

Luščenje modelskih parametrov in razdelčni modeli

6. domača naloga pri predmetu Modelska analiza I
Domen Vaupotič

V nalogi se bomo ukvarjali z luščenjem modelskih parametrov. Osnovni namen luščenja modelskih parametrov je določiti parametre (fizikalnega) modela tako, da model karseda dobro prilega k (eksperimentalnim) meritvam. Pri tem uporabljamo različne mere, s katerimi kvantitativno ovrednotimo, kako dobro se model ujema z meritvami. Ena izmed njih je statistični test χ^2 , ki ga lahko uporabimo, kadar so merne negotovosti porazdeljene Gaussovsko. Tedaj je namreč minimizacija χ^2 ekvivalentna maksimizaciji funkcije verjetja.

$$\chi^2 = \sum_{i=1}^N \frac{(y_i - f(x_i; \vec{a}))^2}{\sigma_i^2}$$

Izračunano vrednost primerjamo s porazdelitvijo χ^2 z ustreznim številom prostostnih stopenj $\nu = N - M$, pri čemer je N število izmerkov in M število parametrov modela.

Pri izbiri modela kot epistemološko podstat pogosto upoštevamo princip *Ockhamove britve*, s čimer težimo po izbiri varčnih modelov – modelov, ki imajo le toliko prostostnih stopenj, kot je nujno potrebno.

Najenostavnejši modeli so linearni:

$$f(x; \vec{a}) = \sum_{i=1}^N a_i \phi_i(x)$$

Tedaj lahko minimizacijo χ^2 pretvorimo v reševanje linearnega sistema enačb

$$A \vec{a} = \vec{b} \quad A_{jk} = \sum_{i=1}^N \frac{\phi_j(x_i) \phi_k(x_i)}{\sigma_i^2}, \quad b_j = \sum_{i=1}^N \frac{y_i \phi_j(x_i)}{\sigma_i^2}$$

pri čemer so (x_i, y_i) meritve, ϕ_j bazne funkcije in σ_i merne negotovosti.

Kadar modela ne moremo zapisati v linearni obliki, se poslužimo nelinearnih modelov, pri katerih minimizacijo opravimo z eno izmed metod za numerično optimizacijo, npr. Levenberg-Marquardtovo iterativno metodo:

$$\vec{a}_{i+1} = \vec{a}_i - H^{-1}(\chi^2(\vec{a}_i))$$

pri čemer H predstavlja Hessovo matriko drugih odvodov funkcije χ^2 .


1. Farmakološki model odziva tkiva

V prvem delu obravnavamo enostaven farmakološki model vezave liganda na receptor $X + Y \leftrightarrow Y^*$, pri katerem v ravnotežju velja

$$y = \frac{y_0 x}{x + \sigma}$$

Okometrična metoda

Preverimo najprej, kakšne parametre lahko določimo zgolj z opazovanjem krivulje: $y_0 = 103$, $\sigma = 18$.



Reševanje linearnega sistema

Model lahko lineariziramo:

$$y = \frac{y_0 x}{x + \sigma} \rightarrow \frac{1}{y} = \frac{\sigma}{y_0} \frac{1}{x} + \frac{1}{y_0} = a_1 + a_2 \frac{1}{x}$$

s čimer dobimo bazni funkciji $\phi_1 = 1$ in $\phi_2 = 1/x$ ter označimo pripadajoča koeficienta $a_1 = 1/y_0$ in $a_2 = \sigma/y_0$.

Dobimo sistem dveh enačb z dvema neznankama.

$$2.65422 \times 10^7 a_1 + 181.798 a_2 = 290.347$$

$$181.798 a_1 + 4660.2 a_2 = 2679.95$$

Sistem rešimo in s tem določimo najboljše parametre. Iz matrike A lahko določimo še negotovost parametrov. Ujemanje modela za vsako posamezno točko prikažemo z residuali:

$$\text{residual}(x_i) = \frac{y_i - f(x_i)}{\sigma_i}$$

$$A^{-1} = \begin{pmatrix} 5.14 \times 10^{-8} & -2.01 \times 10^{-6} \\ -2.01 \times 10^{-6} & 2.93 \times 10^{-4} \end{pmatrix}$$

	vrednost	σ
a_1	9.55×10^{-3}	2.27×10^{-4}
a_2	2.02×10^{-1}	1.71×10^{-2}

	vrednost	σ
a	21.2	2.3
y_0	104.7	2.5

Za izračun kovariance matrike moramo opraviti ustrezno transformacijo.

$$\vec{a} = (a, y_0) = (a_2/a_1, 1/a_1)$$

$$\vec{b} = (a_1, a_2) = (1/y_0, \sigma/y_0)$$

$$\Sigma(\vec{a}) = D \Sigma(\vec{b}) D^T, \quad D_{ki} = \left(\frac{\partial a_i}{\partial b_j} \right) / \sigma_j$$


$$D = \begin{pmatrix} -a_2/a_1^2 & 1/a_1 \\ -1/a_1^2 & 0 \end{pmatrix}$$

$$\Sigma(\vec{a}, y_0) = \begin{pmatrix} 4.39 & 3.55 \\ 3.55 & 6.17 \end{pmatrix}$$




Vgrajene metode

Za prilaganje lahko uporabimo tudi vgrajeno metodo *NonlinearModelFit*, ki modela ne linearizira, temveč uporabi metodo nelinearnega prilaganja po metodi Levenberg-Marquardt.



Estimate	Standard Error	t-Statistic	P-Value	
a	106.317	4.75897	22.2042	1.0493×10^{-7}
σ	19.7676	2.28365	8.65607	0.00030202
y_0	24.7625	4.16392	5.94691	0.00010503

Siclerjemo si še zaporedne iteracije iskanja najboljših parametrov, kot jih opravi metoda *NonlinearModelFit*, ki sicer konvergira v 16. korakih.




Ogledimo si, kako izgleda funkcija, ki jo minimiziramo. Opazimo, da lahko v bližini minimuma funkcijo zares lepo aproksimiramo s kvadratno formo. Zelo lepo se v tem pogledu vidi in razume tudi pomen kovariance elipse (označene z belo).



Razširjeni model

Uporabimo lahko tudi razširjeni (Hillov) model.

Hillov model ($a=2$)




Estimate	Standard Error	t-Statistic	P-Value	
y_0	99.6056	3.51558	28.2042	1.0493×10^{-7}
a	19.7676	2.28365	8.65607	0.00030202
p	1.3641	0.176849	7.71339	0.000584633

$$\chi^2 = 2.9$$

$$\chi^2_c = 1.87$$

$$\Sigma(\vec{a}, y_0) = \begin{pmatrix} 22.6478 & 13.221 \\ 13.221 & 17.3383 \end{pmatrix}$$

Primerjajmo vse tri modele. Opazimo, da se kovariance elipse delno prekrivajo in da z razširjenim modelom dobimo bistveno boljše prilaganje podatkom (na račun enega dodatnega parametra).



2. Čistilnost ledvic

V drugem delu naloge se ukvarjamo z meritvami čistilnosti ledvic, ki jih obravnavamo z razdelčnim modelom. V najnosnejšem modelu ledvice predstavimo z enim razdelkom, čemur ustreza "enoparametrični" eksponentni model (ena razpolovna konstanta). Model lahko razširimo v dvorazdelčni, ki vsebuje dve razpolovni konstanti. Nadajlje lahko k meritvam prilagamo tudi drugačne modele.

Nelinearno prilaganje


Modela tokrat ne moremo več linearizirati, zato je edina možna metoda nelinearno prilaganje. Hitro opazimo, da samodejno prilaganje ni uspešno, saj pride do prekoračitve števil.

```
fit2 = NonlinearModelFit[podatki2, A Exp[-lambda t], {A, lambda}, t];
```

General: Overflow occurred in computation.

Metodi moramo torej podati ustrezne začetne približke (sicer vse postavi na 1). Slabi začetni približki (npr. $A = 10\,000$ in $\lambda = 10$) dajo nemisljen rezultat.

```
fit2 = NonlinearModelFit[podatki2, A Exp[-lambda t], {{A, 10000}, {lambda, 10}}, t];
```




Smiselni začetni rezultati vodijo v uspešno konvergenco metode, vendar takoj opazimo, da model slabo opiše dane meritve.

```
fit2 = NonlinearModelFit[podatki2, A Exp[-lambda t], {{A, 14000}, {lambda, 0.001}}, t];
```




Primerjajmo sedaj različne modele.



Opazimo, da se model s kovarsko-exponentno odvisnostjo (●) prilaga bolje kot navadni eksponentni model (○), čeprav imata isti število parametrov. Zanimivo opazimo, da se recipročni model z zgolj tremi parametri (●), ki ga sicer nismo teoretično izpeljali iz razdelčnih modelov, prilaga boljše kot ostali modeli.

Ogledimo si, kako vpliva dodajanje "ozadja" (konstanta) k dvorazdelčnemu eksponentnemu modelu. Opazimo, da se s tem nekoliko opveča negotovost obeh parametrov A , prav tako se njuna vrednost zelo spremeni, tako da se kovarianci elipse ne prekrivata.

Estimate	Standard Error	t-Statistic	P-Value	Estimate	Standard Error	t-Statistic	P-Value	
a	8.03×10^3	2.12×10^3	3.79×10^1	6.14×10^{-13}	5.45×10^3	4.32×10^2	1.26×10^1	8.34×10^{-12}
b	5.55×10^7	2.10^7	2.77×10^1	1.01×10^{-10}	6.29×10^7	3.59×10^6	1.76×10^1	8.11×10^{-12}
λ_1	-5.24×10^{-4}	2.64×10^{-4}	-1.98×10^1	2.14×10^{-16}	-8.12×10^{-3}	7.55×10^{-4}	-1.08×10^1	1.9×10^{-10}
λ_2	-4.54×10^{-4}	2.62×10^{-4}	-1.73×10^1	4.47×10^{-15}	-1.44×10^{-3}	7.3×10^{-4}	-1.1×10^1	1.17×10^{-10}
				c	1.99×10^7	1.03×10^7	1.92×10^1	1.15×10^{-15}



3. Magnetni spektrometer

V tretjem delu naloge se ukvarjamo s kalibracijskimi podatki magnetnega spektrometra. Najti želimo preslikavo $(x_{tp}, \theta_{tp}) \rightarrow \theta_{tp}$.

Pri tem bomo uporabili potenčne bazne funkcije obeh spremenljivk do p -tega reda v x_{tp} in do q -tega reda v θ_{tp} .

```
baza[p_, q_] := {Sum[x^i, {i, 0, p}], Sum[theta^j, {j, 0, q}]} // Expand // Plus[#, #] & // Flatten
```

```
baza[0, 0]
```

```
baza[3, 0]
```

```
baza[2, 3]
```

```
{1}
```

```
{1, x, x^2, x^3}
```

```
{1, x, x^2, theta, x theta, x^2 theta, theta^2, x theta^2, x^2 theta^2, theta^3, x theta^3, x^2 theta^3}
```

Zaradi velikega števila izmerkov in velikega števila baznih funkcij se moramo poslužiti bolj učinkovite metode za minimizacijo χ^2 . Uporabimo razcep in singularne vrednosti (SVD).

```
SVDfit[baza_, podatki_, tol_ := 10^-15] := Module[{A, b, U, W, V, w, rRec, thresh, a, sigma, X2},
```

```
  a = (baza /. {x -> #[1], theta -> #[2]}) & /@ podatki;
```

```
  b = podatki[[All, 3]];
```

```
  {U, W, V} = SingularValueDecomposition[A, Tolerance -> 10^-20];
```

(*) Prilaganje s SVD dodatno izboljšamo tako, da odstranimo vektorje, ki pripadajo zelo majhnim singularnim vrednostim (mejo izberemo glede na največjo singularno vrednost).

To storimo tako, da postavimo ustrezno singularno vrednost na 0, hkrati pa tudi njeno recipročno vrednost na 0. *)

```
thresh = tol * Max@Diagonal@W;
```

```
{w, wRec} = (If[# > thresh, {#, 1/#}, {0, 0}]) & @ Diagonal[W] // Transpose;
```

```
a = Sum[U[[All, i]].b.V[[All, i]] wRec[[i]],
```

```
  {i, 1, Length@U}];
```

```
sigma = Sqrt[Sum[V[[i, All]]^2 * wRec[[i]]^2,
```

```
  {i, 1, Length@U}];
```

```
X2 = Norm[a - b]^2;
```

```
{a, sigma, X2, w}
```


Test delovanja algoritma

Preverimo, ali algoritem deluje, tako da ga uporabimo na znani porazdelitvi podatkov:

$$(x, \theta) \rightarrow 3 + 2x - x^2 + \theta^2 - 4x\theta + \epsilon,$$

pri čemer je ϵ enakolično porazdeljena merska napaka.

$$\epsilon = 0 \quad \epsilon \sim \mathcal{N}(0, 20)$$




	\vec{a}	$\sigma(\vec{a})$	χ^2
brez napake	$\begin{pmatrix} 1 & 3. & 7.2 \times 10^{-2} \\ x & 2. & 1.2 \times 10^{-2} \\ x^2 & -1. & 1.2 \times 10^{-2} \\ \theta & 3.7 \times 10^{-16} & 5.4 \times 10^{-3} \\ x\theta & -4. & 1.6 \times 10^{-3} \\ x^2\theta & 1.6 \times 10^{-17} & 5.1 \times 10^{-2} \\ x\theta^2 & 1. & 1.5 \times 10^{-3} \\ x^2\theta^2 & -3.9 \times 10^{-16} & 3.8 \times 10^{-3} \\ x^2\theta^2 & -3.9 \times 10^{-16} & 6.7 \times 10^{-3} \end{pmatrix}$	5.4×10^{-24}	
z napako	$\begin{pmatrix} 1 & 5. & 7. \times 10^{-2} \\ x & 1.7 & 9.2 \times 10^{-3} \\ x^2 & -8.1 & 1.5 \times 10^{-2} \\ \theta & -8.5 \times 10^{-2} & 6.7 \times 10^{-3} \\ x\theta & -4. & 1.6 \times 10^{-2} \\ x^2\theta & -8.6 \times 10^{-3} & 5.8 \times 10^{-2} \\ x\theta^2 & 9.9 \times 10^{-1} & 2.8 \times 10^{-3} \\ x^2\theta^2 & 2.4 \times 10^{-2} & 3 \times 10^{-3} \\ x^2\theta^2 & 2.1 \times 10^{-3} & 1.2 \times 10^{-3} \end{pmatrix}$	3.5×10^5	

Opazimo, da nam (do numerične natančnosti) uspe v primeru brez šuma povsem rekonstruirati parametre porazdelitve. Tudi v primeru šuma se približamo pravih vrednostim.

Eksperimentalni podatki


Meritve so podane kot trojica $(x_{tp}, \theta_{tp}, \theta_{tp})$, pri čemer so natančnosti meritev kotov velikostnega reda miliradianov, položajev pa okrog milimetra. Najprej reskaliramo podatke tako, da bo absolutna napaka obojih enil in znašala eno enoto. S tem poenostavimo izraz za χ^2 . Torej pretvorimo vse na miliradiane.



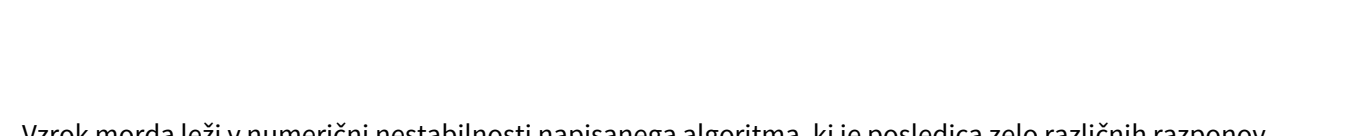
Sedaj prilagamo vse možne kombinacije polinomskih nastavkov do $p \leq 6$ in $q \leq 6$.




Opazimo, da se z naraščanjem števila parametrov model bolje ujema, vendar algoritem odpove pri približno 15 parametrih.



Vzrok morda leži v numerični nestabilnosti napisanega algoritma, ki je posledica zelo različnih razponov vrednosti. Reskalirajmo zato podatke tako, da bodo vse tri količine v območju [-1, 1] in ponovimo prilaganje.



Tokrat algoritem ne odpove in ponovno opazimo boljše ujemanje z večjim številom parametrov. Že pri približno 15 parametrih pa se model ne izboljšuje več bistveno.



Najprimernejši model

Vzemimo kot izhodiščni najprimernejši model $(p, q) = (2, 3)$ z dvanjajstimi parametri, pri katerem je kakovost ujemanja zelo dobra, število parametrov pa še ne preveliko.

člen	koeficient	negotovost	relativna negotovost
1	1.21×10^{-1}	2.9×10^{-2}	2.4×10^{-1}
x	-4.65×10^{-1}	7.5×10^{-2}	1.6×10^{-1}
x^2	-1.35×10^{-2}	3.3×10^{-2}	2.5
θ	5.71×10^{-1}	7.6×10^{-2}	1.3×10^{-1}
$x\theta$	2.51×10^{-1}	$4. \times 10^{-2}$	1.6×10^{-1}
$x^2\theta$	-3.53×10^{-3}	4.8×10^{-2}	1.4×10^1
θ^2	-1.01×10^{-1}	1.3×10^{-1}	1.3
$x\theta^2$	1.47×10^{-1}	4.7×10^{-2}	3.2×10^2
θ^3	1.94×10^{-1}	$1. \times 10^{-1}$	5.4×10^1
$x\theta^3$	1.47×10^{-2}	$6. \times 10^{-2}$	4.1
$x^2\theta^3$	-2.84×10^{-3}	$1. \times 10^{-1}$	4.2×10^1
$x^2\theta^3$	-2.84×10^{-3}	1.8×10^{-1}	6.5×10^1

$$\chi^2 = 0.089$$

Sedaj poskusimo narediti model še varčnejši, tako da postopoma odstranjujemo člene z majhnimi koeficienti in vsakič znova izvedemo prilaganje s danimi baznimi funkcijami.



Opazimo, da lahko odstranimo kar 5 členov in pri tem vrednost χ^2 le za približno 3%. Ostane nam model s 7 parametri.