

PA054: Formální modely v systémové biologii

David Šafránek

17.5.2013

Obsah

Parametrizace modelů a estimace parametrů

Obsah

Parametrizace modelů a estimace parametrů

Estimace parametrů

- co je cílem?
 - najít takovou valuaci parametrů, která nejlépe odpovídá experimentálně zjištěným time-course datům
 - chceme tedy co nejvíce přiblížit simulaci experimentálním datům (tzv. **fitting**)
 - tradiční pojetí pro spojitou sémantiku
- lineární regrese požaduje normální rozložení chyb měření
- transformací se nepřesnosti kumulují
- model je inherentně nelineární
 - nelineární jsou i naměřená data
- problém fittingu chápán jako optimalizační problém
- mnoho heuristických metod pro aproximativní řešení

Problém reverzního inženýrství

- tzv. **inverzní problémy**
 - cílem je získat model z pozorování systému
 - obecně řešeno v teorii systémů (identifikace systémů)
 - pro nelineární systémy obecně neřešitelné
 - viz. IV120
- obecné schema řešení inverzního problému:
 1. identifikace vztahů mezi proměnnými
 2. identifikace funkcí popisujících sémantiku jednotlivých vztahů (např. zákon zachování hmoty, Michaelis-Menten, Hill, ...)
 3. **estimace hodnot parametrů ve funkcích získaných v předch. bodě**

Estimace parametrů optimalizací

- obecný postup:
 1. srovnej experimentální time-course se simulovaným time-course
 2. pokud rozdíl menší než nastavená tolerance → DONE
jinak modifikuj parametry modelu
 3. proved time-course simulaci modelu
 4. iteruj (1)

Estimace parametrů optimalizací

- mějme model daný systémem $\frac{dx}{dt} = f(x, p)$ kde x je stavový vektor a p je **vektor hodnot parametrů**
- uvažujme $T = \langle t_1, \dots, t_m \rangle$ rostoucí posloupnost časových bodů (tzv. **časovou řadu**)
- předpokládejme posloupnost $\langle x(t_1), \dots, x(t_m) \rangle$ je aproximace řešení $x(t)$ zachycená v časové řadě T (**simulace**)
- zdůrazněme fakt, že simulace byla získána při nastavení hodnot parametrů p , označením $x(t)_p$
- mějme **experiment** jako posloupnost vektorů naměřených veličin $\langle y(t_1), \dots, y(t_m) \rangle$ v časové řadě T
- pro jednoduchost uvažujme $\dim(x) = \dim(y) = 1$ (obecně $\dim(x) \geq \dim(y)$ libovolné, ale složitější formulace)

Estimace parametrů optimalizací

- definujeme odchylku experimentu od simulace v časovém bodě t_i jako tzv. **reziduál**:

$$r(t_i, p) = y(t_i) - x(t_i)_p$$

- reziduál chápeme jako funkci závislou na nastavení parametrů simulovaného modelu
- srovnání experimentu a simulace je vyjádřeno jako součet čtverců reziduálů přes vš. časové body T :


$$S(p) = \sum_i^m (r(t_i, p))^2$$

Estimace parametrů optimalizací

- funkce $\mathcal{S}(p)$ se nazývá **užitková funkce**
- vystihuje průměrnou odchylku simulace od experimentu přes danou časovou řadu
- **minimální hodnota** $\mathcal{S}(p)$ určuje optimální vektor hodnot parametrů p , který globálně minimalizuje rozdíl mezi experimentem a modelem
- jedná se o nelineární funkci
- počet neurčitých parametrů určuje její dimenzi

Optimalizační krajina

Fitness



Search Space

Procházky po optimalizační krajině...

- CÍL: najít **globální minimum**
- nejpoužívanější jsou stochastické black-box přístupy:
 - náhodné procházení (random search)
 - evoluční strategie (evolution strategy)
 - ...
- black-box znamená absolutní nezávislost na tvaru užitkové funkce
- existují i metody, které využívají znalosti užitkové funkce (např. simulované žíhání, Truncated Newton, ...)

Procházky po optimalizační krajině...

Random Search

1. inicializuj náhodně výchozí hodnotu p
 - typicky z rovnoměrného rozložení
2. dokud není překročen povolený počet iterací, prováděj:
 - 2.1 sampluj novou pozici p'
 - uniformní náhodný výběr z hyperkoule o daném poloměru
 - 2.2 spočítej $S(p')$
 - 2.3 pokud $S(p') < S(p)$, nastav novou pozici $p := p'$
3. p nastaveno na nejvýhodnější pozici (z pohledu běhu algoritmu)

Pozn. Existují varianty s fixním i adaptivním poloměrem.

Procházky po optimalizační krajině...


Evoluční strategie

- inherentně adaptivní metoda, redukuje počet
- staví na výběrech z (vícerozměrného) normálního rozložení
- rozměr daný dimenzí vektoru parametrů
- značeno CMA-ES (Covariance Matrix Evolution Strategy)
- postup:
 1. vytvoř generaci
 - sampluj rozložení pozic hodnot P dle normálního rozložení
 2. pro každé $p \in P$ spočítej $S(p)$
 3. adaptace: uprav parametry normálního rozložení pro další iteraci
 - různé varianty, mohou být velice komplexní adaptace citlivé na charakter evoluční krajiny – adaptace kovarianční matice
- metoda se ukazuje výhodná pro biologické modely (vysoká míra neznalosti parametrů)


Procházky po optimalizační krajině...

Evoluční strategie


First generation



Second generation



Third generation



Tuning dynamických modelů

Estimace parametrů vzhledem k hypotézám

- estimaci parametrů lze rozšířit pro temporální specifikace (hypotézy)
 - každý experiment lze zakódovat jako LTL formuli
 - typické abstraktnější vlastnosti dávají větší stupeň volnosti
- mějme specifikaci chování reprezentovanou LTL formulí φ
- uvažme parametrizovaný systém $\frac{dx}{dt} = f(x, p)$
- uvažme časovou řadu T
- $x_{p,T}$ značí simulovanou posloupnost v časové řadě T s nastavením parametrů p
- definujme užitečnou funkci

$$S(p) = vd(x_{p,T}, \varphi)$$

, kde $vd(x_{p,T}, \varphi)$ určuje míru splnění formule φ na $x_{p,T}$

Aplikace formálních metod

- temporální vlastnosti jako dynamická omezení
 - obecnější než časové řady
 - časové řady je také možné vyjádřit
 - logiky interpretované na spojitých trajektoriích (QLTL, STL)
- optimalizace vůči míře splněnosti
- kritériem je maximalizovat robustnost splnitelnosti vlastnosti
- nástroje Breach (VERIMAG), BioCHAM (INRIA), Parasim (FIMU)

Kvalitativní modely

- parametrizována je přechodová relace
- např. boolovské modely regulačních sítí
- lze použít symbolické metody (např. NuSMV)
- explicitní metody (SimBioNet)
- heuristiky pro explicitní metody (Parsybone)

Stochastické modely

- spojitý prostor parametrů (rates)
- problém parametrizace CTMC
- metody tzv. momentů (numerická simulace charakteristických funkcí pravd. rozložení)
- numerické metody vycházející z tranzientní analýzy (výpočetně náročné, ve vývoji)