

DESIGN EXPERIMENTU PRO REGRESNÍ MODELY S PODMÍNKAMI TYPU I

TUČKOVÁ M.^{1,2,*}, KUBÁČEK L.¹, TUČEK P.²

¹ Katedra matematické analýzy a aplikací matematiky

² Katedra geoinformatiky

Přírodovědecká fakulta, Univerzita Palackého v Olomouci

*korespondující autor: michaela.tuckova@upol.cz

SHRNUTÍ

Poster prezentuje hledání lokálně optimálního návrhu měření pro regresní modely s podmínkami typu I. Zabýváme se kriteriálními funkcemi lokální A-optimality, C-optimality a D-optimality, pro které odvozujeme konkrétní podoby gradientů a následně demonstrujeme iterační proces výpočtu.

REGRESNÍ MODEL S PODMÍNKAMI TYPU I

Uvažujeme regulární nelineární model s nelineárními podmínkami typu I daný vztahem

$$\mathbf{Y} = \phi(\mathbf{x}, \boldsymbol{\theta}) + \boldsymbol{\epsilon}, \quad \eta_j(\boldsymbol{\theta}) = 0, \quad j = 1, \dots, q,$$

kde \mathbf{Y} je observační vektor, ϕ a η_j jsou známé nelineární funkce, $\mathbf{x} = \{x_1, \dots, x_n\}$ je množina experimentálních bodů, $\boldsymbol{\theta} = (\theta_1, \dots, \theta_k)^T$ je vektor neznámých parametrů a $\boldsymbol{\epsilon}$ je vektor chyb měření se $E(\boldsymbol{\epsilon}) = 0$ a $\text{Var}(\boldsymbol{\epsilon}) = \sigma^2 \cdot \mathbf{I}$. Jestliže označíme

$$\mathbf{F} = \frac{\partial \phi(\mathbf{x}, \boldsymbol{\theta})}{\partial \boldsymbol{\theta}^T} \Big|_{\boldsymbol{\theta}=\boldsymbol{\theta}^0} \text{ jako } (n \times k) \text{ matici plánu, } \mathbf{B} = \frac{\partial \eta_j(\boldsymbol{\theta})}{\partial \boldsymbol{\theta}^T} \Big|_{\boldsymbol{\theta}=\boldsymbol{\theta}^0} \text{ jako } (q \times k) \text{ matici podmínek,}$$

potom můžeme psát model v lineární formě jako

$$\begin{aligned} \mathbf{Y} \sim \phi(\mathbf{x}, \boldsymbol{\theta}^0) + \frac{\partial \phi(\mathbf{x}, \boldsymbol{\theta})}{\partial \boldsymbol{\theta}^T} \cdot \delta \boldsymbol{\theta} \Big|_{\boldsymbol{\theta}=\boldsymbol{\theta}^0} + \boldsymbol{\epsilon} &\Rightarrow \mathbf{Y} - \phi(\mathbf{x}, \boldsymbol{\theta}^0) = \mathbf{F} \cdot \delta \boldsymbol{\theta} + \boldsymbol{\epsilon}, \\ \eta_j(\boldsymbol{\theta}) \sim \eta_j(\boldsymbol{\theta}^0) + \frac{\partial \eta_j(\boldsymbol{\theta})}{\partial \boldsymbol{\theta}^T} \cdot \delta \boldsymbol{\theta} \Big|_{\boldsymbol{\theta}=\boldsymbol{\theta}^0} = 0 &\Rightarrow \eta_j(\boldsymbol{\theta}) - \eta_j(\boldsymbol{\theta}^0) = \{\mathbf{B}\}_j \cdot \delta \boldsymbol{\theta} = 0, \quad j = 1, \dots, q, \end{aligned}$$

kde $\delta \boldsymbol{\theta} = \boldsymbol{\theta} - \boldsymbol{\theta}^0$. Jestliže ξ je návrh (pravděpodobnostní míra na množině experimentálních bodů \mathbf{x}), potom informační matice pro parametr $\boldsymbol{\theta}$ je tvaru

$$\mathbf{M}(\boldsymbol{\theta}) = N \cdot \sigma^{-2} \cdot \underbrace{\sum_{x_i \in \text{Sp}(\xi)} \left(\frac{\partial \phi(x_i, \boldsymbol{\theta})}{\partial \boldsymbol{\theta}} \right) \cdot \left(\frac{\partial \phi(x_i, \boldsymbol{\theta})}{\partial \boldsymbol{\theta}} \right)^T}_{\mathbf{M}(\boldsymbol{\theta}, \xi)} \cdot \xi(x_i),$$

kde $\mathbf{M}(\boldsymbol{\theta}, \xi)$ je normovaná informační matice, $\text{Sp}(\xi) = \{x_i : \xi(x_i) > 0, x_i \in \mathbf{x}\}$ je nosič návrhu ξ a N je celkový počet měření. Jestliže $\mathbf{M} = \mathbf{M}(\boldsymbol{\theta})$ je regulární matici, potom platí, že varianční matice NLNO $\hat{\boldsymbol{\theta}}$ je tvaru

$$\text{Var}(\hat{\boldsymbol{\theta}}) = \mathbf{M}^{-1} - \mathbf{M}^{-1} \mathbf{B}^T \left[\mathbf{B} \mathbf{M}^{-1} \mathbf{B}^T \right]^{-1} \mathbf{B} \mathbf{M}^{-1} \Rightarrow \mathbf{V}_{\boldsymbol{\theta}}(\xi) = N \cdot \sigma^{-2} \cdot \text{Var}(\hat{\boldsymbol{\theta}}),$$

kde $\mathbf{V}_{\boldsymbol{\theta}}(\xi)$ je normovaná varianční matice $\hat{\boldsymbol{\theta}}$ (viz. [2]).

Uvažujeme-li konvexní kriteriální funkci Φ , pak je lokálně optimální návrh ξ^* takový návrh, který splňuje podmínu: $\Phi[\mathbf{V}_{\boldsymbol{\theta}}(\xi^*)] = \min_{\xi \in \Xi} \Phi[\mathbf{V}_{\boldsymbol{\theta}}(\xi)]$, kde Ξ je konvexní množina všech návrhů.

KRITÉRIUM LOKÁLNÍ A-OPTIMALITY

Kriteriální funkce lokální A-optimality pro model s podmínkami typu I je dána vztahem

$$\Phi[\mathbf{V}_{\boldsymbol{\theta}}(\xi)] = \text{Tr}[\mathbf{V}_{\boldsymbol{\theta}}(\xi)] = \text{Tr}[N \cdot \sigma^{-2} [\mathbf{M}^{-1} - \mathbf{M}^{-1} \mathbf{B}^T (\mathbf{B} \mathbf{M}^{-1} \mathbf{B}^T)^{-1} \mathbf{B} \mathbf{M}^{-1}]].$$

Pro výpočetní algoritmus je třeba určit gradient $\nabla \Phi(\mathbf{V})$ kriteriální funkce, tj.

$$\nabla \Phi(\mathbf{V}) = N \cdot \sigma^{-2} [-\mathbf{M}^{-2} + \mathbf{M}^{-1} \mathbf{B}^T (\mathbf{B} \mathbf{M}^{-1} \mathbf{B}^T)^{-1} \mathbf{B} \mathbf{M}^{-2} - \mathbf{M}^{-1} \mathbf{B}^T (\mathbf{B} \mathbf{M}^{-1} \mathbf{B}^T)^{-1} \mathbf{B} \mathbf{M}^{-2} \mathbf{B}^T (\mathbf{B} \mathbf{M}^{-1} \mathbf{B}^T)^{-1} \mathbf{B} \mathbf{M}^{-1} + \mathbf{M}^{-2} \mathbf{B}^T (\mathbf{B} \mathbf{M}^{-1} \mathbf{B}^T)^{-1} \mathbf{B} \mathbf{M}^{-1}].$$

KRITÉRIUM LOKÁLNÍ C-OPTIMALITY

K definování této kriteriální funkce je nutná existence známé funkce parametrů $h(\boldsymbol{\theta})$, která je diferencovatelná. Při splnění těchto předpokladů pak pro regulární regresní model platí

$$\text{Var}(h(\hat{\boldsymbol{\theta}})) = \partial h^T \text{Var}(\hat{\boldsymbol{\theta}}) \partial h \Rightarrow \mathbf{V}_{\boldsymbol{\theta}}^h(\xi) = N \cdot \sigma^{-2} \cdot \text{Var}(h(\hat{\boldsymbol{\theta}})).$$

Následně je kritérium lokální C-optimality definováno vztahem

$$\Phi[\mathbf{V}_{\boldsymbol{\theta}}^h(\xi)] = \partial h^T(\boldsymbol{\theta}) \mathbf{V}_{\boldsymbol{\theta}}^h(\xi) \partial h(\boldsymbol{\theta}) = N \cdot \sigma^{-2} [\partial h^T(\boldsymbol{\theta}) [\mathbf{M}^{-1} - \mathbf{M}^{-1} \mathbf{B}^T (\mathbf{B} \mathbf{M}^{-1} \mathbf{B}^T)^{-1} \mathbf{B} \mathbf{M}^{-1}] \partial h(\boldsymbol{\theta})].$$

Gradient $\nabla \Phi(\mathbf{V})$ kriteriální funkce je tvaru

$$\nabla \Phi(\mathbf{V}) = N \cdot \sigma^{-2} [-\mathbf{M}^{-1} \partial h \partial h^T \mathbf{M}^{-1} + \mathbf{M}^{-1} \mathbf{B}^T (\mathbf{B} \mathbf{M}^{-1} \mathbf{B}^T)^{-1} \mathbf{B} \mathbf{M}^{-1} \partial h \partial h^T \mathbf{M}^{-1} - \mathbf{M}^{-1} \mathbf{B}^T (\mathbf{B} \mathbf{M}^{-1} \mathbf{B}^T)^{-1} \mathbf{B} \mathbf{M}^{-1} \partial h \partial h^T \mathbf{M}^{-1} \mathbf{B}^T (\mathbf{B} \mathbf{M}^{-1} \mathbf{B}^T)^{-1} \mathbf{B} \mathbf{M}^{-1} + \mathbf{M}^{-1} \partial h \partial h^T \mathbf{M}^{-1} \mathbf{B}^T (\mathbf{B} \mathbf{M}^{-1} \mathbf{B}^T)^{-1} \mathbf{B} \mathbf{M}^{-1}].$$

KRITÉRIUM LOKÁLNÍ D-OPTIMALITY

V regresním modelu s podmínkami nelze apriori definovat kritérium lokální D-optimality vztahem známým z regresních modelů bez podmínek, tedy jako

$$\Phi[\mathbf{V}_{\boldsymbol{\theta}}(\xi)] = \ln \det[\mathbf{V}_{\boldsymbol{\theta}}(\xi)]$$

neboť normovaná varianční matice $\mathbf{V}_{\boldsymbol{\theta}}(\xi)$ je často singulární, přestože je parametr $\boldsymbol{\theta}$ odhadnutelný. Z tohoto důvodu je třeba k problematice lokálně D-optimálního návrhu zvolit odlišný přístup než v případě předchozích kriteriálních funkcí.

Matici podmínek \mathbf{B} je rozdělena do bloků $\mathbf{B} = (\mathbf{B}_1, \mathbf{B}_2)$ tak, aby platilo $r(\mathbf{B}_1) = q$. Pak je možné zapsat podmínky typu I jako

$$\mathbf{B}_1 \delta \boldsymbol{\theta}_1 + \mathbf{B}_2 \delta \boldsymbol{\theta}_2 = \mathbf{0} \rightarrow \delta \boldsymbol{\theta}_1 = -\mathbf{B}_1^{-1} \mathbf{B}_2 \delta \boldsymbol{\theta}_2,$$

čímž je původní model s podmínkami typu I převeden na model bez podmínek:

$$\mathbf{Y} \sim \underbrace{\mathbf{F} \left(\begin{array}{c} -\mathbf{B}_1^{-1} \mathbf{B}_2 \\ \mathbf{I} \end{array} \right)}_{\mathbf{F}^*} \delta \boldsymbol{\theta}_2 + \boldsymbol{\epsilon},$$

kde \mathbf{F}^* je nová matici plánu. Normovaná informační matice nového modelu je tvaru

$$\mathbf{M}^*(\boldsymbol{\theta}_2, \xi) = \sum_{x_i \in \text{Sp}(\xi)} \{\mathbf{F}^*\}_i \{\mathbf{F}^*\}_i^T \xi(x_i),$$

kde $\{\mathbf{F}^*\}_i^T$ je i -tý řádek nové matice plánu \mathbf{F}^* . Tímto postupem je zaručena regulárnost matice $\mathbf{M}^*(\boldsymbol{\theta}_2, \xi)$ (důkaz viz. [1]), takže je možné definovat kriteriální funkci lokální D-optimality stejným způsobem jako je tomu v regresních modelech bez podmíny, tedy

$$\Phi[\mathbf{M}^*(\boldsymbol{\theta}_2, \xi)] = -\ln[\det(\mathbf{M}^*(\boldsymbol{\theta}_2, \xi))].$$

Gradient $\nabla \Phi(\mathbf{M}^*)$ kriteriální funkce je vyjádřen jako

$$\nabla \Phi(\mathbf{M}^*) = -[\mathbf{M}^*(\boldsymbol{\theta}_2, \xi)]^{-1}.$$

K uvedené problematice je možné zvolit alternativní přístup užitím QR rozkladu matice \mathbf{B}^T . Popis tohoto přístupu je uveden ve [2].

Příklad

Pro jednoduchost uvažujeme lineární regresní model s podmínkou typu I

$$\begin{aligned} Y_i &= \theta_1 + \theta_2 \cdot x_i + \epsilon_i, & \text{pro } i = 1, \dots, 10 \\ Y_i &= \theta_3 + \theta_4 \cdot x_i + \theta_5 \cdot x_i^2 + \epsilon_i, & \text{pro } i = 11, \dots, 20 \\ \theta_1 + \theta_2 \cdot x_{10} &- (\theta_3 + \theta_4 \cdot x_{10} + \theta_5 \cdot x_{10}^2) = 0. \end{aligned}$$

Dále uvažujeme celkový počet měření $N = 20$, množinu experimentálních bodů $\mathbf{x} = (1, \dots, 20)$, matici plánu \mathbf{F} a matici podmínek \mathbf{B} tvaru:

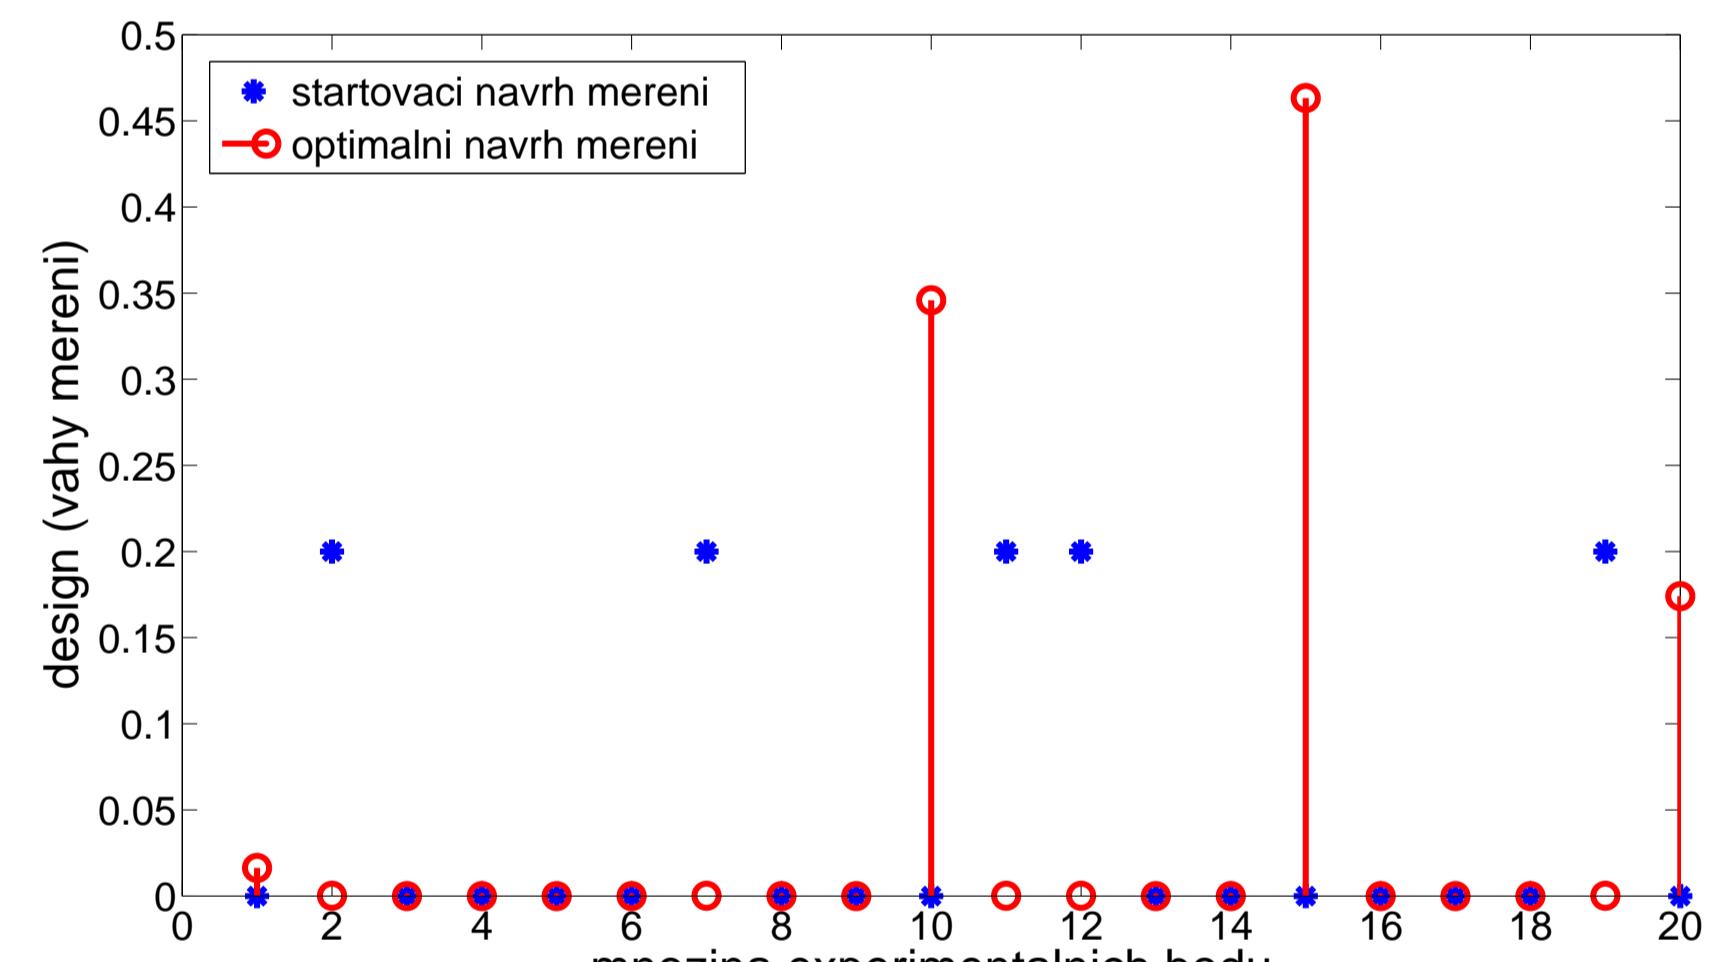
$$\mathbf{F} = \begin{pmatrix} 1 & 1 & 0 & 0 & 0 \\ \vdots & & & & \\ 1 & 10 & 0 & 0 & 0 \\ 0 & 0 & 1 & 11 & 11^2 \\ \vdots & & & & \\ 0 & 0 & 20 & 20^2 & \end{pmatrix}, \quad \mathbf{B} = [1 \ 10 \ -1 \ -10 \ -100].$$

Aby byl parametr $\boldsymbol{\theta}$ odhadnutelný z jakéhokoli návrhu ξ_j , kde $j = 1, 2, \dots$ v průběhu iteračního procesu, je nutné zajistit odhadnutelnost parametru $\boldsymbol{\theta}$ ze startovacího návrhu ξ_0 . To nastane tehdy, bude-li dodržena regulárnost matice $\mathbf{M}(\boldsymbol{\theta}, \xi_0) + \mathbf{B}^T \mathbf{B}$. Tuto podmínu například splňuje startovací návrh rovnoměrně rozdělený do bodů $\text{Sp}(\xi_0) = \{2, 7, 11, 12, 19\}$.

Nejdříve stanovíme lokálně A-optimální návrh měření. Určíme gradient kriteriální funkce, který dosadíme do výpočetního algoritmu založeného na metodě největšího spádu.

Z obrázku 1 je patrné, že nosič lokálně A-optimálního návrhu obsahuje 4 body, kdy relativní počet měření v každém tomto bodě je:

$$\begin{aligned} \xi(x_1) \cdot N &= 0.0164 \cdot 20 \doteq 1, \\ \xi(x_{10}) \cdot N &= 0.3459 \cdot 20 \doteq 7, \\ \xi(x_{15}) \cdot N &= 0.4633 \cdot 20 \doteq 9, \\ \xi(x_{20}) \cdot N &= 0.1743 \cdot 20 \doteq 4. \end{aligned}$$



Obr. 1.: Lokálně A-optimální návrh měření.

Nyní najdeme lokálně C-optimální návrh měření. Matice \mathbf{F} a matice \mathbf{B} mají stejnou strukturu jako v předchozím případě, avšak vyskytuje se zde navíc diferencovatelná funkce parametrů $h(\boldsymbol{\theta})$ ve formě: $0 \cdot \theta_1 + 0 \cdot \theta_2 + 1 \cdot \theta_3 - 2 \cdot \theta_4 - 0.5 \cdot \theta_5$. Potom $\partial h^T = [0, 0, 1, -2, -0.5]$.

Z obrázku 2 je patrné, že nosič lokálně C-optimálního návrhu obsahuje 3 body, kdy relativní počet měření v každém tomto bodě je:

$$\begin{aligned} \xi(x_{10}) \cdot N &= 0.3518 \cdot 20 \doteq 7, \\ \xi(x_{15}) \cdot N &= 0.4710 \cdot 20 \doteq 9, \\ \xi(x_{20}) \cdot N &= 0.1772 \cdot 20 \doteq 4. \end{aligned}$$

