

# PB051: Výpočetní metody v bioinformatice a systémové biologii

David Šafránek

6.4.2012

Tento projekt je spolufinancován Evropským sociálním fondem a státním rozpočtem České republiky.



# *Obsah*

*Systémové paradigma – síť interakcí*

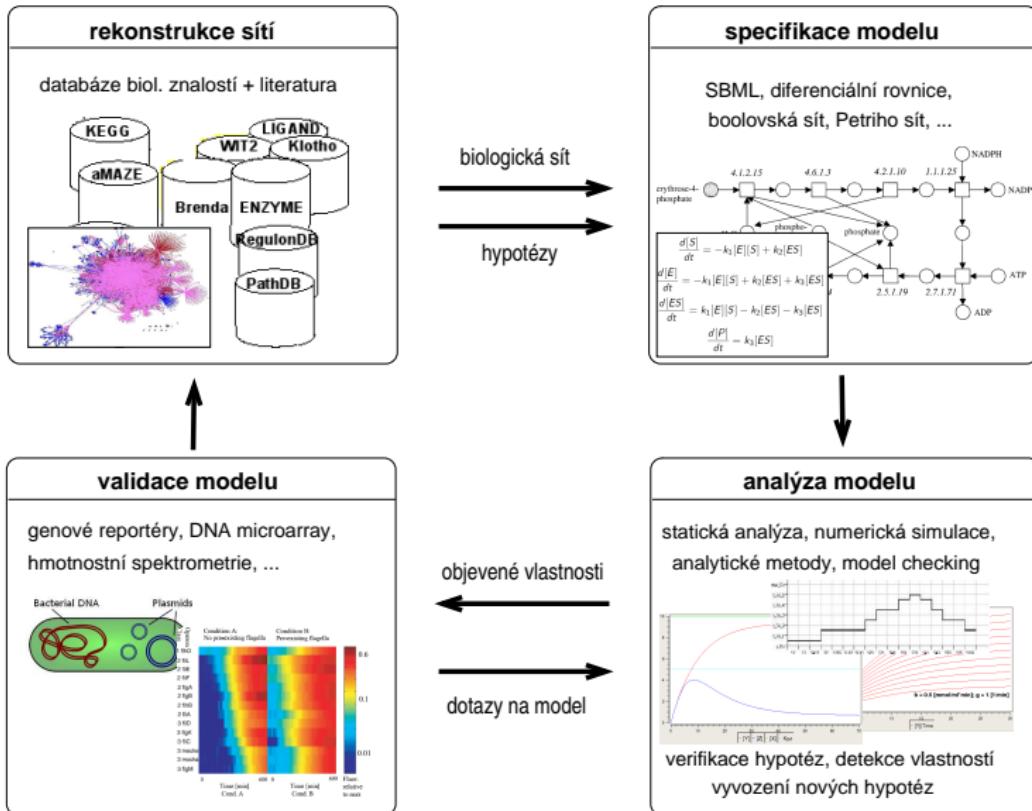
*Rekonstrukce genových interakčních sítí*

# *Obsah*

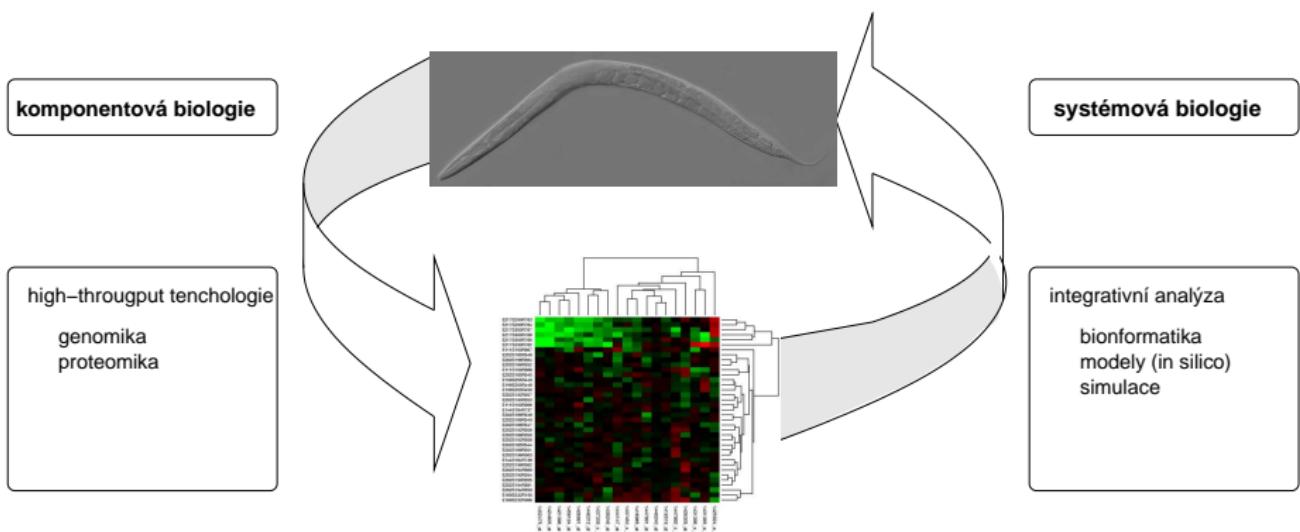
*Systémové paradigma – síť interakcí*

*Rekonstrukce genových interakčních sítí*

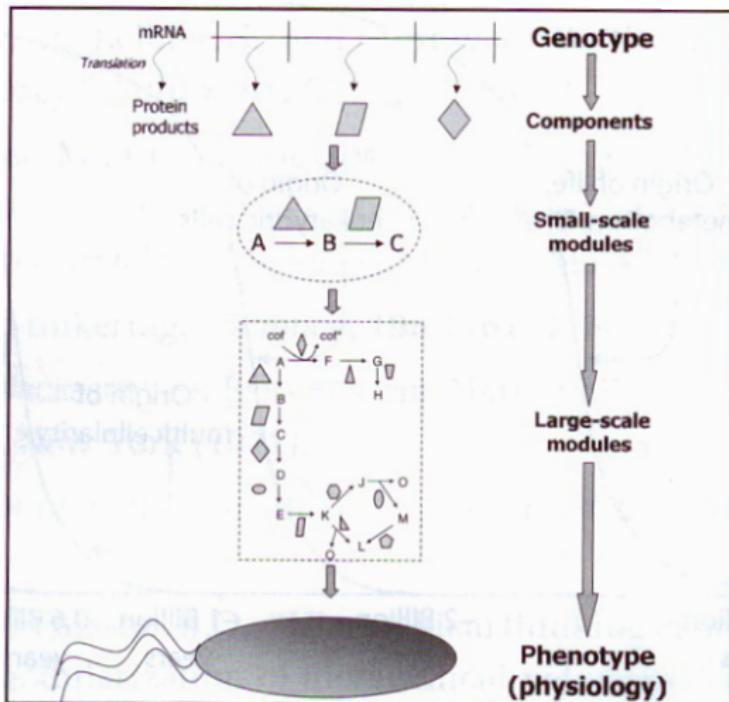
# Průběh výzkumu v systémové biologii



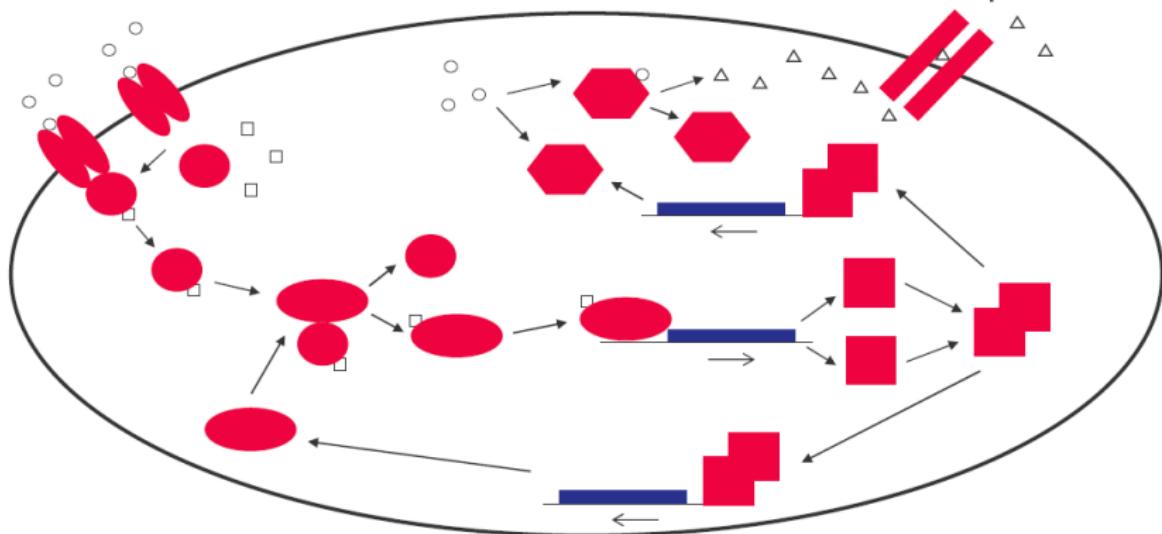
# Metody systémového měření



## Koncept hierarchie

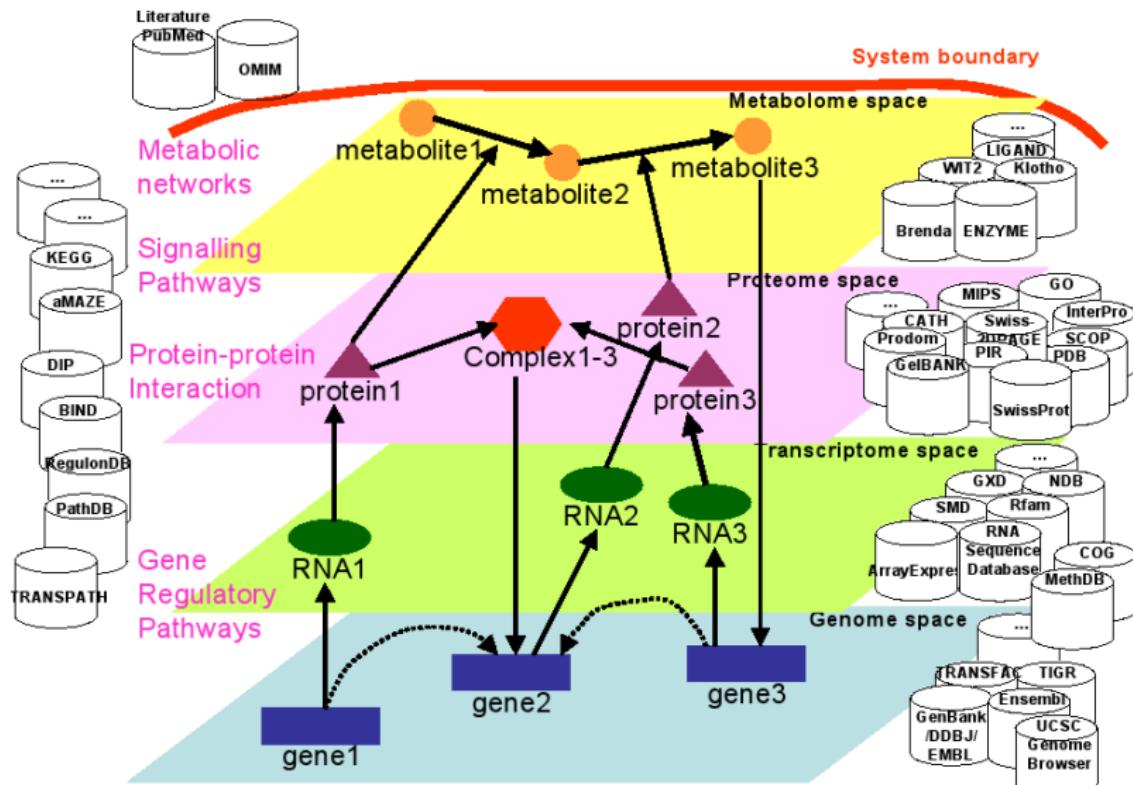


## Biochemické procesy v buňce

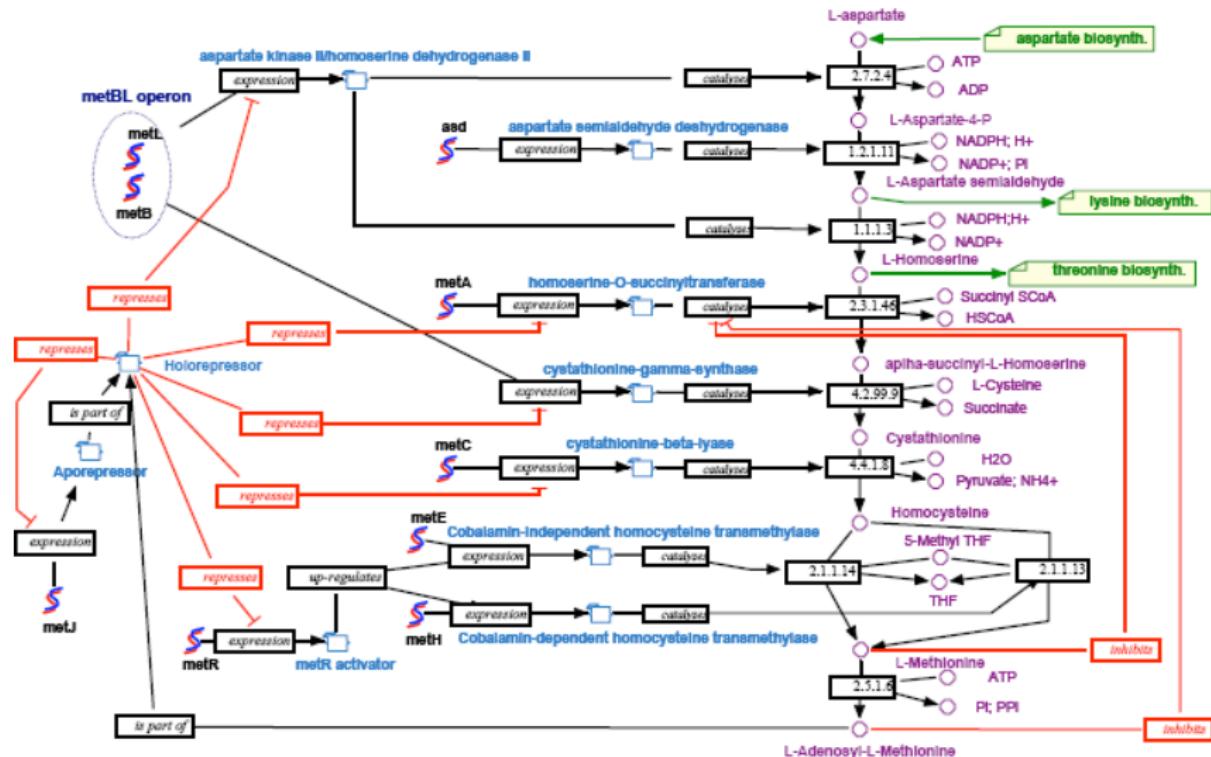


- molekulární komponenty – proteiny, DNA, RNA,...
- interakce na různých úrovních (transkripce, metabolismus,...)
- příjem signálů a živin (nutrientů) na membráně

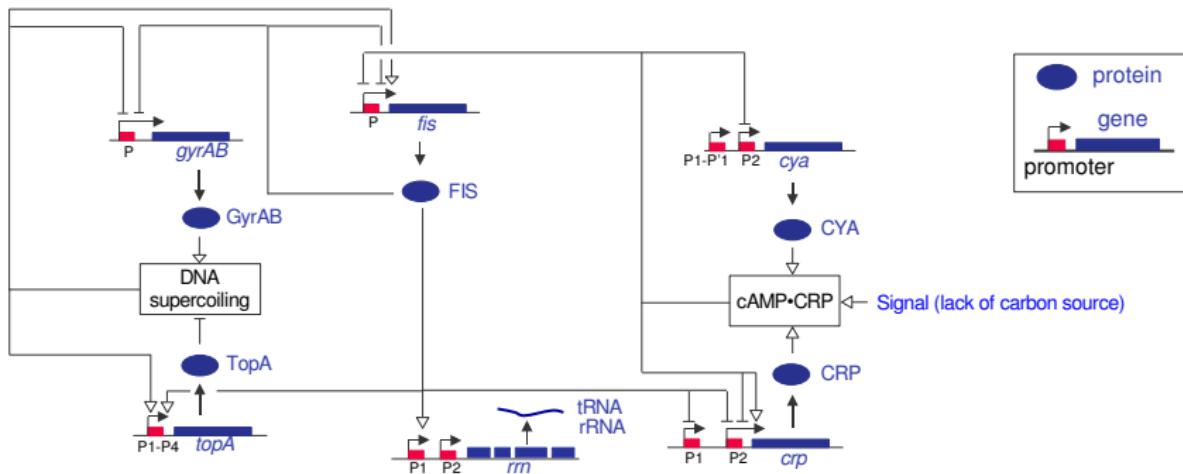
# Funkční vrstvy buňky



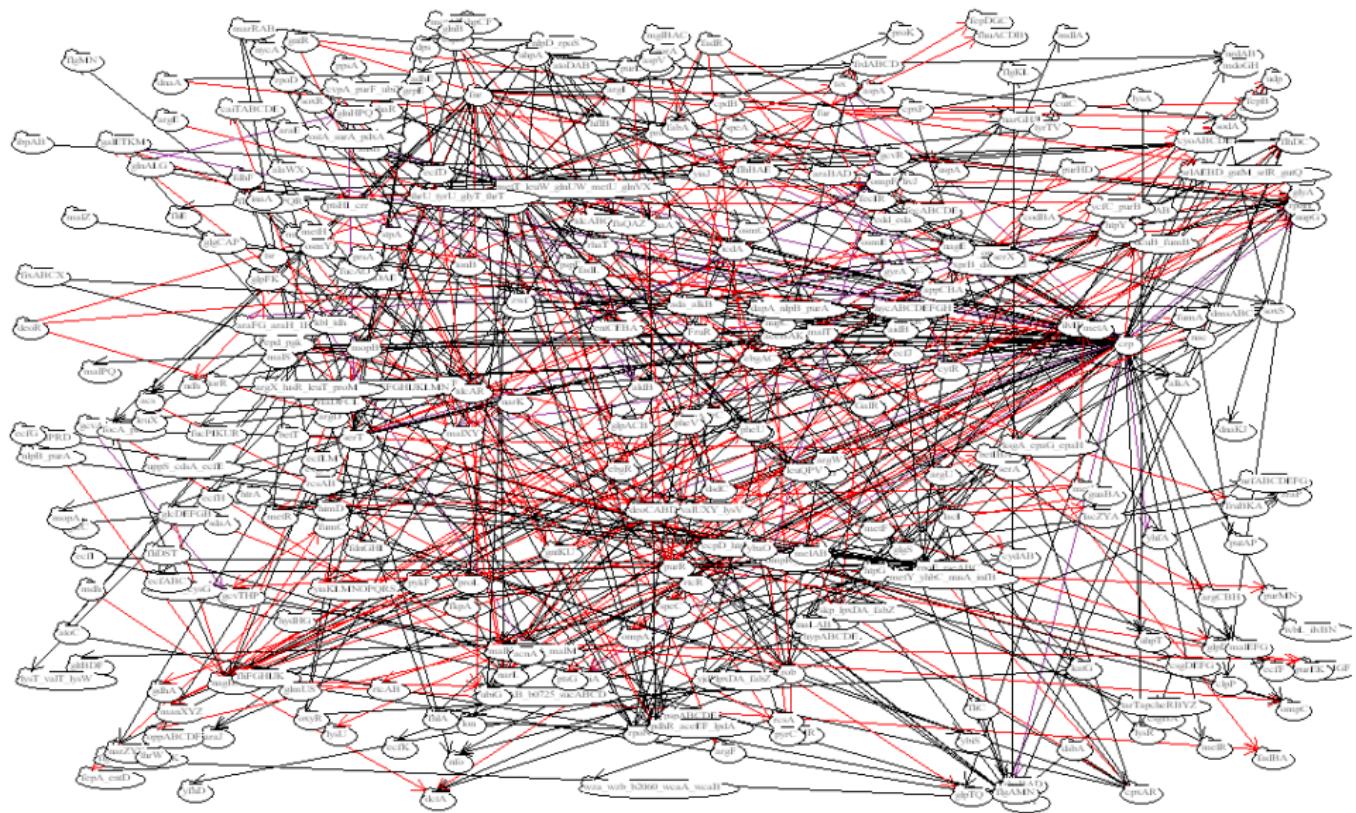
# Příklad geneticky řízené metabolické dráhy



# Příklad modulu genetické regulace v *E. Coli*



# Kompletní transkripční síť *E. Coli*



# *Biologická síť jako obecný graf*

## *Definition*

Nechť  $V$  je konečná množina uzlů a  $E \subseteq V \times V$  relace.

*Biologickou sítí* nazveme graf  $G$  reprezentovaný uspořádanou dvojicí  $G \equiv (V, E)$ .

- Pokud  $\forall \langle a, b \rangle \in E. \langle a, b \rangle \in E \rightarrow \langle b, a \rangle \in E$ ,  $G$  nazýváme *neorientovaný*.
- V ostatních případech hovoříme o *orientovaném* grafu.

typ sítě	$V$	$E$	$G$
genové	geny (resp. proteiny)	regulace exprese	or.
proteinové	proteiny	proteinové interakce	neor.
metabolické	metabolity, enzymy	enzymové reakce	or.
signální	molekuly	aktivace/deaktivace	or.

# *Biologické sítě – výpočetní problémy*

- (re)konstrukce sítí
  - identifikace interakcí
    - ⇒ z experimentálních dat
    - ⇒ integrací dat z databází znalostí
- zpracování sítí
  - vizualizace
  - integrace atributů uzlů, hran
- analýza sítí
  - analýza statistických vlastností
    - ⇒ rozložení konektivity, detekce motivů, ...
  - porovnání sítí

# *Ontologie genů a genových produktů*

- nutnost systematicky uchopit genom, genové produkty a funkce (interaktom)
- akumulace biologických dat
  - decentralizovaný proces
  - paralelní proces
- problém: nejednoznačné popisy téhož objektu, procesu
  - např. proteolýza vs. (řízená degradace proteinů)
- od roku 1998 vývoj Gene Ontology  
⇒ <http://geneontology.org>

## *Gene Ontology*

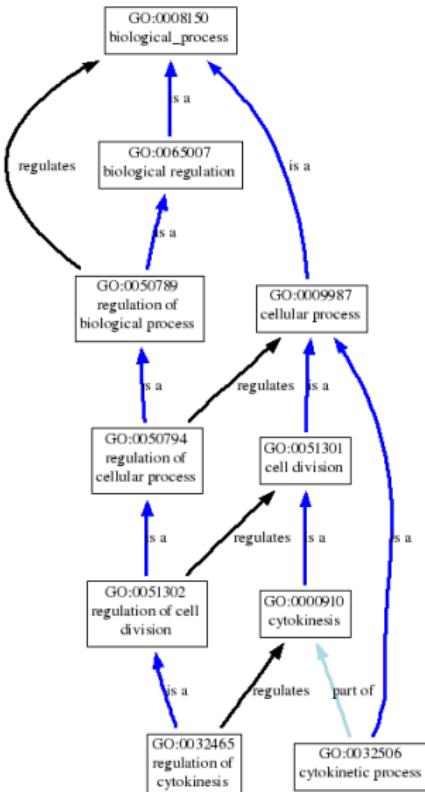
- cílem je ucelený systematický popis genových produktů a jejich funkcí
- ontologie představuje systematický slovník pojmu
  - hierarchický pohled na data včetně vazeb mezi nimi (DAG)
  - zachycení synonym
- GO obsahuje 3 kategorie (DAGy):
  - biological process
  - cellular component
  - molecular function

## *Gene Ontology*

- respektuje standard OBO a OWL (W3C) pro strukturu a reprezentaci ontologií
  - <http://obofoundry.org/>
  - <http://www.w3.org/TR/owl-features/>
- každý uzel představuje jednoznačný pojem (množinu synonym)  
⇒ jednoznačně reprezentován ID (tzv. GO termem)
- různé typy relací mezi uzly:
  - part\_of, is\_a, located\_in, derived\_from, ...
  - viz <http://obofoundry.org/ro/>

# Gene Ontology

## Příklad podgrafa GO



## *Nástroje pro Gene Ontology*

- on-line i off-line vyhledávače v GO
- statistické testy na overrepräsentaci dané množiny genů v pojmech GO
  - GOstat –  
<http://gostat.wehi.edu.au/cgi-bin/goStat.pl>
  - DAVID – <http://david.abcc.ncifcrf.gov/>
  - BiNGO –  
<http://www.psb.ugent.be/cbd/papers/BiNGO/Home.html>
- mapování microarray dat na ontologický strom
  - ~~eCON~~ <http://www.genetools.no/>
  - High-Throughput GoMiner –  
<http://discover.nci.nih.gov/gominer/htgm.jsp>
  - ~~Meta Gene Profiler (MetaGP)~~ <http://metagp.ism.ac.jp/>
- ...

# *KEGG – Kyoto Encyclopedia of Genes and Genomes*

- integrativní databáze genových produktů
- genový prostor  
⇒ GENES, GENOME, ORTHOLOGY, Organisms
- chemický prostor  
⇒ COMPOUND, GLYCAN, REACTION, ENZYME, LIGAND
- systémový prostor  
⇒ PATHWAY, BRITE, DISEASE, DRUG
- každý pojem má jednoznačné ID
- zachycena ortologie (podobnost) genů
- genový prostor čerpá aktuálně z několika zdrojů

## Cvičení

Uvažujme sekvenci aminokyselin (FASTA formát):

SVVEEHGQLSISNGELVNERGEQVQLKGMSHGLQWYGQ  
FVNYESMKWLRRDDWGINVFRAAMYTSSGGYIDDPS  
VKEKVKEAVEAAIDLDIYVIIDWHILSDNDPNIYK  
EEAKDFFDEMSELYGDYPNVIYEIANEPNGSDVTW  
GNQIKPYAEEVPIIIRNNDPNNIIIVGTGTWSQDV  
HHAADNQLADPNVMYAFHFYAGTHGQNLRDQVDYA  
LDQGAAIFVSEWGTSAATGDGGVFLDEAQVWIDFM  
DERNLSWANWSLTHKDESSAALMPGANPTGGWTEA  
ELSPSGTFVREKIRE

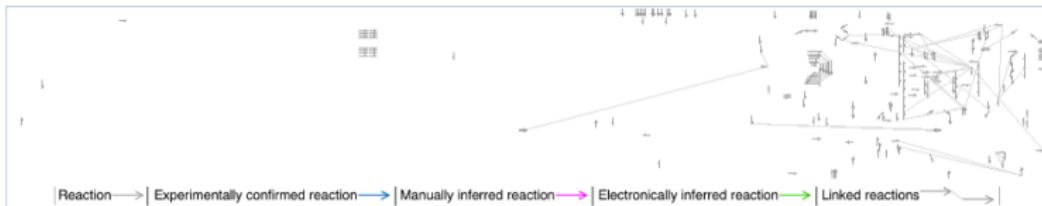
pomocí vhodné služby odhadněte, o jaký protein/enzym se jedná a k němu dohledejte informaci na IntEnz

- najděte na <http://www.ebi.ac.uk/intenz/>
- prozkumejte relevantní dráhy na <http://www.genome.jp/kegg/>

# Reactome

## Reactome - a curated knowledgebase of biological pathways

The data displayed is for Escherichia coli ▾ Use the menu to change the species. Check  for cross-species comparison.



Apoptosis	Axon guidance	Biological oxidations	Botulinum neurotoxicity
Cell junction organization	Cell Cycle Checkpoints	Cell Cycle, Mitotic	Chromosome Maintenance
DNA Repair	DNA Replication	Diabetes pathways	Respiratory electron transport, ATP synthesis by chemiosmotic coupling, and heat production by uncoupling proteins.
Gene Expression	Hemostasis	HIV Infection	Interactions of the immunoglobulin superfamily with other proteins
Influenza Infection	Integration of energy metabolism	Integrin cell surface interaction	
Metabolism of amino acids and derivatives	Metabolism of carbohydrates	Metabolism of lipids and lipoproteins	
Metabolism of nucleotides	Metabolism of porphyrins	Metabolism of proteins	
Metabolism of vitamins and cofactors	Muscle contraction	mRNA Processing	
Pyruvate metabolism and Citric Acid (TCA) cycle	Regulation of beta-cell development	Regulatory RNA pathways	
Signaling by EGFR	Signaling by FGFR	Signaling by GPCRs	
Signaling in immune system	Signaling by Insulin receptor	Signalling by NGF	

starý look reactome;  
v současné verzi používá  
SBGN standard,  
doporučuji proklikat

<http://www.reactome.org/>

## *Specificky zaměřené zdroje dat*

- EcoCyc — <http://ecocyc.org> - E. coli K12
- SGD — <http://www.yeastgenome.org/>
- WORMBASE — <https://wormbase.org/>  
~~[http://www.sanger.ac.uk/Projects/C\\_elegans/WORMBASE/](http://www.sanger.ac.uk/Projects/C_elegans/WORMBASE/)~~
- FlyBase — <http://flybase.org/>
- ...

# *Nástroje pro analýzu biologických sítí*

- Cytoscape

<http://www.cytoscape.org>

- vizualizační layouty
- mapper vizuálních prvků na data
- filtry
- pluginy pro práci s biologickými sítěmi

- VisANT

<http://visant.bu.edu/>

- prakticky taktéž funkčnost jako Cytoscape
- podpora hierarchického zanořování (MetaNodes)
- méně flexibilní prostředí
- více biologicky-relevantních funkcí

# *Cytoscape*

- analyzátor komplexních interakčních sítí
- původně zaměřený na bioinformatická data
- přístup k webovým službám (databáze)
- funkce pro integraci dat
- platforma pro pluginy
- open source politika

## *Cytoscape – formát dat*

- SIF – Simple Interaction Format (interní formát)
- GML – Graph Modelling Language (obecný formát pro popis grafu, zahrnuje i vizuální informace)
- XGMML – eXtensible Graph Markup and Modeling Language (možnost anotací uzlů a hran daty)
- BioPAX – formát využívající OWL (standard pro popis ontologií)
- SBML – standard pro popis dynamických modelů
- dále OBO, text format CSV, MS Excel XLS format, ...

## *Cytoscape – základní principy*

- sítě organizovány v tzv. sessions (formát cys)
- v rámci session lze spravovat několik sítí
- data o uzlech/hranách jsou sdílena v rámci session
- session zahrnuje též vizuální data včetně nastavení stylů, vnitřní stavy některých pluginů

## *Cytoscape – základní principy*

- možnost vyhledávání a filtrace dat
- datový panel zobrazuje filtrovaná/vyhledaná data
- jednoduše lze vytvořit podsíť z aktuálně vybraných uzelů
- možnost topologických filtrů

# *Obsah*

*Systémové paradigma – síť interakcí*

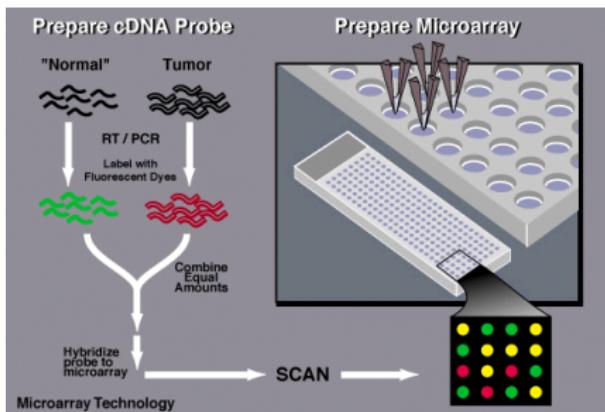
*Rekonstrukce genových interakčních sítí*

# *Detekce regulačních interakcí*

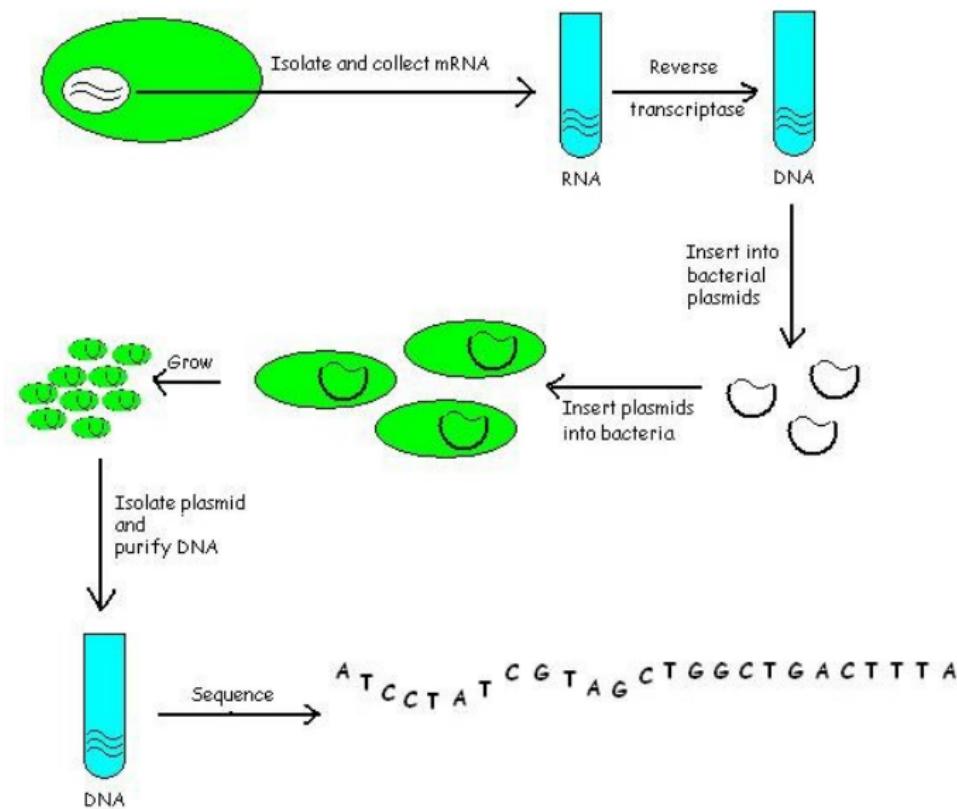
- využití databází promotorových sekvencí
  - prohledávání promotorových sekvencí na přítomnost známých TFBSs
  - TRANSFAC, MATCH, PromoterScan, RegulonDB promoter analysis, ...
- využití DNA mikročipů
  - identifikace genů s podobnými profily exprese a jejich agregace do skupin (tzv. klastrů)
- analýza promotorů ortologických genů (napříč různými druhy)
  - tzv. phylogenetic footprinting
  - viz např. [http://bayesweb.wadsworth.org/binding\\_sites/index.html](http://bayesweb.wadsworth.org/binding_sites/index.html) (*E. coli*)

# Měření genové exprese

- nejpoužívanějším nástrojem je technologie DNA microarray
- umožňuje tzv. high-throughput analýzu
  - v daném okamžiku je paralelně nasamplována exprese všech genů v genomu příslušného organismu
  - postaveno na relativním srovnání minimálně dvou různých vzorků
    - exprese v přítomnosti vs. nepřítomnosti  $O_2$
    - exprese při knock-outu určitého genu vs. normální stav
    - ...



# Reverzní transkriptáza a cDNA



## *Reverzní transkriptáza a cDNA*

- enzym EC 2.7.7.49 (druh DNA polymerázy)
- objevena v retrovirech [Temin, Baltimore, 1970]
- přepisuje mRNA na jednořetězcovou (komplementární) DNA (tzv. cDNA)
- umožňuje vytvořit knihovnu DNA

# *Polymerase Chain Reaction (PCR)*

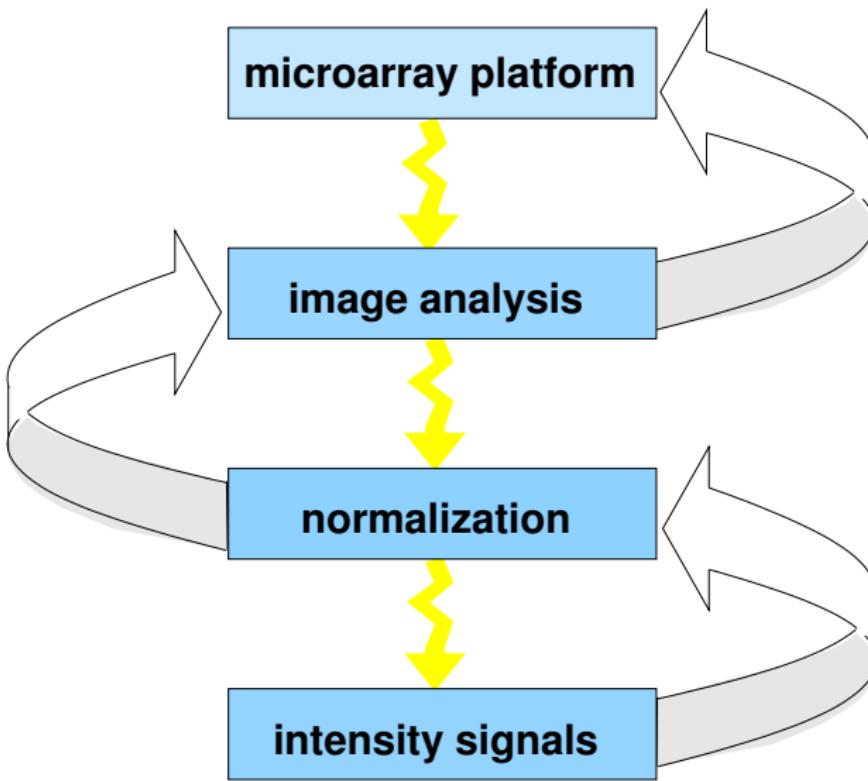
- umožňuje replikaci určité části DNA (tzv. amplifikace)
- DNA je zahřátím rozdělena
- úsek DNA je označen párem oligonukleotidů (15-25 bazí)
  - při snížení teploty hybridizace oligonukleotidů s řetězcem DNA
  - doplnění zbývající sekvence DNA prostřednictvím RNA polymerázy
- <http://www.dnalc.org/resources/animations/pcr.html>
- lze využít i pro mRNA: RT-PCR (reverse transcription PCR)
  - reverzní transkripce mRNA do cDNA
  - amplifikace cDNA (PCR)

## *Postup při DNA microarray experimentu*

1. konstrukce čipu z cDNA knihovny (amplifikace a rozmístění)
2. odběr celkové mRNA z experimentálních vzorků (typicky 2)
3. reverzní transkripce do cDNA asociované s fluorescenčním barvivem
4. hybridizace odebrané cDNA s cDNA na čipu
5. omytí čipu a oskenování výsledku
6. analýza dat
7. komerční čipy používají místo cDNA knihovny skupinu oligonukleotidů pro každý gen  
⇒ pouze jeden vzorek mRNA je analyzován na jednom čipu (porovnání více identicky připravených čipů)

<http://www.bio.davidson.edu/courses/genomics/chip/chip.html>

# *Workflow produkce výsledků DNA microarray experimentu*



## *Validace a zpracování výsledků*

- validace dat separátním měřením koncentrací mRNA nepřímo (pomocí RT-PCR)
  - RT-PCR spuštěna pro oba vzorky (shodný počet kroků PCR)
  - porovnání koncentrací příslušných cDNA
- klastrování dat
  - zjišťování podobnosti mezi datovými vektory
  - agregace do specifických skupin (klastrů)

## *Databáze microarray dat*

- Stanford Microarray Database – různé pohledy na data, filtrace

<http://smd.stanford.edu/cgi-bin/cluster/dr GetData.pl>

- ArrayExpress – statisticky zpracovaná data

<http://www.ebi.ac.uk/gxa/>

- Gene Expression Omnibus (GEO)

<http://www.ncbi.nih.gov/geo/>

- MUSC DNA Microarray Database

<http://proteogenomics.musc.edu/ma/>

- GenExpDB (E. Coli specifická data)

<http://genexpdb.ou.edu/>

## Klastrování microarray dat

- předpokládejme matici se sondami pro  $n$  genů
- uvažujme sadu  $p$  experimentů
- pro každý gen  $i$  dostáváme vektor  $\mathbf{x}_i = (x_{i1}, \dots, x_{ip})$  zachycující posloupnost výsledků (tzv. expresní profil)
- definujeme míru vzdálenosti  $d : \mathbb{R}^p \times \mathbb{R}^p \rightarrow \mathbb{R}$ :

$$d(\mathbf{x}_n, \mathbf{x}_m) = \left( \sum_{i=1}^p |x_{ni} - x_{mi}|^q \right)^{\frac{1}{q}}$$

- pro  $q = 2$  dostáváme Euklidovskou vzdálenost

## *Klastrování microarray dat*

- existují dva hlavní přístupy ke klastrování
  - partitioning – cílem je najít jedno **nejvhodnější** rozdelení do klastrů (parametrem je počet požadovaných klastrů)  
⇒ Self-organizing maps, K-means
  - hierarchické metody – vytvořen celý strom hierarchie  
⇒ kořen – klas str obsahující všechny experimenty, v listech  
⇒ listy – jednoprvkový klas str pro každý experiment
- klastry mohou být identifikovány i pro vektory tvaru $x_j' = (x_{1j}, \dots, x_{nj})$

# *Algoritmus pro hierarchické klastrování*

- nejpoužívanější metoda je tzv. aglomerativní (zdola-nahoru)
- parametrem je míra podobnosti hodnot  $d(x_i, x_j)$
- postup ( $t$  značí aktuální úroveň):
  1.  $t = n \Rightarrow$  inicializuj pro každý gen  $i \leq n$ :  $C_i^n = \{x_i\}$
  2. spoj dva klastery  $C_k^t$  a  $C_l^t$  s minimální vzdáleností  $D(C_k^t, C_l^t)$
  3. update  $D$  dle nového rozdělení
  4.  $t := t - 1$
  5. iteruj (2-4) dokud  $t > 1$

## *Algoritmus pro hierarchické klastrování*

Při aglomeraci se používá míra podobnosti dvou klastrů na téže úrovni  $t$ :

- $D(C_k^t, C_l^t) = \min_{x_i \in C_k^t, x_j \in C_l^t} d(x_i, x_j)$  (single linkage)
- $D(C_k^t, C_l^t) = \max_{x_i \in C_k^t, x_j \in C_l^t} d(x_i, x_j)$  (complete linkage)
- $D(C_k^t, C_l^t) = \frac{1}{|C_k^t||C_l^t|} \sum_{x_i \in C_k^t, x_j \in C_l^t} d(x_i, x_j)$  (average linkage)

# Algoritmus pro hierarchické klastrování

- update míry vzdálenosti (krok (3)):

$$\begin{aligned} D(C_m^{t-1}, C_k^t \cup C_l^t) = & \alpha_k D(C_m^t, C_k^t) + \alpha_l D(C_m^t, C_l^t) \\ & + \gamma |D(C_m^t, C_l^t) - D(C_m^t, C_k^t)| \end{aligned}$$

- single linkage:  $\alpha_k = \alpha_l = 0.5, \gamma = -0.5$
- complete linkage:  $\alpha_k = \alpha_l = 0.5, \gamma = 0.5$
- average linkage:  $\alpha_i = \frac{|C_i^t|}{|C_k^t| + |C_l^t|}, i \in \{k, l\}, \gamma = 0$

## *Metoda K-means*

- založeno na optimalizaci odchylky mezi expresními profily vzhledem ke středu (průměrnému profilu) klastru
- nejčastěji je tato optimalizace reprezentována minimalizací
- pevně dán počet požadovaných klastrů
- náhodně se inicializují střední profily
  - metoda je přesnější při větším počtu pokusů
- klastry jsou průběžně modifikovány při minimalizaci odchylek (Euklidovské vzdálenosti) od středových profilů

## *Metoda K-means*

- algoritmus K-means má dvě základní fáze
  - výpočet vzdáleností jednotlivých vektorů od vektoru středových hodnot
  - update vzhledem k optimalizační funkci
- nejpoužívanější metrikou je Euklidovská vzdálenost
- vektor středových hodnot je vypočítán jako aritmetický průměr vektorů aktuálně přiřazených danému klasteru

## Algoritmus K-means

- vstup: počet iterací (inicializací), počet klastrů  $K$ , práh přesnosti  $\epsilon$
- náhodně inicializuj rozdělení do klastrů  $C_1^1, \dots, C_K^1$  se středy  $c_1^1, \dots, c_K^1$  a vypočítej hodnotu optimalizační funkce  $W^1$
- v  $i$ -tému kroku proved:
  - výpočet  $C_1^{i+1}, \dots, C_K^{i+1}$  – přiřaď každý datový vektor  $x$  ke klastru s nejmenší vzdáleností středového vektoru od  $x$
  - přeypočítej středové vektory  $c_1^{i+1}, \dots, c_K^{i+1}$  a minimalizuj  $W^{i+1}$
- dokud  $\exists k, |c_k^i - c_k^{i+1}| \geq \epsilon$ , iteruj

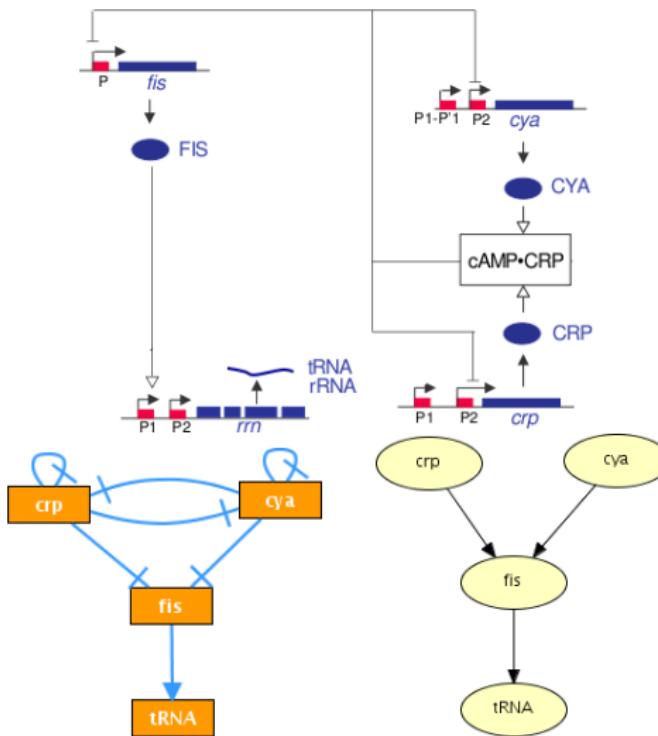
# *Nástroje pro cluster-based analýzu*

- klastrování lze využít pro detekci skupin shodně regulovaných genů
- kombinace klastrování dle genů a experimentů
  - odhadování regulátorů jednotlivých klastrů
  - odhadování programů regulace
- nástroje
  - Genomica (dříve GeneXPress)  
<http://genomica.weizmann.ac.il/>
  - FunCluster (balík pro R)  
<http://cran.r-project.org/web/packages/FunCluster/index.html>
  - STEM  
<http://www.cs.cmu.edu/~jernst/stem/>
  - EisenLab tools  
<http://rana.lbl.gov/EisenSoftware.htm>

## *Předpověď (reinženýring) regulačních sítí*

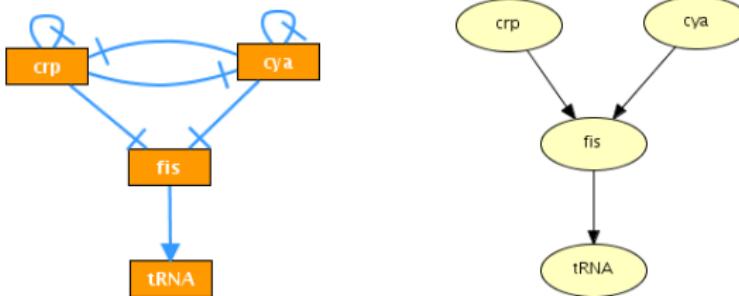
- regulační sítě lze předpovídat z microarray dat
- předpověď struktury sítě
  - detekce podmíněných závislostí proměnných
  - charakter korelace proměnných
- předpověď dynamiky proměnných
  - fitování naměřených dat na (spojitý) model
  - pravděpodobnostní rozložení diskrétních hodnot

# Předpověď (reinzenýring) regulačních sítí



# Předpověď (reinzenýring) regulačních sítí

Boolovské vs. Bayesovské sítě



$$crp(t+1) = \neg crp(t) \wedge \neg cya(t)$$

$$P(X_{crp})$$

$$cya(t+1) = \neg cya(t) \wedge \neg crp(t)$$

$$P(X_{cya})$$

$$fis(t+1) = \neg crp(t) \wedge \neg cya(t)$$

$$P(X_{fis}|X_{crp}, X_{cya})$$

$$tRNA(t+1) = fis(t)$$

$$P(X_{tRNA}|X_{fis})$$

# Předpověď (reinzenýring) regulačních sítí

## Bayesovské sítě

$$P(V|W) = \frac{P(V, W)}{P(W)}$$

$$P(W|V) = \frac{P(W, V)}{P(V)}$$

$$P(V, W) = P(W, V) = P(V|W) \cdot P(W) = P(W|V) \cdot P(V)$$

Bayesův vzorec:

$$P(V|W) = \frac{P(W|V) \cdot P(V)}{P(W)}$$

Obecně pro pravděpodobnost současných jevů platí řetězové pravidlo:

$$\begin{aligned} P(V, W, Y) &= P(V|W, Y) \cdot P(W, Y) \\ &= P(V|W, Y) \cdot P(W|Y) \cdot P(Y) \end{aligned}$$

# *Předpověď (reinženýring) regulačních sítí*

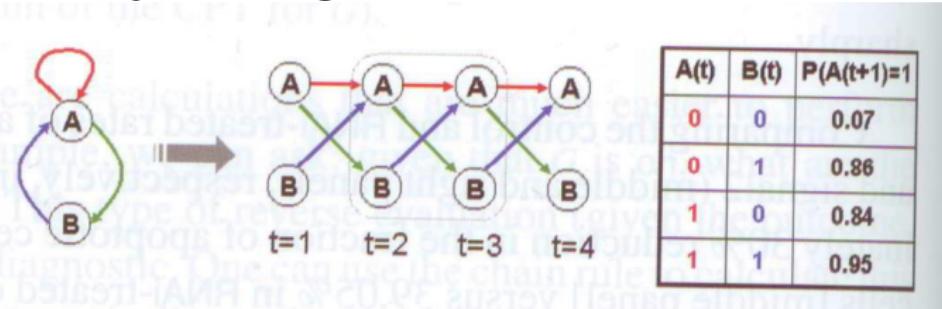
## *Algoritmy pro bayesovské sítě*

- strojové učení z experimentálních dat:
  - algoritmy učení struktury
  - algoritmy učení pravděpodobnostního rozložení  
např. Expectation Maximization (EM) – iterativní metoda maximalizující  $P(\text{data}|\text{model})$
  - kombinované algoritmy
- pro úspěšný výsledek vyžadována rozsáhlá sada dat
- nástroje:
  - Hugin (<http://www.hugin.com/>)
  - Genomica (<http://genomica.weizmann.ac.il/>)

# Předpověď (reinzenýring) regulačních sítí

## Algoritmy pro bayesovské sítě

- problémem jsou zpětné vazby (cykly v síti)
- řešením je unfolding v diskrétním čase:



- původní síť s  $n$  uzly je nahrazena sítí s  $2n$  uzly
- tabulka podmíněných pravděpodobností charakterizuje pravděpodobnost přechodů mezi jednotlivými konfiguracemi