

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

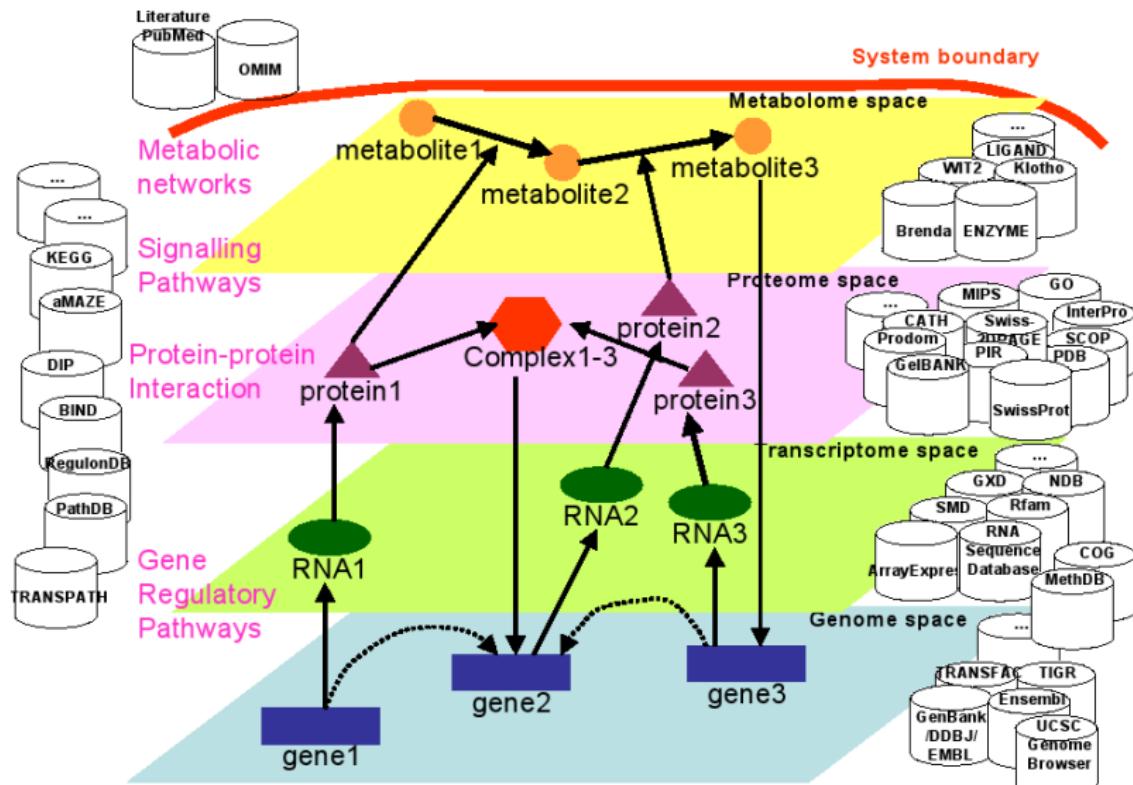


Biochemické procesy v buňce




- 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 sítě 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.

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)

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
 - ...



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)

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)

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 ϵ
- 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
 - odhady regulátorů jednotlivých klastrů
 - odhady programů regulace
- nástroje
 - balíky R a Python (BioPython)
 - STEM - příklad kombinované techniky
<http://www.cs.cmu.edu/~jernst/stem/>

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