

BAYESOVSKÝ ODHAD PARAMETRŮ MODELU METODAMI MCMC S APLIKACÍ NA MODELOVÁNÍ REGRESNÍCH KŘIVEK

Petr VOLF
ÚTIA AV ČR

Abstract: In the paper, the Markov chain Monte Carlo (MCMC) procedures are reviewed, namely the Gibbs and Metropolis–Hastings algorithms. It is shown how the procedures apply to Bayesian estimation of parameters of a probabilistic model. The MH algorithm is then used for adaptive construction of regression function from a chosen functional basis, e.g. from the B-splines.

Резюме: В этой статье описываются методы Markov chain Monte Carlo (MCMC). Специально, изучается алгоритм Метрополиса-Астингса. Этот алгоритм используется для адаптивного построения регрессионной функции используя Б-сплайны.

Cílem statistické analýzy dat je poskytovat modely pozorovaných systémů. Mnohdy jsme v situaci, kdy je úloha specifikovat model převedena na úlohu odhadu (někdy velmi mnoha) parametrů. Bayesovský přístup nabízí jednu možnost, jak problém odhadu parametrů řešit. Jenže, v mnoha případech, zvláště těch složitějších, je konstrukce Bayesova aposteriorního rozdělení nezvládnutelným úkolem a nebývá to snadné ani s pomocí numerických metod. Pro tyto případy jsou nyní k dispozici postupy, které využívají počítačové simulace a namísto výpočtu aposteriorního rozdělení generují jeho reprezentaci. Přesněji, metody MCMC (Markov Chain Monte Carlo) generují Markovovu náhodnou posloupnost, jejíž rozdělení se blíží hledanému aposteriornímu.

V této práci nejprve zopakujeme Bayesovo pravidlo a jeho využití pro odhad parametrů modelu. Pak popíšeme některé metody umožňující generovat výběry, které se řídí (alespoň v limitě, jako je tomu pro MCMC metody) aposteriorním rozdělením. Jednu z metod, konkrétně algoritmus Metropolise–Hastingse, pak využijeme k modelování regresních křivek, a to k jejich konstruování z polynomiálních splinů (případně z jiné baze “elementárních” funkcí).

1 Bayesovský odhad parametrů

Představme si, že data \mathbf{y} , která měříme, jsou realizace náhodných veličin $\mathbf{Y} = Y_1, \dots, Y_n$, model “vzniku” dat nechť je popsán pomocí pravděpodobnosti

(řekněme hustoty) $f(\mathbf{y}; \boldsymbol{\theta})$, kde $\boldsymbol{\theta} \in \Theta \subset R^p$ je neznámý parametr. V Bayesovském ‘světě’ se neurčitost hodnoty $\boldsymbol{\theta}$ popisuje také pomocí pravděpodobnosti, na začátku se zvolí apriorní rozdělení – označme je (jeho hustotu) $p_0(\boldsymbol{\theta})$. Bayesovo pravidlo pak udává aposteriorní rozdělení jako podmíněné rozdělení hodnot parametru při napozorovaných datech, tj.

$$p(\boldsymbol{\theta}|\mathbf{y}) = C(\mathbf{y}) \cdot f(\mathbf{y}; \boldsymbol{\theta}) \cdot p_0(\boldsymbol{\theta}). \quad (1)$$

Zde $C(\mathbf{y})$ je normující člen, nezávisící na $\boldsymbol{\theta}$.

Tímto způsobem dostaneme tedy rozdělení pravděpodobnosti hodnot parametru, které je ovlivněno pozorovanými daty \mathbf{y} . Pokud chceme bodový odhad parametru $\boldsymbol{\theta}$, bere se nejčastěji modus aposteriorního rozdělení, $\hat{\boldsymbol{\theta}}(\mathbf{y}) = \arg \max_{\boldsymbol{\theta}} p(\boldsymbol{\theta}|\mathbf{y})$ (– všimněme si, že při rovnoramenném apriorním $p_0(\boldsymbol{\theta})$ je tento odhad totožný s maximálně věrohodným), nebo $\tilde{\boldsymbol{\theta}}(\mathbf{y}) = E(\boldsymbol{\theta}|\mathbf{y})$, tj. střední hodnota z aposteriorního rozdělení.

Problém samozřejmě bývá s výpočtem členu $C(\mathbf{y})$, ten ale k zjištění $\hat{\boldsymbol{\theta}}(\mathbf{y})$ vlastně nepotřebujeme. Jenže často (v případech mnohorozměrného $\boldsymbol{\theta}$) není snadné získat ani maximum, ani další charakteristiky aposteriorního rozdělení (mohly by nás zajímat především rozptyl a kvantily, ke zjištění “síře” aposteriorního rozdělení a tím i ‘kredibility’ (důvěryhodnosti? – Bayesovské varianty konfidence) odhadu parametru). A tady nastupují metody, které jsou schopny aposteriorní rozdělení nasimulovat.

Poznámka: V dalším budeme s daty zacházet jako s “konstantou” – tj. jsme v situaci, kdy data jsou k dispozici a naším cílem je odhadnutí aposteriorního rozdělení parametru.

Mimochodem, při růstu rozsahu dat $n \rightarrow \infty$ se uplatní teorie konzistence, což v Bayesovském případě znamená, že aposteriorní rozdělení se soustřeďuje do jednoho bodu, do ‘skutečné’ hodnoty parametru $\boldsymbol{\theta}$. Tímto jevem se zde zabývat nebudeme.

2 MCMC procedury

Je vyvinuto několik metod jak vygenerovat výběr z určitého rozdělení a vyuhnout se přitom výpočtu přesného tvaru tohoto rozdělení či alespoň jak generovat Markovovu posloupnost, jejíž rozdělení se blíží k onomu cílovému. Do první skupiny patří např.

Zamítací metoda [1], [2], [5]: Chceme získat (jednoho) reprezentanta rozdělení $p(\boldsymbol{\theta}|\mathbf{y})$. Mějme k dispozici jinou hustotu rozdělení pravděpodobnosti $q(\boldsymbol{\theta})$ na Θ , nedegenerovanou, takovou, že $p(\boldsymbol{\theta}|\mathbf{y})/q(\boldsymbol{\theta}) \leq U$ pro každé $\boldsymbol{\theta} \in \Theta$ (a pro naše data \mathbf{y}).

Vygenerujme nyní $\boldsymbol{\theta}^*$ z rozdělení $q(\boldsymbol{\theta})$ a "přijměme" jej s pravděpodobností $p^* = p(\boldsymbol{\theta}^*|\mathbf{y})/(q(\boldsymbol{\theta}^*) \cdot U) \leq 1$, tj. udělejme "nula–jedničkový" náhodný pokus, který má za výsledek "1" s pravděpodobností p^* , "0" s $1 - p^*$. Je snadné ukázat (viz zmíněná literatura), že takto získaná (a přijatá) veličina $\boldsymbol{\theta}^*$ má právě rozdělení $p(\boldsymbol{\theta}|\mathbf{y})$. Použití této metody je omezeno tím, že musíme znát konstantu U , která by neměla být příliš velká, abychom na získání dostatečného počtu reprezentantů nepotřebovali příliš mnoho "kandidátů", kteří by se při velkém U většinou zamítali.

Hned se nabízí následující zjednodušení. Generujme kandidáty $\boldsymbol{\theta}^*$ z apriorního rozdělení $q_0(\boldsymbol{\theta})$. Máme-li rozumnou konstantu V takovou, že $f(\mathbf{y}; \boldsymbol{\theta}) \leq V$ pro každé $\boldsymbol{\theta}$, pak z (1) plyne, že $p(\boldsymbol{\theta}|\mathbf{y})/q_0(\boldsymbol{\theta}) = C(\mathbf{y})f(\mathbf{y}; \boldsymbol{\theta}) \leq C(\mathbf{y})V$, což odpovídá konstantě U shora. Přijímací pravděpodobnost je pak

$$p^* = \frac{p(\boldsymbol{\theta}|\mathbf{y})}{C(\mathbf{y})V q_0(\boldsymbol{\theta})} = \frac{f(\mathbf{y}; \boldsymbol{\theta})}{V}.$$

Gibbsův algoritmus [2], [4], [7] je MCMC metoda, která je vhodná pro případ mnohorozměrného parametru. Označme $p_j(\theta_j|\boldsymbol{\theta}_{(-j)}, \mathbf{y})$ hustoty podmíněných aposteriorních rozdělení, kde

$$\boldsymbol{\theta}_{(-j)} = (\theta_1, \dots, \theta_{j-1}, \theta_{j+1}, \dots, \theta_p).$$

Algoritmus začne z nějaké (zvolené) počáteční hodnoty $\boldsymbol{\theta}^{(0)}$ a postupně v každém kroku inovuje 1 složku $\boldsymbol{\theta}$, a to tak, že ji generuje právě z podmíněného rozdělení p_j . Takže například novou j -tou složku v $m + 1$. cyklu dostaneme tak, že $\theta_j^{(m+1)}$ vygenerujeme pomocí hustoty

$p_j(\theta_j|\theta_1^{(m+1)}, \dots, \theta_{j-1}^{(m+1)}, \theta_{j+1}^{(m)}, \dots, \theta_p^{(m)})$. Zjevně dostáváme náhodnou posloupnost $\boldsymbol{\theta}^{(m)}$, která je Markovova. Není problém ukázat, [2], [7], že hustota invariantního rozdělení takového Markovovy posloupnosti je právě $p(\boldsymbol{\theta}|\mathbf{y})$, a že rozdělení $\boldsymbol{\theta}^{(m)}$ při $m \rightarrow \infty$ konverguje k aposteriornímu rozdělení.

To je důsledek vět o konvergenci rozdělení nerozložitelných aperiodických Markovových řetězců k svému invariantnímu rozdělení (viz třeba kniha Feller, Probability Theory), zobecnění (neb zde již nejde o řetězce v pravém slova smyslu) je např. v [7]. Dalším důsledkem je také ergodická vlastnost, mimo jiné, že skoro jistě, pro $K \rightarrow \infty$,

$$\frac{1}{K} \sum_{m=1}^K \boldsymbol{\theta}^{(m)} \longrightarrow \int_{\Theta} \boldsymbol{\theta} p(\boldsymbol{\theta}|\mathbf{y}) d\boldsymbol{\theta} = \mathbb{E}(\boldsymbol{\theta}|\mathbf{y}).$$

Samozřejmě, zdaleka ne vždy známe tvar podmíněných pravděpodobností p_j . Pak je možné Gibbsův algoritmus při generování každé nové složky kombinovat se zamítací metodou. A nebo použít proceduru Metropolise–Hastings.

Algoritmus Metropolise–Hastingse [2], [6], [7] také vytváří Markovovu náhodnou posloupnost $\boldsymbol{\theta}^{(m)}$, a to následujícím způsobem. Nechť $\boldsymbol{\theta}^{(m)}$ je zatím poslední člen posloupnosti, nechť $q(\boldsymbol{\theta}|\boldsymbol{\theta}^{(m)})$ je nějaká (zatím zcela libovolná) hustota rozdělení pravděpodobnosti (tj. může být podmíněna aktuální hodnotou parametru, ale nemusí). Vygenerujme s její pomocí “kandidáta” $\boldsymbol{\theta}^*$ na další člen posloupnosti. Položme pak

$$\pi(\boldsymbol{\theta}^*, \boldsymbol{\theta}^{(m)}) = \frac{p(\boldsymbol{\theta}^*|\mathbf{y}) \cdot q(\boldsymbol{\theta}^{(m)}|\boldsymbol{\theta}^*)}{p(\boldsymbol{\theta}^{(m)}|\mathbf{y}) \cdot q(\boldsymbol{\theta}^*|\boldsymbol{\theta}^{(m)})} \quad (2)$$

a přijměme $\boldsymbol{\theta}^{(m+1)} = \boldsymbol{\theta}^*$ s pravděpodobností $\alpha(\boldsymbol{\theta}^*, \boldsymbol{\theta}^{(m)}) = \min\{1, \pi(\boldsymbol{\theta}^*, \boldsymbol{\theta}^{(m)})\}$. Pokud $\boldsymbol{\theta}^*$ nepřijmeme, pokládáme $\boldsymbol{\theta}^{(m+1)} = \boldsymbol{\theta}^{(m)}$.

Takto tedy vzniká Markovova posloupnost, jejíž (hustoty) přechodové pravděpodobnosti z $\boldsymbol{\theta}$ do $\boldsymbol{\theta}'$ jsou

$$h(\boldsymbol{\theta}'|\boldsymbol{\theta}) = \begin{cases} q(\boldsymbol{\theta}'|\boldsymbol{\theta}) \cdot \alpha(\boldsymbol{\theta}', \boldsymbol{\theta}) & \text{pro } \boldsymbol{\theta}' \neq \boldsymbol{\theta}, \\ 1 - \int_{\Theta} q(\boldsymbol{\theta}''|\boldsymbol{\theta}) \alpha(\boldsymbol{\theta}''|\boldsymbol{\theta}) d\boldsymbol{\theta}'' & \text{pro } \boldsymbol{\theta}' = \boldsymbol{\theta}. \end{cases} \quad (3)$$

Funkce $q(\boldsymbol{\theta}'|\boldsymbol{\theta}) \cdot \alpha(\boldsymbol{\theta}', \boldsymbol{\theta})$ tedy tvoří “ jádro ” pro tyto pravděpodobnosti přechodů, a vlastnosti výsledné Markovovy posloupnosti do značné míry závisí na vlastnostech hustoty q . I tu můžeme chápout jako hustotu rozdělení pravděpodobnosti přechodů pro nějakou (jinou) Markovovu posloupnost na Θ (a to samozřejmě i v případě, kdy $q(\boldsymbol{\theta}'|\boldsymbol{\theta}) = q(\boldsymbol{\theta}')$ – tj. q by generovala i.i.d. posloupnost).

Je dokázáno [6], že pokud q generuje nerozložitelnou a aperiodickou Markovovu posloupnost, tak pak i posloupnost $\boldsymbol{\theta}^{(m)}$ vzniklá algoritmem Metropolise–Hastingse je nerozložitelná a aperiodická. Z toho pak plynou ony příjemné vlastnosti: 1. Existence jediného invariantního rozdělení, 2. Konvergence rozdělení $\boldsymbol{\theta}^{(m)}$ k němu, 3. Ergodicita.

A je snadné ukázat ([2], [6]), že aposteriorní rozdělení $p(\boldsymbol{\theta}|\mathbf{y})$ je právě invariantním rozdělením posloupnosti $\boldsymbol{\theta}^{(m)}$. Nejprve se ukáže z (2) a (3), že pro libovolná $\boldsymbol{\theta} \neq \boldsymbol{\theta}'$ $h(\boldsymbol{\theta}'|\boldsymbol{\theta}) \cdot p(\boldsymbol{\theta}|\mathbf{y}) = h(\boldsymbol{\theta}|\boldsymbol{\theta}') \cdot p(\boldsymbol{\theta}'|\mathbf{y})$ (pro $\boldsymbol{\theta} = \boldsymbol{\theta}'$ to platí), z toho pak vyvodíme $\int_{\Theta} p(\boldsymbol{\theta}|\mathbf{y}) \cdot h(\boldsymbol{\theta}'|\boldsymbol{\theta}) d\boldsymbol{\theta} = p(\boldsymbol{\theta}'|\mathbf{y})$.

Z těchto limitních vlastností tedy plyne, že pokud vygenerujeme dostatečně dlouhou posloupnost (a uřízneme její dostatečně dlouhý začátek), tak výsledný vzorek hodnot můžeme (s rezervou, že nejde o i.i.d. výběr) považovat za reprezentaci aposteriorního rozdělení. Rozhodně tak můžeme zacházet s výběrovými kvantily a s průměrem $\frac{1}{K} \sum \boldsymbol{\theta}^{(m)}$ (součet přes m , od nějakého $K_0 + 1$ do $K_0 + K$) jako aproximací pro $E(\boldsymbol{\theta}|\mathbf{y})$ (použijeme jej tedy jako bodový odhad parametru $\boldsymbol{\theta}$).

Nyní si všimněme, jak se rozhodovací pravidlo zjednoduší, když budeme kandidáty na nové členy posloupnosti generovat přímo z apriorního rozdělení

$q_0(\boldsymbol{\theta})$. Ve (2) pak dostaneme (po dosazení za $p(\boldsymbol{\theta}|\mathbf{y})$ z Bayesova vzorce (1))

$$\pi(\boldsymbol{\theta}^*, \boldsymbol{\theta}) = \frac{f(\mathbf{y}; \boldsymbol{\theta}^*) \cdot q_0(\boldsymbol{\theta}^*)}{f(\mathbf{y}; \boldsymbol{\theta}) \cdot q_0(\boldsymbol{\theta})} \cdot \frac{q_0(\boldsymbol{\theta})}{q_0(\boldsymbol{\theta}^*)} = \frac{f(\mathbf{y}; \boldsymbol{\theta}^*)}{f(\mathbf{y}; \boldsymbol{\theta})}, \quad (4)$$

neboli věrohodnostní poměr.

Připomeňme si ještě další metodu patřící do této skupiny, zvanou **simulované žíhání**. Je to metoda vhodná na znáhodněné hledání maxima funkce. Je používána v úlohách rekonstrukce obrazů (viz i Janžura, Robust 90).

3 Úloha odhadu regresní funkce

Nyní budeme aplikovat algoritmus Metropolise–Hastingse na úlohu odhadu regresní funkce. Mějme *neparametrický* regresní model

$$Y = r(x) + e, \quad (5)$$

kde $r(x)$ je neznámá (předpokládáme, že ‘hladká’) funkce, e je náhodná veličina s $\mathcal{N}(0, \sigma^2)$ rozdělením, σ^2 neznámé. Data jsou pak nezávislé realizace dvojice $(X, Y) : (\mathbf{x}, \mathbf{y}) = (x_1, y_1, \dots, x_m, y_m)$. O jedné možnosti odhadu regresní funkce, o jádrových odhadech, existuje i v “Robustech” několik článků, např. Antoch (1986), Michálek (1994). Zde se budeme snažit odhad funkce $r(x)$ zkonztruovat jako lineární kombinaci z nějaké báze funkcí, tj. ve tvaru

$$r^*(x) = \boldsymbol{\alpha}' \mathbf{B}(x; \boldsymbol{\beta}) = \sum_{j=1}^M \alpha_j B_j(x; \boldsymbol{\beta}). \quad (6)$$

Funkce B_j jsou tedy vybrané “jednotky” ze zvolené báze funkcí, $\boldsymbol{\beta}$ jsou jejich vnitřní parametry. Zpravidla každá B_j závisí jen na jedné či několika málo komponentách z $\boldsymbol{\beta}$. Máme tedy před sebou úlohu optimální volby $\boldsymbol{\beta}$ (a také M – počtu použitých jednotek), zatímco $\boldsymbol{\alpha}$ se již dají (při ostatním známém) spočítat, zde přímo metodou nejmenších čtverců.

Jsme tedy v situaci, kterou jsme popsali na začátku, tj. máme co dělat s mnohorozměrným parametrem, který je velice obtížné odhadnout optimálně přímými metodami. Jsou k dispozici i adaptivní nebayesovské postupy, např. MARS [3] používá polynomické spliny z “+” baze a tvoří spojitý model ‘stromovité’, podobným způsobem, jako jsou vytvářeny (nespojité) klasifikační a regresní stromy (CART – viz Antoch, Robust’88). My budeme raději používat lépe lokalizovaných jednotek (než jsou “+” spliny), konkrétně kubické B -spliny, případně tzv. radiální bázové funkce. Parametr β_j tedy znamená “umístění” j -té funkce, tj. uzel regresního splinu, či střed RB funkce. Mimochodem, problém “učení” neuronových sítí je vlastně tentýž (optimalizace nastavení parametrů funkcionálních “jednotek” – a také počtu jednotek), množí se již pokusy řešit tuto úlohu v rámci Bayesova přístupu.

3.1 Aplikace algoritmu Metropolise–Hastingse

Uvažujme tedy regresní model (5) s Gaussovým šumem $e \sim \mathcal{N}(0, \sigma^2)$, zatím s jednorozměrnou kovariátou X v ohraničeném intervalu $[a, b] \subset R^1$. Hledejme odhad regresní funkce ve tvaru (6). Vérohodnostní funkce (či hustota sdružené pravděpodobnosti pro \mathbf{y} při daných $\boldsymbol{\alpha}, \boldsymbol{\beta}, M, \mathbf{x}$), platí-li model (5) s funkcí (6), je

$$f(\mathbf{y}; \boldsymbol{\alpha}, \boldsymbol{\beta}, M, \mathbf{x}) = \prod_{i=1}^n \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(y_i - r^*(x_i))^2}{2\sigma^2}\right).$$

Máme tedy co dělat s parametry $\boldsymbol{\alpha}, \boldsymbol{\beta}, M$, kde M může nabýt kladných celých hodnot, prostor hodnot $\boldsymbol{\beta}$ je $a < \beta_1 < \beta_2 < \dots < \beta_M < b$ (tj. závisí na M ; v případě B -splinů jde o vnitřní uzly v $[a, b]$). Parametry $\boldsymbol{\alpha}$ by také mohly být získávány nějakým znáhodněným způsobem, ale protože jde o parametry “lineární”, můžeme pro každé M a $\boldsymbol{\beta}$ (a daná data) ihned metodou nejmenších čtverců spočít odhady

$\hat{\boldsymbol{\alpha}} = \arg \min_{\boldsymbol{\alpha}} \sum_{i=1}^n \left(y_i - \sum_{j=1}^M \alpha_j B_j(x_i; \boldsymbol{\beta}) \right)^2$. V rámci Metropolisova–Hastingsova algoritmu budeme tedy generovat (po jednotlivých složkách) Markovovu posloupnost hodnot parametrů $\boldsymbol{\theta} = (M, \boldsymbol{\beta})$. Zvolíme apriorní rozdělení pro M , $Q_0(M)$, podmíněná apriorní rozdělení $q_{0j}(\beta_j | M, \boldsymbol{\beta}_{(-j)})$ – tj. se závislostí na M , dále přechodové rozdělení pro generování nových kandidátů M^* , např. jako symetrickou náhodnou procházku, s pravděpodobnostmi $Q(M^* | M) = 1/3$ pro $M^* = M - 1, M$, nebo $M + 1$, jinak $Q(M^* | M) = 0$. Pro generování nových kandidátů $\boldsymbol{\beta}_j^*$ při daném $\boldsymbol{\beta}_{(-j)}$ a M použijeme přímo q_{0j} . K vytvoření přijímacího pravidla ještě potřebujeme vérohodnostní funkci při daných $\mathbf{x}, \boldsymbol{\beta}, M$. Vezmeme prostě $f^*(\mathbf{y}; \hat{\boldsymbol{\alpha}}, \boldsymbol{\beta}, M, \mathbf{x})$, tj. vždy pro $\boldsymbol{\beta}, M$ dosadíme za $\boldsymbol{\alpha}$ příslušný odhad $\hat{\boldsymbol{\alpha}}$.

Jak nyní vypadá jeden dílčí krok MH algoritmu? Představme si, že poslední stav posloupnosti je $M, \boldsymbol{\beta} = (\beta_1, \dots, \beta_M)$ a chceme zkusit inovovat j -tou složku $\boldsymbol{\beta}$. Nejprve vygenerujeme M^* z $Q(M^* | M)$. Je-li

$M^* = M - 1$, prostě zkusíme β_j vynechat. Nové $\boldsymbol{\beta}^*$ je tedy

$\boldsymbol{\beta}_{(-j)} = (\beta_1, \dots, \beta_{j-1}, \beta_{j+1}, \dots, \beta_M)$. Je-li $M^* = M$, generujeme β_j^* z $q_{0j}(\beta_j | M, \boldsymbol{\beta}_{(-j)})$, dostaneme tedy $\boldsymbol{\beta}^* = (\beta_1, \dots, \beta_{j-1}, \beta_j^*, \beta_{j+1}, \dots, \beta_M)$. Konečně, je-li $M^* = M + 1$, pak generujeme dvě hodnoty z $q_{0j}(\beta_j | M, \boldsymbol{\beta}_{(-j)})$, menší z nich označíme β_j^* , větší β_j^{**} , a máme tak M^* rozměrný vektor $\boldsymbol{\beta}^* = (\beta_1, \dots, \beta_{j-1}, \beta_j^*, \beta_j^{**}, \beta_{j+1}, \dots, \beta_M)$. Dále k M^* a $\boldsymbol{\beta}^*$ spočteme příslušné $\hat{\boldsymbol{\alpha}}^*$. Nyní nastupuje znáhodněné přijímací pravidlo. Podle (2) dostaneme

$$\pi(M^*, \boldsymbol{\beta}^*, M, \boldsymbol{\beta}) = \frac{p(\boldsymbol{\beta}^*, M^* | \mathbf{y}, \mathbf{x}) \cdot q(\boldsymbol{\beta}, M | \boldsymbol{\beta}^*, M^*)}{p(\boldsymbol{\beta}, M | \mathbf{y}, \mathbf{x}) \cdot q(\boldsymbol{\beta}^*, M^* | \boldsymbol{\beta}, M)},$$

kde ale rozdělení pravděpodobnosti, podle kterého jsme získali nové kandidáty $\boldsymbol{\beta}^*, M^*$, je

$q(\beta', M' | \beta, M) = q_0(\beta' | M') \cdot Q(M' | M)$. Když nyní rozepíšeme i $p(\beta, M | y, x)$ podle Bayesova vzorce (1) jako $C(x, y) \cdot f(y; \hat{\alpha}, \beta, M, x) \cdot q_0(\beta | M) \cdot Q_0(M)$, dostaneme nakonec

$$\pi(M^*, \beta^*, M, \beta) = \frac{f(y; \hat{\alpha}^*, \beta^*, M^*, x) \cdot Q_0(M^*)}{f(y; \hat{\alpha}, \beta, M, x) \cdot Q_0(M)}. \quad (7)$$

Nyní tedy uděláme náhodný nula–jedničkový pokus a (β^*, M^*) s pravděpodobností $\min(1, \pi)$ přijmeme jako další člen Markovovy posloupnosti $\{\beta^{(m)}, M^{(m)}, m = 0, 1, 2, \dots\}$, v opačném případě je nový člen roven starému (β, M) , tj. nedošlo k přechodu.

Vidíme, že rozhodovací pravidlo je znovu založeno na věrohodnostním poměru a také na poměru apriorních pravděpodobností pro “velikost” modelu M . To nám dává možnost vhodnou volbou $Q_0(M)$ usměrňovat volbu počtu použitých jednotek. Představme si například, že $Q_0(M)$ je klesající v M , pak pro $M^* = M + 1$ je tento poměr < 1 a vlastně tak “penalizujeme” prostý věrohodnostní poměr, abychom zabránili přílišnému růstu M během iterací. Připomíná to penalizující kriteria pro výběr řádu autoregresního modelu (používají se kriteria AIC, BIC, varianty krosvalidace a j.).

Zkoušeli jsme například volit $Q_0(M) \approx \exp(-M^2/n^\gamma)$, kde n byl rozsah dat a číslo $\gamma \in (0.5, 1)$. Dalším, spíše praktickým, opatřením bylo, že jsme rovnou zamítali takové nové uzly, které byly k některému starému blíže než na zvolenou vzdálenost. Podmíněná apriorní rozdělení $q_{0j}(\beta_j | \beta_{-j}, M)$ jsme volili rovnoměrná, vždy pro β_j mezi v tu chvíli pevnými sousedními β_{j-1}, β_{j+1} . To pak odpovídá rovnoměrnému sdruženému rozdělení $q_0(\beta | M)$ na $a < \beta_1 < \dots < \beta_M < b$.

V případě Gaussova rozdělení odchylek e_i potřebujeme ve věrohodnostním poměru ještě odhad parametru σ . Ten jsme odhadovali z reziduí poslední předchozí iterace modelu.

Poznámka: Samozřejmě, pokud si předem stanovíme pevné M , které nechceme měnit, situace (a kriterium (7)) se zjednoduší.

4 Mnohorozměrná regrese

Jakmile je kovariáta mnohorozměrná, tj. $\mathbf{X} \in R^p$, narazí naše metoda na problém, jak v R^p náhodně volit jednotky. Za funkcionální jednotku v R^p zpravidla bereme součin jednorozměrných, např. $D(x, z) = B(x) \cdot C(z)$. Regresní funkci v R^2 bychom pak modelovali jako

$$(\alpha_{00}) + \sum_{j=1}^{M_1} \alpha_{j0} B_j(x, \beta) + \sum_{k=1}^{M_2} \alpha_{0k} C_k(z, \gamma) + \sum \sum \alpha_{jk} B_j(x, \beta) \cdot C_k(z, \gamma).$$

Takže ”vnitřních” parametrů β_j, γ_k by bylo $M_1 + M_2$, zatímco parametrů α_{jk} by bylo $M_1 \cdot M_2 + M_1 + M_2 + (1)$. Změna jedné komponenty (uzlu) β_j by vytvářela změnu nejméně $M_2 + 1$ jednotek modelu. Snaha zmenšit dimenzi prostoru, ve kterém se v každém kroku rozhoduje, vedla k ”stromovým” procedurám, viz CART, MARS [3]. Takovéto metody zkoušíme i v rámci MCMC přístupu, zatím nemáme uspokojivé řešení.

Additivní model. Jiná je situace, když se spokojíme s aditivním modelem vlivu kovariát, tj. hledáme regresní funkci ve tvaru $r(\mathbf{x}) = \sum_{j=1}^p r_j(x_j)$. Každou funkci r_j pak jednotlivě modelujeme z jednodimensionálních funkcionálních jednotek. MCMC procedura probírá a iteruje opakováně jednu funkci r_j za druhou.

Poznámka: Když už máme proceduru, která mění počet jednotek, podobným způsobem by mohla měnit i počet kovariát použitých v modelu, tj. měnit p . Vlastně by to znamenalo připustit i hodnoty $M_j = 0$.

5 Věrohodnostní modely


Věrohodnostním modelem myslíme takový, kde je neznámý parametr (v případě regrese tedy regresní funkce) parametrem ve věrohodnostní funkci, a je tedy zpravidla odhadován metodou maxima věrohodnosti. Samozřejmě, Gaussův model je speciálním případem. Další příklady jsou exponenciální modely (GAM – Hastie a Tibshirani), logistický regresní model, i Coxův model, kde je odhadování založeno na částečné věrohodnostní funkci (viz i Wolf, Robust 92).

Naše pravidlo pro přijímání nových členů posloupnosti je založeno přímo na poměru věrohodností, můžeme je tedy použít pro jakýkoli věrohodnostní model. Změní se však způsob inovace parametrů $\boldsymbol{\alpha}$. Ten je teď třeba získat jako MVO, tj. maximalizací $\mathcal{L} = \ln f(\mathbf{y}; \boldsymbol{\alpha}, \boldsymbol{\beta}, M, \mathbf{x})$, pro daná data \mathbf{y}, \mathbf{x} a dané hodnoty $M, \boldsymbol{\beta}$. Znamená to řešit rovnice $\partial \mathcal{L} / \partial \alpha_m = 0, m = 1, \dots, M$.

Takové rovnice se většinou řeší iterací (algoritmem Newtona Raphsona třeba). V případě ortogonálních jednotek B_m s omezeným nosičem vystačíme v každém kroku s inovací jen několika α_j . Například, kdybychom použili approximaci regresní funkce pomocí histogramu, změna jednoho uzlu histogramu má za následek změnu jen 2 sousedních ’políček’ histogramu, a tedy jen 2 parametrů. Podrobněji viz i Linka a spol. [9].

Příklad: Zkoušeli jsme náš postup jak pro Coxův model, tak pro logistický klasifikační model, a samozřejmě pro model standardní, s Gaussovým šumem. Pro ilustraci uvedeme jen jednoduchý umělý příklad.

Vygenerovali jsme $x_i, i = 1, \dots, n$ pro $n = 500$, rovnoměrně v $(0, 5)$, k nim pak $y_i = x_i \sin(x_i^2) + e_i$, kde e_i byly i.i.d. z $\mathcal{N}(0, \sigma = 1)$. Jako bazi funkcí jsme použili kubické B-spliny. Začali jsme s třemi rovnoměrně umístěnými vnitřními uzly v $(0, 5)$. Apriorní rozdělení β bylo rovnoměrné při daném M , apriorní rozdělení M jsme zvolili tak, aby přidání jedné jednotky bylo v (7) penalizováno členem $\exp(-2M/n^{0.7})$, tj. apriorní rozdělení bylo úměrné $\exp(-M^2/n^{0.7})$. Generovali jsme Markovou posloupnost $M^{(s)}, \beta^{(s)}$ délky 200, z které jsme použili posledních 80 členů. Pro každý z nich jsme tedy obdrželi odhad regresní funkce $r_s^*(x)$ (ve tvaru (6)). Z těch jsme udělali průměr a to byl konečný odhad regresní funkce. Výsledek je na následujícím obrázku, kde body představují data a křivka je výsledný odhad.



6 Dodatek o polynomiálních splinech

Polynomiální spliny jsou jedním z nejpoužívanějších prostředků na approximaci a modelování hladkých funkcí. Popíšeme zde kubické spliny, konstruované na intervalu $x \in [a, b] \subset R$.

Interval $[a, b]$ je rozdělen pomocí *uzlů* na podintervaly, na kterých je funkce modelována jako polynom třetího stupně, v uzlech pak přechází jeden polynom v druhý spojitě, i se spojitou 1. a 2. derivací. Nejznámější jsou dva způsoby konstrukce takovéto funkce (viz např. [8]).

První způsob používá funkcí, které jsou definovány jako $(u)_+ = u$ pro $u \geq 0$, $= 0$ jinak. Mějme v (a, b) zvoleno M vnitřních uzlů $a < \beta_1 < \dots <$

$\beta_M < b$. Pak kompletní spline je dán jako

$$r^*(x) = a_0 + a_1 x + a_2 x^2 + a_3 x^3 + \sum_{j=1}^M \alpha_j (x - \beta_j)_+^3.$$

Tato funkce má požadované vlastnosti (spojitost derivací v uzlech) a vidíme, že obsahuje $M + 4$ 'lineární' parametry. Použité '+' jednotky nejsou lokalizovány, tj. nemají omezený nosič.

Druhou možností je použít t.zv. B-spliny. Kromě M vnitřních uzlů definujme ještě formálně $\beta_{-j} = a - j(\beta_1 - a)$, $\beta_{M+1+j} = b + j(b - \beta_M)$ pro $j = 0, 1, 2, 3$. Máme nyní dohromady $M + 8$ uzlů. Nyní pro $j = -1, 0, 1, \dots, M, M + 1, M + 2$ definujme 'jednotky' – B-spliny:

$$B_j(x, \boldsymbol{\beta}) = 1[x \leq \beta_{j+2}] \sum_{k=j-2}^{j+2} \{(x - \beta_k)_+^3 / \prod_{s=j-2, s \neq k}^{j+2} (\beta_k - \beta_s)\}.$$

Výsledná funkce je pak $r^*(x) = \sum_{j=-1}^{M+2} \alpha_j B_j(x, \boldsymbol{\beta})$. Skládá se tedy z $M + 4$ jednotek a obsahuje opět $M + 4$ 'lineárních' parametrů α_j . Co je podstatné, funkce B_j jsou lokalizované, každá B_j je nenulová jen mezi uzly β_{j-2}, β_{j+2} . Změna jednoho uzlu β_k vede ke změně B_j pro $j = k - 2, \dots, k + 2$. Proto jsme si dovolili další approximaci v inovaci modelu používajícím B-spliny, a to že k změněnému jednomu β_k jsme nepočítali celý nový vektor $\boldsymbol{\alpha}$, ale jen 5 komponent $\alpha_{k-2}, \dots, \alpha_{k+2}$. Tato úspora je cenná zvlášť při modelování ve věrohodnostních modelech, kde α jsou počítána Newtonovou–Raphsonovou iterací.

References

- [1] Antoch, J., Vorlíčková D. (1992). *Vybrané metody statistické analýzy dat*. Academia, Praha.
- [2] Bernardo, J. M., Smith, A. F. M. (1994). *Bayesian Theory*. Wiley, New York.
- [3] Friedman, J. H. (1991). "Multivariate adaptive regression splines". *Annals Statist.* 19, 1–141.
- [4] Geman, S., Geman, D. (1984). "Stochastic relaxation, Gibbs distributions and the Bayesian restoration of images". *IEEE Trans. Pattern Anal. Mach. Intell.* 6, 724–741.
- [5] Smith, A. F. M., Gelfand, A. E. (1990). "Sampling based approaches to calculating marginal densities". *J. Amer. Statist. Assoc.* 85, 398–409.

- [6] Hastings, W. K. (1970). "Monte Carlo sampling methods using Markov chains and their applications". *Biometrika* 57, 97–109.
- [7] Roberts, G. O., Smith, A. F. M. (1994). "Simple conditions for the convergence of the Gibbs sampler and Metropolis–Hastings algorithms". *Stoch. Processes and Applic.* 49, 207–216.
- [8] Wold, S. (1974). "Spline functions in data analysis". *Technometrics* 16, 1–11.
- [9] Linka, A., Picek, J., Volf, P. (1996). "Monte Carlo method for likelihood regression analysis". In: *Compstat '96*, Barcelona. Physica–Verlag, 343–348.

Petr Volf, ÚTIA AV ČR, Pod vodárenskou věží 4, 182 08 Praha 8,
e-mail: volf@utia.cas.cz