

RŮZNÉ PŘÍSTUPY K JÁDROVÉMU ODHADU REGRESNÍ FUNKCE

MARIE BUDÍKOVÁ, IVANA HOROVÁ

Cílem příspěvku je poukázat na souvislosti mezi aparátem teorie aproximací funkcí a neparametrickým odhadem regresní funkce.

I. VLASTNOSTI LINEÁRNÍCH POZITIVNÍCH OPERÁTORŮ

V roce 1968 definoval D. D. Stancu následující třídu lineárních pozitivních operátorů ([5]):

$$(1) \quad P_n^\alpha(f; x) = \sum_{k=0}^n w_{n,k}^\alpha(x) f\left(\frac{k}{n}\right); \quad x \in [0, 1], f \in C[0, 1],$$

kde α je reálný parametr, který může záviset pouze na přirozeném čísle n ,

$$(2) \quad w_{n,k}^\alpha(x) = \frac{\binom{n}{k} x^{(k,-\alpha)} (1-x)^{(n-k,-\alpha)}}{1^{(n,-\alpha)}}$$

a

$$x^{(k,-\alpha)} = \begin{cases} 1, & k = 0 \\ x(x+\alpha)\dots(x+(k-1)\alpha), & k \geq 1. \end{cases}$$

Pro vhodné hodnoty parametru α definují operátory $P_n^\alpha(f; x)$ známé typy lineárních pozitivních operátorů, jako např. Bernštejnovy polynomy, Szász-Mirakjanovy operátory, Baskakovovy operátory a pro $\alpha = -1/n$ dostaváme Lagrangeův interpolační polynom v uzlech $x_i = \frac{i}{n}$, $i = 0, 1, \dots, n$.

Funkce $w_{n,k}^\alpha(x)$, $k = 0, 1, 2, \dots, n$, budeme nazývat vahovými funkcemi. Je zřejmé, že platí:

a) $w_{n,k}^\alpha(x) \geq 0 \quad \forall x \in [0, 1], \quad k = 0, 1, 2, \dots, n$

b) $\sum_{k=0}^n w_{n,k}^\alpha(x) = 1 \quad \forall x \in [0, 1]$

Připomeňme větu o konvergenci posloupnosti operátorů $P_n^\alpha(f; x)$.

Věta 1. Nechť $f \in C[0, 1]$ a nechť $\alpha = \alpha(n)$, $\alpha(n) \rightarrow 0$ pro $n \rightarrow \infty$. Pak posloupnost $\{P_n^\alpha(f; x)\}$, $n = 0, 1, 2, \dots$, konverguje stejnoměrně k funkci $f(x)$ na intervalu $[0, 1]$.

Důkaz lze najít v [5].

Poznámka. Položme-li v (1) $\alpha = 0$, dostáváme známé *Bernštejnovy polynomy*, tj.

$$P_n^0(f; x) = \sum_{k=0}^n \binom{n}{k} x^k (1-x)^{n-k} f\left(\frac{k}{n}\right)$$

a věta 1 je v tomto případě známou Weierstrassovou větou o stejnoměrné aproxi-
maci spojité funkce polynomem.

Nyní uvedeme některé vlastnosti funkcií $w_{n,k}^\alpha(x)$ ([3]):

1. $x \in (0, 1), x < \alpha, \alpha > 1/2 \Rightarrow$

$$w_{n,k-1}^\alpha(x) \geq w_{n,k}^\alpha(x), \text{ je-li } 1 \leq k \leq \left[\frac{(n+1)(\alpha-x)}{2\alpha-1} \right]$$

$$w_{n,k-1}^\alpha(x) \leq w_{n,k}^\alpha(x), \text{ je-li } \left[\frac{(n+1)(\alpha-x)}{2\alpha-1} \right] < k \leq n,$$

kde $[a]$ značí celou část čísla a .

Jelikož se dále budeme převážně zabývat hodnotami vahových funkcí v bodě $x = 1/2$, uvedeme vlastnosti posloupnosti těchto funkcí v bodě $x = 1/2$.

2. $x = 1/2, \alpha > 1/2 \Rightarrow$

$$w_{n,k-1}^\alpha\left(\frac{1}{2}\right) \geq w_{n,k}^\alpha\left(\frac{1}{2}\right), \quad \text{je-li } 1 \leq k \leq \left[\frac{n+1}{2} \right]$$

$$w_{n,k-1}^\alpha\left(\frac{1}{2}\right) \leq w_{n,k}^\alpha\left(\frac{1}{2}\right), \quad \text{je-li } \left[\frac{n+1}{2} \right] < k \leq n$$

3. $x = 1/2, \alpha = 1/2 \Rightarrow$

$$w_{n,k-1}^{1/2}\left(\frac{1}{2}\right) = w_{n,k}^{1/2}\left(\frac{1}{2}\right), \quad \text{je-li } k = 1, 2, \dots, n.$$

4. $x = 1/2, 0 < \alpha < 1/2 \Rightarrow$

$$w_{n,k-1}^\alpha\left(\frac{1}{2}\right) \leq w_{n,k}^\alpha\left(\frac{1}{2}\right), \quad \text{je-li } 1 \leq k \leq \left[\frac{n+1}{2} \right]$$


$$w_{n,k-1}^\alpha\left(\frac{1}{2}\right) \geq w_{n,k}^\alpha\left(\frac{1}{2}\right), \quad \text{je-li } \left[\frac{n+1}{2} \right] < k \leq n$$

5. $x \in (0, 1), \alpha = 0, \Rightarrow$

$$w_{n,k-1}^0(x) \leq w_{n,k}^0(x), \quad \text{je-li } 1 \leq k \leq [(n+1)x]$$

$$w_{n,k-1}^0 \geq w_{n,k}^0(x), \quad \text{je-li } [(n+1)x] < k \leq n.$$

Z výše uvedeného plyne, že vlastnosti funkcií $w_{n,k}^\alpha$ jsou pro $\alpha > 1/2$ zcela odlišné
od vlastností těchto funkcií v případě, že $\alpha \leq 1/2$. Tuto skutečnost také ilustruje
obr. 1.



Obr. 1. Průběhy vahových funkcí pro $n = 8$ a různé hodnoty α .

II. JÁDRO S MINIMÁLNÍM ROZPTYLEM

Nechť

$$\mathcal{M}_{\nu,k} = \left\{ f \in \text{Lip}([-1, 1]), \int_{-1}^1 f(x)x^j dx = \begin{cases} 0, & 0 \leq j < k, j \neq \nu \\ (-1)^\nu \nu!, & j = \nu \end{cases} \right\}$$

Ríkáme, že funkce $K_\nu(x)$ je jádrem řádu k , jestliže $K_\nu \in \mathcal{M}_{\nu,k}$ a $\beta_k = \int_{-1}^1 K_\nu(x)x^k dx \neq 0$.

Předpokládáme dále, že $0 \leq \nu \leq k - 2$ a čísla ν, k jsou obě buď lichá nebo sudá.

Jádra s minimálním rozptylem jsou řešením variační úlohy

$$\int_{-1}^1 K_\nu^2(x) dx \rightarrow \min, \quad K_\nu \in \mathcal{M}_{\nu,k}$$

Řešení této úlohy je založeno na vlastnostech Legendreových polynomů a je následující:

Věta 2. Jádra K_ν řádu k s minimálním rozptylem na intervalu $[-1, 1]$ jsou polynomy stupně $(k - 2)$ s $(k - 2)$ různými reálnými kořeny v $(-1, 1)$.

Poznámka. Jádro $K_0(x)$ řádu 2 s minimálním rozptylem je obdélníkové jádro $K_0(x) \equiv \frac{1}{2}, \forall x \in [-1, 1]$.

III. VYHLAZOVÁNÍ

Uvažujme regresní model

$$y_i = m(x_i) + \varepsilon_i, \quad i = 1, 2, \dots, N,$$

kde y_1, y_2, \dots, y_N jsou realizace závisle proměnné Y , x_1, x_2, \dots, x_N jsou realizace vysvětlující proměnné X , m je teoretická regresní funkce a veličiny $\varepsilon_1, \varepsilon_2, \dots, \varepsilon_N$ reprezentují náhodnou složku.

Budeme se zabývat výhradně modelem s pevným plánem. V tomto případě X představuje deterministickou proměnnou, která je volena ekvidistantně. Předpokládejme dále, že $x_i = i$, $i = 1, 2, \dots, N$ a náhodné veličiny $\varepsilon_1, \varepsilon_2, \dots, \varepsilon_N$ jsou stochasticky nezávislé, $E(\varepsilon_i) = 0$, $D(\varepsilon_i) = \sigma^2$, $i = 1, 2, \dots, N$.

Neznámou regresní funkci m budeme odhadovat neparametricky metodou vážených klouzavých průměrů.

Nechť $(2l+1)$ je počet vah (tj. šířka vyhlazovacího okna). Váhy w_0, w_1, \dots, w_{2l} jsou reálná čísla taková, že

$$(3) \quad \sum_{k=0}^{2l} w_k = 1, \quad w_k = w_{2l-k}, \quad k = 0, 1, \dots, l.$$

Odhad regresní funkce m v bodě $x_i = i$ označme \hat{y}_i . Prvních a posledních l hodnot neodhadujeme. Lze snadno ukázat, že pro odhad regresní funkce ve středu vyhlazovacího okna (o šířce $2l+1$) platí

$$(4) \quad \hat{y}_{l+i} = \sum_{k=0}^{2l} w_k y_{i+k}, \quad i = 0, 1, 2, \dots, N - 2l.$$

Podívejme se nyní na předchozí úvahy z jiného hlediska, a to z hlediska vyhlazování pomocí jader.

Nejdříve sestrojíme pomocí vah w_0, w_1, \dots, w_{2l} jádro K_0 řádu 2.

Definujme funkci K_0 takto:

a) K_0 je spojitá a po částech lineární v intervalu $[-1, 1]$.

b) $K_0(x) \equiv 0$ vně intervalu $[-1, 1]$.

c) v bodech $x_k = -1 + \frac{k}{l}$, $k = 0, 1, 2, \dots, 2l$ nabývá hodnot $\frac{l w_k}{1 - w_0}$, $k = 0, 1, \dots, 2l$ (za předpokladu $w_0 \neq 1$), tj.

$$(5) \quad K_0\left(-1 + \frac{k}{l}\right) = \frac{l w_k}{1 - w_0}, \quad k = 0, 1, \dots, 2l.$$

Snadno ověříme, že takto definovaná funkce $K_0 \in M_{0,2}$. Je totiž

$$\begin{aligned} \int_{-1}^1 K_0(x) dx &= \frac{l}{1 - w_0} \sum_{k=1}^{2l} \int_{x_{k-1}}^{x_k} ((w_k - w_{k-1})l(x - x_k) + w_k) dx \\ &= \frac{l}{1 - w_0} \frac{1}{2l} \sum_{k=1}^{2l} (w_k + w_{k-1}). \end{aligned}$$

Užijeme-li nyní (3), dostaneme

$$(6) \quad \int_{-1}^1 K_0(x) dx = 1,$$

což znamená, že pro $j = \nu = 0$ je

$$\int_{-1}^1 K_0(x) x^j dx = 1.$$

Nechť nyní $j = 1$, tj. $0 \leq j < k$, $k = 2$. Pak zřejmě

$$(7) \quad \int_{-1}^1 K_0(x) x dx = 0,$$

neboť $K_0(x)$ je sudá funkce a dále

$$(8) \quad \beta_2 = \int_{-1}^1 K_0(x) x^2 dx \neq 0.$$

Je rovněž jasné, že takto sestrojená funkce $K_0 \in \text{Lip}([-1, 1])$. Tedy $K_0 \in \mathcal{M}_{0,2}$ a je jádrem řádu 2.

Použijme nyní tohoto postupu k získání jádra pomocí operátorů $P_n^\alpha(f; x)$.
Položme

$$w_k = w_{n,k}^\alpha\left(\frac{1}{2}\right), \quad n = 2l, \quad k = 0, 1, \dots, 2l.$$

V tomto případě jsou všechny váhy w_k kladné a splňují předepsané podmínky (3).

Položíme-li $\alpha = 0$, tj. pro případ Bernštejnových polynomů, nabývá funkce K_0 v bodech $x_k = -1 + k/l$, $k = 0, 1, \dots, 2l$, hodnot $\frac{l}{2^{2l}-1} \binom{2l}{k}$, $k = 0, 1, \dots, 2l$.

Je-li $\alpha = 1$, je

$$K_0(x_k) = \frac{(2k-1)!! (2(2l-k)-1)!!}{(2l)! 2^{2l} - (4l-1)!!} l \binom{2l}{k}.$$

Z vlastnosti (3) pro váhové funkce $w_{n,k}^\alpha(x)$ plyne, že pro $\alpha = 1/2$, $x = 1/2$ je posloupnost $w_{n,k}^{1/2}$ konstantní. Snadno se ukáže, že


$$w_{n,k}^{1/2}\left(\frac{1}{2}\right) = \frac{1}{n+1}, \quad k = 0, 1, \dots, n.$$

Užijeme-li nyní těchto vah ke konstrukci jádra, tj.


$$w_k = \frac{1}{2l+1}, \quad k = 0, 1, \dots, 2l,$$

dostaneme obdélníkové jádro $K_0(x) \equiv 1/2$, $\forall x \in [-1, 1]$. To znamená, že výše uvedená konstrukce zahrnuje jádro s minimálním rozptylem na intervalu $[-1, 1]$.

Následující obrázky ukazují tvary jader pro různé hodnoty l a α .



Obr. 2. Tvar jádra $K_0(x)$ pro $x = \frac{1}{2}$, $\alpha = 0$, $l = 2, 4, 8$.



Obr. 3. Text viz obr. 2, $\alpha = 1$

Připomeňme, že jádrový odhad regresní funkce v bodě $x_i = i$ je dán vzorcem

$$(9) \quad \hat{y}_i = \frac{\frac{1}{N} \sum_{k=1}^N K(i-k)y_k}{\frac{1}{N} \sum_{k=1}^N K(i-k)}, \quad i = 1, 2, \dots, N,$$

kde $K(x)$ je jádro s nosičem $[-1, 1]$ a $\int_{-1}^1 K(x) dx = 1$.

Ve jmenovateli je odhad hustoty pravděpodobnosti nezávisle proměnné veličiny X . Vzhledem k tomu, že uvažujeme model s pevným plánem s ekvidistantními vzdálenostmi, je tato hustota konstantní. Její odhad označme c . Protože prvních a posledních l hodnot regresní funkce neodhadujeme, vzorec (9) nabývá tvaru

$$(10) \quad \hat{y}_{l+i} = \frac{1}{c} \sum_{i=1}^N K(l+i-k)y_k, \quad i = 1, 2, \dots, N-2l$$

Porovnáním (4) a (10) dostaneme

$$\frac{1}{c} K(l+i-k) = w_k, \quad k = 1, 2, \dots, N-2l$$

a současně podle (5) $K_0\left(-1 + \frac{k}{l}\right) = \frac{l}{1-w_0} w_k, \quad k = 0, 1, \dots, 2l$, tudíž $c = \frac{l}{1-w_0}$,

$$K_0\left(-1 + \frac{k}{l}\right) = K(l+i-k), \quad k = 0, 1, \dots, 2l, \quad i = 1, 2, \dots, N-2l.$$

Položíme-li $k = j - i$, můžeme vzorec (10) přepsat do tvaru

$$\hat{y}_{l+i} = \frac{1-w_0}{l} \sum_{j=1}^N K_0\left(\frac{-l+j-i}{l}\right) y_j, \quad i = 1, 2, \dots, N-2l.$$

V tabulce je uvedena závislost velikosti $\int_{-1}^1 K_0^2(x) dx$ na šířce vyhlazovacího okna $2l+1$ pro různé hodnoty parametru α .

$2l+1$	$\alpha = 0$	$\alpha = \frac{1}{2}$	$\alpha = 1$
3	0,5185	0,5	0,5067
5	0,5743	0,5	0,5255
7	0,6647	0,5	0,5406
9	0,7623	0,5	0,5530
11	0,8560	0,5	0,5634


IV. APLIKACE

Vliv jádra $K_0(x)$ pro $\alpha = 0, \frac{1}{2}, 1$ na odhad regresní funkce jsme zkoumaly v simulačním experimentu s regresní funkcí uvažovaného modelu tvaru


$$m(x) = \sin(0,2x - \frac{\pi}{6}) + \sin(0,12x + \frac{\pi}{8}) + \sin(0,16x + \frac{\pi}{3}) + \sin(0,08x + \frac{\pi}{4}),$$

kde proměnná x nabývala hodnot $1, 2, \dots, 100$. Náhodné chyby mely standardizované normální rozložení. Šířka vyhlazovacího okna byla zvolena $2l+1 = 9$.


Výsledky simulačního experimentu ukazují obrázky:



Obr. 4. Vyhlažování simulovaných dat pomocí jádra
 $K_0(x)$, $x = \frac{1}{2}$ s parametry $\alpha = 0$, $l = 4$.




Obr. 5. Text viz obr. 4, $\alpha = 1$.




Obr. 6. Text viz obr. 4, $\alpha = \frac{1}{2}$.


Jádro $K_0(x)$ s parametry $\alpha = 0, \frac{1}{2}, 1$ jsme rovněž použily k vyhlazení průměrných jarních teplot v Hurbanově v letech 1903–1992.



Obr. 7. Chod průměrných jarních teplot v Hurbanově v letech 1903–1992, vyhlazení jádrem $K_0(x)$, $x = \frac{1}{2}$ s parametry $\alpha = 0, l = 4$.



Obr. 8. Text viz obr. 7, $\alpha = 1$.



Obr. 9. Text viz obr. 7, $\alpha = \frac{1}{2}$.

LITERATURA

- [1] Cipra, T., *Analýza časových řad s aplikacemi v ekonomii*, SNTL/Alfa, Praha 1986.
- [2] Härdle, W., *Applied Nonparametric Regression*, Econometric Society Monographs, Cambridge University Press, 1990.
- [3] Horová, I., Budíková, M., *A Note on D. D. Stancu Operators*, zasláno do tisku.
- [4] Müller, H. G., *Nonparametric Regresion Analysis of Longitudinal Data*, Lecture notes in statistics 46, Springer-Verlag, Berlin 1988.
- [5] Stancu, D. D., *Approximation of functions by a new class of linear positive operators*, Rev. Roumaine Math. Pures Appl. 13 (1968), 1173-1194.

ADRESY AUTORŮ

MARIE BUDÍKOVÁ & IVANA HOROVÁ
KATEDRA APLIKOVANÉ MATEMATIKY PŘF MU
JANÁČKOVО NÁM. 2A
662 95 BRNO