**
 - nové aplikace to nemají snadné...
 - důvod proč i nápadité nástroje mohou zůstat nepoužívány

Rychlý vývoj bioinformatických aplikací/databází (2)

- několik let (nejen v bioinformatice) je velmi dlouhá doba
 - aktualizace minimálně 1 ročně, optimálně měsíční, půlroční
 - i přes to mohou starší nástroje fungovat lépe než novější...
 - případně nic „lepšího“ není
 - důležité celosvětové reference a citovanost/používání (recentní) daného nástroje/databáze
- bioinformatické aplikace/databáze není možné nevyvíjet/neaktualizovat
 - při vytváření nástroje/databáze nutno počítat s udržitelností jeho vývoje...
- školící programy/workshopy/stáže v bioinformatických centrech
 - EBI, SIB aj.
- význam spoluprací – jeden tým často nedokáže pojmet celé spektrum použitých nástrojů, přístupů včetně interpretace výstupů

10. 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 – podmínky pro interakce jako *in vivo* výstupem *pull-down* roztoky – proteiny vázající se na *bait* a nesp. proteiny
 - paralelně experimenty bez *bait* – negativní kontrola – *bead proteome*
 - minimálně 3 biologické replikáty, lépe 5 od vzorku i negativní kontroly

LC-MS/MS analýza pull-down vzorků

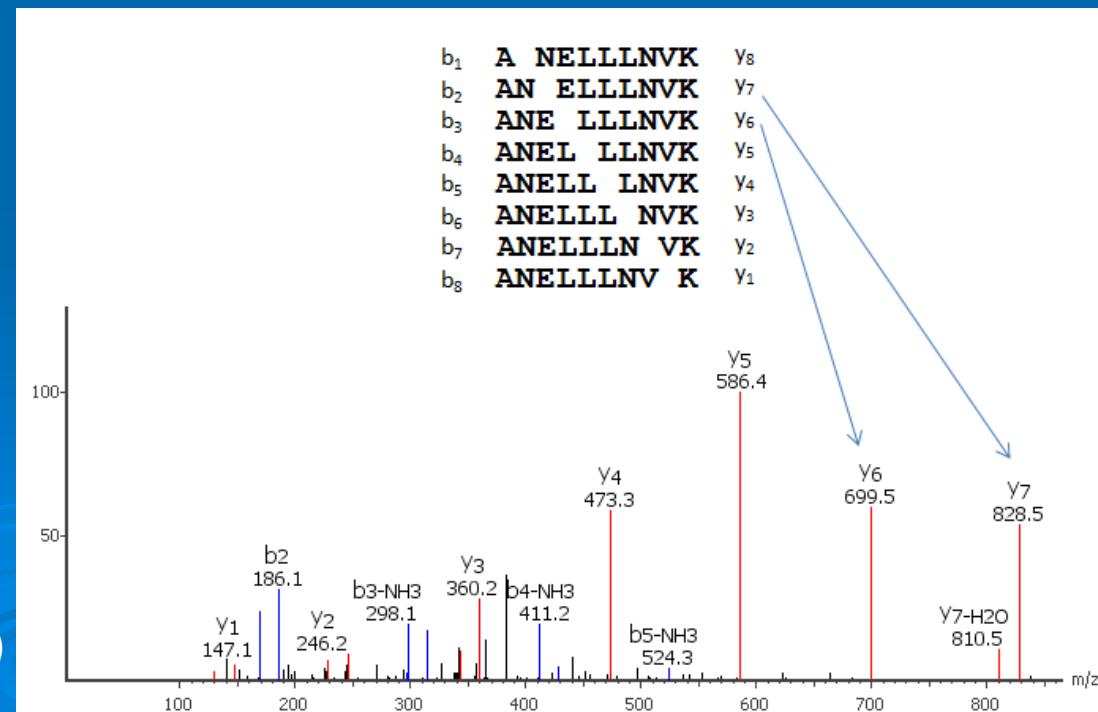
- digesce proteinů \Rightarrow peptidy (např. trypsinem; peptidy končí R nebo K)
- LC-MS/MS analýza směsi peptidů
 - peptidy vstupují do MS v pořadí rostoucí hydrofobicity (LC separace)
- MS zjistí MW peptidů a získá MS/MS spektra
(fragmentační spektrum vybraného peptidu)

např. peptid ANELLNVK

(MW 1012.5917 Da)

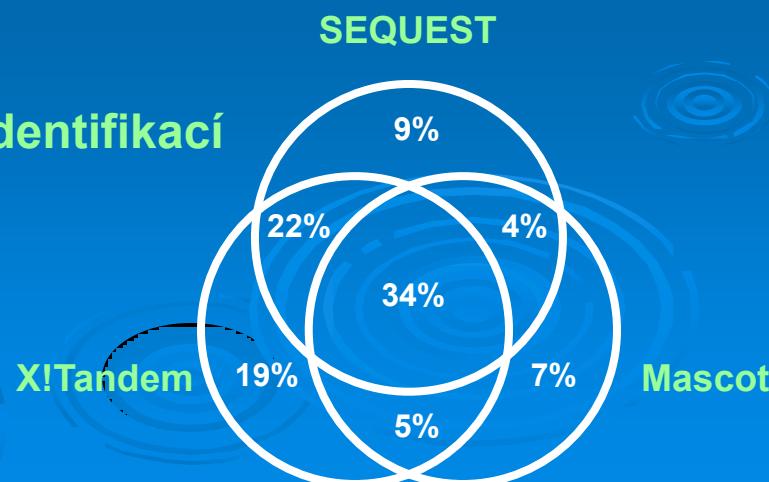
1. MW_{exp} = 1012.5923 Da
(0,6 ppm chyba)

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



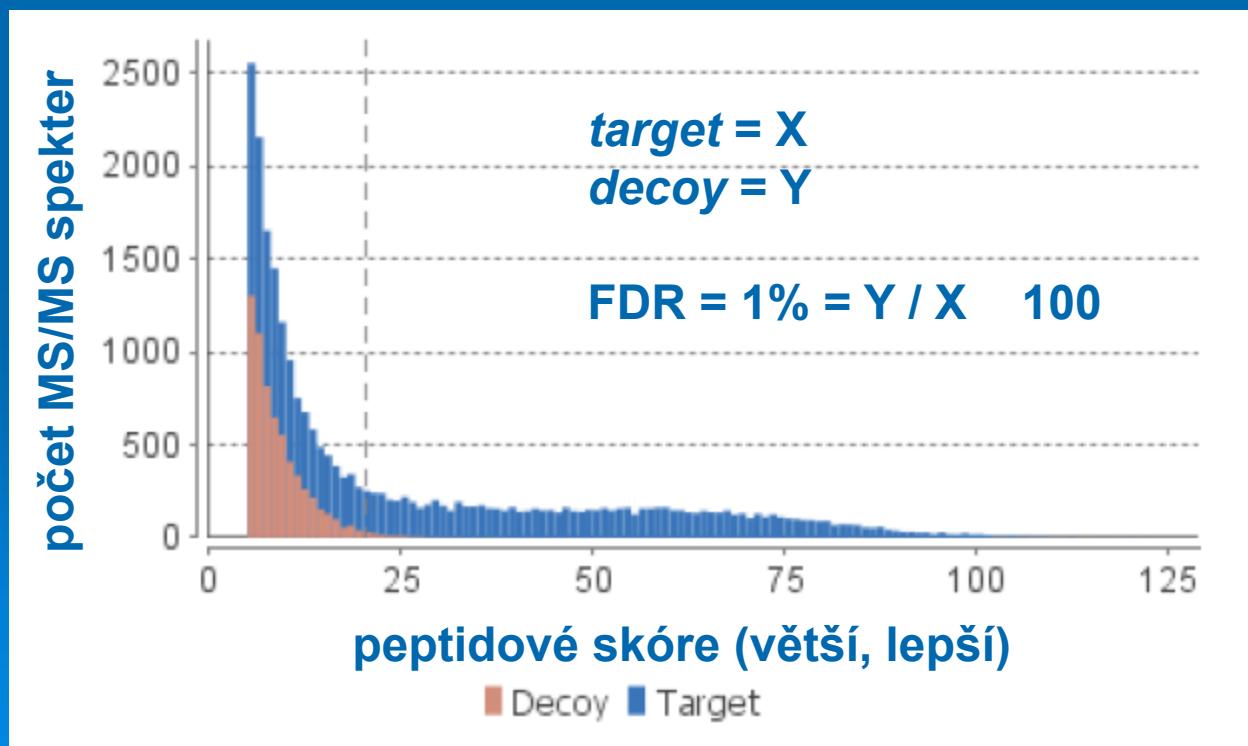
Zpracování LC-MS/MS dat

- LC-MS/MS data z analýz *pull-down* vzorků po digesci = MS/MS spektra
- řádově 10 000 – 1 000 000 MS/MS spekter
- identifikace peptidů
 - vycházíme z proteinové databáze, např. TAIR (*Arabidopsis thaliana*)
 - *in silico* se vytvoří seznam možných peptidů
 - >20 algoritmů pro automat. přiřazení MS spektra možným peptidům (Sequest, Mascot, XTandem!, OMSSA, Phenyx, Andromeda, ...)
 - jiný algoritmus ⇒ jiný přístup ⇒ různá citlivost ⇒ odlišné výsledky
⇒ kombinace algoritmů
⇒ zvýšení počtu pozitivních 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 (TAIR) i decoy proteinové databázi
- ⇒ jeden z možných přístupů jak určit FDR – peptidová úroveň



Zpracování LC-MS/MS dat (3)

- z identifikovaných peptidů k proteinům přítomným ve vzorku
 - problém u **bottom-up** přístupu (digesce proteinů, analýza až peptidů)
 - v MS analýze **vidíme jen malou část** z např. tryptických **peptidů** proteinů a navíc nevíme ze kterých proteinů pozorované peptidy původně pochází...
⇒ **problém s určením seznamu proteinů přítomných ve vzorku**
(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 – sada proteinů A
 - slepý vzorek; „bead proteome“ – sada proteinů B
- co nás zajímá v našem IP experimentu nejvíce?
- sada proteinů A, které zároveň nejsou v sadě proteinů B

Pohled na seznamy identifikovaných proteinů (2)

- proteiny „navíc“ v A
 - 1) kvalitativní změny (A: „ano“, B: „ne“)
 - citlivost použitého přístupu...
 - proteiny identifikované relativně slabě v A mohou být v B také přítomny!
 - 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** – „Stable Isotope Labeling by Amino acids in Cell Cultures“ – 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, další databáze; GO, pathways)
- 3) DAVID <http://david.abcc.ncifcrf.gov/home.jsp>
- 4) ANAP http://gmdd.shgmo.org/Computational-Biology/ANAP/ANAP_V1.1/
 - 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