

Identifikace parametrů vybraných subsystémů dynamického modelu fyziologických funkcí "eGolem"

autor: Bc. Jan Šilar,
vedoucí: Mgr. Marek Mateják

Práce psána ve spolupráci s

Laboratoř biokybernetiky a počítačové podpory výuky

Ústav patologické fyziologie

1. lékařská fakulta

Universita Karlova

RNDr. Bohuslav RŮŽEK CSc - inverzní úlohy geofyziky

Identifikace modelů

- ▶ modely fyziologických dějů - simulují děje v lidském těle
- ▶ Úkol: zjistit hodnoty parametrů modelu tak, aby výsledky simulace odpovídaly datům naměřeným při experimentu na konkrétním člověku
- ▶ používáme optimalizační nebo inverzní techniky
- ▶ takto určujeme parametry jejichž měření: invazivní (zásah do těla), drahé, nemožné

Proč identifikovat parametry?

- ▶ **získání hodnot parametrů**, které je jinak obtížné zjistit → nová diagnostická metoda využitelná v praxi
- ▶ **nafitovaný model**: model nyní simuluje konkrétního člověka → využití v praxi (např. v anesteziologii)
- ▶ **ověření modelu**: nafitování modelu na experimentální data se zdaří → model dobře popisuje jevy probíhající při měřeném experimentu

Model

- ▶ soustava algebraických a obyčejných diferenciálních rovnic (*DAE*)
- ▶ rovnice nelineární
- ▶ modely často hybridní - hodnoty veličin nebo celé rovnice se mění v závislosti na podmínkách (příklad s cévou)
- ▶ počet proměnných až několik tisíc



S modely nejde pracovat analyticky \Rightarrow numerické řešení.

- ▶ modely implementovány v simulačním jazyce *Modelica* (editor *Dymola*) a přeloženy \rightarrow reziduální funkce

$$F(t, x, \dot{x}) = 0 \quad (1)$$

jako knihovna (zatím většinou v C++)

- ▶ solver řeší model na základě reziduální funkce

Formulace úlohy

Máme:

experimentální data: $\bar{x}_E(t)$ - vektor časových průběhů veličin naměřených při experimentu na pacientovi. Každá složka – funkce času, odpovídá jedné měřené veličině.

implementovaný model: $M(\bar{p}, \bar{x}_0) \rightarrow \bar{x}_S(t)$ - simuluje experiment, vektoru parametrů \bar{p} a vektoru počátečních podmínek \bar{x}_0 přiřadí vektor časových průběhů simulovaných veličin $\bar{x}_S(t)$.

Úkol najít:

minimum

$$\min_{\bar{p}} \| M(\bar{p}, \bar{x}_0) - \bar{x}_E(t) \|_{L2} \quad (\text{optimalizace}), \quad (2)$$

nebo řešení přeurčené soustavy rovnic pro neznámé \bar{p}

$$M(\bar{p}, \bar{x}_0, t_i) = \bar{x}_E(t_i), \quad \forall i \in N \quad (\text{inverze}). \quad (3)$$

Lokální / globální metody

Účelová funkce může mít na prohledávaném intervalu jedno nebo více lokálních minim.

- ▶ **jedno lokální minimum** \Rightarrow použijeme lokální metodu (např. simplexovou) - rychlý výpočet.
- ▶ **více lokálních minim** \Rightarrow globální metody. Pro n parametrů prohledáváme prostor dimenze n . Hrubá síla $O(\exp(n))$.
- ▶ fyziologické modely - většinou více lokálních minim \rightarrow zabýváme se hlavně globálními metodami
- ▶ vyhodnocování modelu časově náročné \rightarrow efektivní jsou metody, které minimalizují počet vyhodnocení modelu

Odhad počtu lokálních minim

kvůli výběru metody

- ▶ náhodně generujeme počáteční odhady \bar{p}
- ▶ voláme opakovaně lokální minimalizační metodu (simplexovou)
- ▶ N numerických aproximací minim \rightarrow shluková analýza
- ▶ shlukujeme do $m = 1, 2, 3 \dots$ shluků
- ▶ sledujeme hodnotu kritériální funkce



$$c = \sum_{i=1}^m \sum_{j=1}^n \text{std}(p_j^i), \quad (4)$$

n je počet parametrů, m je počet shluků. Součet směrodatných odchylek přes všechny parametry a všechny shluky.

Příklad:

$$y = \sin(x) + \sin(y) \quad (5)$$

na intervalu $\langle -4, 6 \rangle \times \langle -4, 6 \rangle$, kde má 4 minima.



Funkce přestane prudce klesat → správný počet shluků

Testované metody

- ▶ ANNI
- ▶ Isometrická metoda (obě pro inverzní metody navržené pro úlohy geofyziky)
- ▶ CMA-ES - evoluční algoritmus

Funkce Matlabu (balíčky *Optimization Toolbox* a *Global Optimization Toolbox*)

- ▶ `fminsearch` - simplexová metoda
- ▶ `ga` - genetický algoritmus
- ▶ `patternsearch`
- ▶ `simulannealbnd` - simulované žíhání

Testy

fitování dvou testovacích funkcí, jedna z nich:


$$y = c \cdot \text{sinc}(a \cdot (x - b)) + d \cdot x \quad (6)$$

$a = 2$, $b = 0$, $c = 3$, $d = 0.2$

- ▶ Vygenerujeme hodnoty funkce na nějaké síťce
- ▶ Data zašumíme
- ▶ “Zapomeneme” hodnoty parametrů a fitujeme

Metoda	N_{eval}	$errsum$
ANNI	809	$5.6 \cdot 10^{-17}$
CMA-ES	–	–
GA	1041	0.047
Isometric	6796	0.043
Pattern Search	683	0.043
SimulAnneal	2559	0.039

ANNI – nejpřesnější
Pattern Search – nejméně vyhodnocení
CMA-ES – nefungovala.



Model odporu krevního řečiště při zátěži - úvod

Experiment

- ▶ data od týmu Dr. Uwe Hoffmanna
- ▶ pacient na rotopedu, zátěž 30W, 200W, 0W
- ▶ měřeno *HR* – srdeční frekvence, *MAP* – střední arteriální tlak, *CO* – minutový srdeční tok, *PW* – celkový výkon.

Fyziologie


- ▶ při fyzické zátěži – svaly spotřebovávají kyslík
- ▶ dostatek kyslíku ve svalech → změny odporu částí krevního řečiště – redistribuce krve (kyslíku) do jednotlivých tkání
- ▶ způsobeno *sympatickou reakcí* – dva efekty
 - ▶ stažení cév vegetativních orgánů → méně krve do orgánů, více krve do svalů, zvětšení celkového odporu.
 - ▶ zvýšení *HR*
- ▶ *HR* měřená – ukazatel velikosti sympatické reakce

Základní model

Zjednodušené krevní řečiště modelu eGolem. Nepočítá každý úder srdce, jen střední hodnoty toků.

Analogie s elektrickým obvodem.

- ▶ srdce – pumpa, dodává tok CO (měřená veličina).
- ▶ krevní řečiště má jediný odpor – celkový hydraulický odpor velkého krevního oběhu
$$R = R_0 \cdot q(HR, \tau)$$
- ▶ R_0 základní systémový odpor (bez simpatické reakce),
- ▶ q koeficient změny odporu vlivem simpatické reakce, závisí na HR , τ - zpoždění změny (stažení nenastává okamžitě)




Identifikace základního modelu

- ▶ Identifikujeme parametry $R_0 \in \langle 0, 300 \rangle$ a $\tau \in \langle 0, 20 \rangle$.
- ▶ Účelová funkce má na intervalu jediné lokální minimum.

Metoda	N_{eval}	(R_0, τ)	f_{val}
ANNI	1613	(172.6, 9.8)	$4.6914 \cdot 10^3$
CMA-ES	2379	(187.0, 9.8)	$4.6873 \cdot 10^3$
GA	2021	(11.6, 9.4)	$1.1383 \cdot 10^4$
Isometric	3117	(182.3, 9.8)	$4.6881 \cdot 10^3$
PatSe	414	(187.0, 9.8)	$4.6873 \cdot 10^3$
SimAn	6002	(166.1, 9.8)	$4.6898 \cdot 10^3$
Simplex	83	(188.0, 9.8)	$4.6873 \cdot 10^3$

Simplexová – neefektivnější,
PatternSearch – druhá,
GA – nenašla.

Chyba vlivem rozdílu křivek,
těžko provnat přesnost.



Rozšířený model

- ▶ Další vliv – lokální svalová reakce.
- ▶ Cévy přivádějící krev do pracujících svalů se samy rozšíří → více krve do svalů, snížení celkového odporu.

$$R = R_0 \cdot \frac{q(HR, \tau)}{rf(PW, \tau_{inc}, c_{dec})}$$

- ▶ rf relaxační faktor – závisí na výkonu svalů, τ_{inc} zpoždění náběhu relaxace, c_{dec} koeficient ústupu reakce

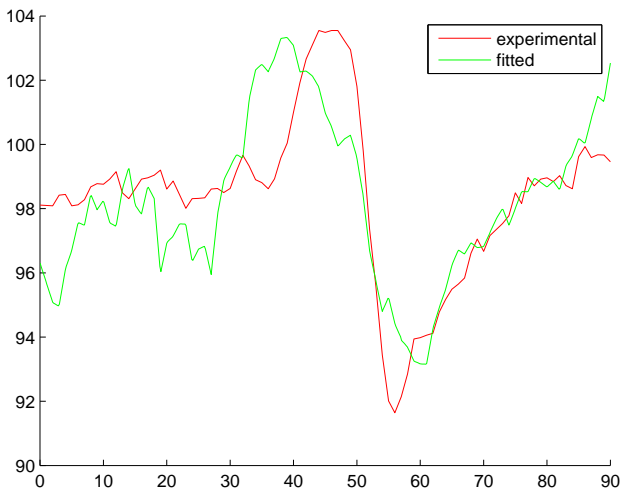
Metoda	N_{eval}	$(R_0, \tau, \tau_{inc}, c_{dec})$	f_{val}
ANNI	1617	(66.8, 9.84, 4.24, 5.51)	269.1
CMA-ES	1995	(190.0, 10.0, $1.72 \cdot 10^5$, $2.91 \cdot 10^5$)	$4.69 \cdot 10^3$
GA	1701	(51.2731, 9.86, 4.365.36)	275.0
Isometric	3434	(69.6, 9.89, 4.03, 5.29)	252.4
PatternSearch	1863	(71.2, 9.89, 4.13, 5.34)	251.8
SimmulAnneal	12002	(182.7, 9.97, 3.45, 5.31)	318.6095
Simplex	387	(55.49.8818.311.8)	$2.17 \cdot 10^3$

ANNI – neefektivnější

PatternSearch – nepřesnější

Simulované žihání – neefektivní, nepřesné

CMA-ES, Simplexová – špatné výsledky



Experimentální a naitovaná data rozšířeného modelu si již docela dobře odpovídají. Posunutá maxima – možnost upřesnit model.

Projekty, spolupráce

Současné:

- ▶ CESNET - vybudování gridu pro identifikaci parametrů (výpočetně náročné). Vytvoření robustního rozhraní mezi modelem a identifikačním algoritmem pro paralelizaci.
- ▶ Spolupráce s týmem Dr. Uwe Hoffmannan, Sportovní univerzita v Kolíně nad Rýnem. Fyziologie v extrémních podmínkách - vrcholoví sportovci, potapěči, kosmonauti. Zpracováváme jejich data.

Plánované:

- ▶ GAČR - Podán grantový návrh. Identifikace parametrů modelu krevního řečiště. Plánováno několik experimentů – měření mnoha veličin.

Co se udělalo

- ▶ vybrány a otestovány vhodné metody pro identifikaci fyziologických modelů.
- ▶ vytvořeno prostředí pro identifikaci modelů. Umožňuje rychlé přepínání identifikovaných modelů, snadná volba identifikační metody a parametrů metody. Zpřehledňuje práci. Implementace rozhraní mezi identifikačním algoritmem a modelem pomocí tcp-ip.
- ▶ navržena metoda pro zjištění počtu minim (hlavně 1 nebo více)
- ▶ pospána citlivostní analýza MC simulace chyb, implementace po odevzdání.
- ▶ identifikační prostředí použito při identifikaci modelu odporu krevního řečiště při zátěži → navrženo rozšíření modelu eGolem.

Co se plánuje udělat

- ▶ zpřehlednit kód.
- ▶ robustnější rozhraní pro komunikaci identifikační algoritmus – model.
- ▶ paralelizace vybraných metod – grid, později CUDA.
- ▶ hybridní přístup → lokální metody.
- ▶ identifikační prostředí součástí editoru modelů.

Děkuji za pozornost.

Použití aproximačních modelů v medicíně

▶ kdy se používají:

mnoho vztahů v používaných v modelech je získáno aproximací měřených dat nějakou funkcí. Fyziologické a fyzikální mechanismy jsou často složité nebo neznámé.

▶ při identifikaci parametrů

- ▶ nemáme k dispozici “trénovací množinu” – množinu dvojic (\bar{p}_i, \bar{d}_i) pro naučení/nastavení aproximačního modelu.
- ▶ jediná možnost nastavit aproximační model tak, aby kopíroval fyziologický model → mnoho vyhodnocení dopředného modelu.
- ▶ Aproximační model – rychlejší výpočet než fyziologický → vyplatí se, pokud bychom prováděli identifikaci opakovaně, s různými daty.

▶ Neuronové sítě – zpracování a rozpoznávání signálů.

Automatická diagnóza onemocnění, detekce nádoru v obraze (MR), zpracování EKG a EEG...

Citlivostní analýza a závislost parametrů

Citlivost identifikovaných parametrů na chyby v datech.
Závislost parametrů – různé kombinace hodnot parametrů vedou k podobnému výsledku modelu → parametry není možné identifikovat.

MC simulace chyb

- ▶ identifikované parametry → modelová data.
- ▶ opakujeme:
 - ▶ generování náhodného šumu (zde gaussovský $\sigma^2 = 1$, $\mu = 0$)
 - ▶ data + šum
 - ▶ identifikace → parametry
- ▶ spočtemem kovarianční matici realizací parametrů

Výsledky simulace chyb

$$\bar{p} = (R_0, \tau, \tau_{inc}, c_{dec}) = (71.2, 9.89, 4.13, 5.34) \quad (7)$$

$$\text{cov}(pp) = \begin{pmatrix} 5.8309 & 0.0088 & -0.1496 & -0.0330 \\ 0.0088 & 0.0000 & -0.0004 & -0.0001 \\ -0.1496 & -0.0004 & 0.0159 & 0.0034 \\ -0.0330 & -0.0001 & 0.0034 & 0.0015 \end{pmatrix} \quad (8)$$

Největší rozptyl má první parametr, ale

$$\text{err} \approx \sigma = \sqrt{\sigma^2} = (2.41473, 0.0, 0.1261, 0.03873) \quad (9)$$

$$\text{err}_r \approx \sigma/\bar{p} = (0.034, 0.0, 0.031, 0.0090) \quad (10)$$

Kdyby byl rozptyl chyby měření dat roven 1, odpovídaly by chyby identifikovaných parametrů zhruba těmito hodnotám.

Mimodigonální prvky jsou relativně malé, parametry by neměly být závislé.

Děkuji za pozornost.