

Aplikace matematiky

Václav Fabian

Poznámka k Halperinove metodě prokládání přímky, jsou-li obě proměnné pozorovány s chybou

Aplikace matematiky, Vol. 8 (1963), No. 3, 197–(198a),199–200

Persistent URL: <http://dml.cz/dmlcz/102852>

Terms of use:

© Institute of Mathematics AS CR, 1963

Institute of Mathematics of the Czech Academy of Sciences provides access to digitized documents strictly for personal use. Each copy of any part of this document must contain these *Terms of use*.



This document has been digitized, optimized for electronic delivery and stamped with digital signature within the project *DML-CZ: The Czech Digital Mathematics Library* <http://dml.cz>

POZNÁMKA K HALPERINOVĚ METODĚ PROKLÁDÁNÍ PŘÍMKY,
JSOU-LI OBĚ PROMĚNNÉ POZOROVÁNY S CHYBOU

VÁCLAV FABIAN

(Došlo dne 16. března 1962.)

Z Halperinových výsledků je odvozen simultánní intervalový odhad hodnot lineární funkce, jejíž parametry jsou odhadovány v experimentu, v němž pozorování funkčních hodnot i argumentů jsou zatížena náhodnými chybami.

1. Úvod a shrnutí. Tento článek obsahuje menší doplněk k práci [1]. Matematicky jde o velmi jednoduchý výsledek, který autor uveřejňuje jen pro jeho praktickou užitečnost a proto, že přes svou jednoduchost by patrně tvrzení i jeho důkaz nebyly samy o sobě zřejmé každému experimentátoru používajícímu Halperinovy metody.

V článku [1] je studován problém odhadu neznámých parametrů α, β lineární funkce $r(u) = \alpha + \beta u$ na základě posloupnosti dvojic $[x_1, y_1], \dots, [x_n, y_n]$, kde každé y_i je odhadem funkční hodnoty $r(u_i) = \alpha + \beta u_i$ v jistém bodě u_i . Číslo u_i je odhadováno hodnotou x_i .

Poznamenáme, že teorie regrese se obvykle zabývá případem, v němž je $u_i = x_i$, tj. v němž známe hodnoty nezávisle proměnné přesně. Obecnější problém (tzv. strukturální relace), do něhož spadá práce [1] a v němž se připouští chyba i v odhadu hodnot nezávisle proměnné, je v praxi častější, ale bohužel i obtížnější k řešení.

Halperinova metoda je založena ještě na další posloupnosti z_1, z_2, \dots, z_n odhadů hodnot u_1, u_2, \dots, u_n , nezávislých na $[x_1, y_1], \dots, [x_n, y_n]$.

Předpoklady lze nyní shrnout takto: x_i, y_i, z_i jsou náhodné proměnné, jejichž očekávané hodnoty splňují vztah $Ey_i = r(Ex_i)$. Označíme-li $\eta_i = y_i - Ey_i$, $\xi_i = x_i - Ex_i$, jsou $[\xi_1, \eta_1], \dots, [\xi_n, \eta_n]$ vzájemně nezávislé identicky distribuované náhodné vektory s dvojrozměrným normálním rozložením pravděpodobností a jsou nezávislé na z_1, z_2, \dots, z_n .

Poznamenáme, že ve formálním vyjádření předpokladů se nevyskytuje požadavek, aby z_i byly dobrými odhady hodnot Ex_i . Čím je však lépe tento požadavek splněn, tím užitečnější je odhad, který metoda poskytne; jsou-li z_i špatnými odhady čísel Ex_i (Ex_i jsou přesné hodnoty nezávisle proměnné), může být odhad, který metoda dává, neužitečný (podrobněji viz [1]).

Symbolem $F_\alpha(f_1, f_2)$ označme nyní $(1 - \alpha)$ -kvantil F -rozložení s f_1 a f_2 stupni volnosti (tabelované např. v [2], tabulka 12) a položíme $R = 2F_\gamma(2, n - 2)/(n - 2)$. Píšme formálně¹⁾

$$\bar{a} = \frac{1}{n} \sum_{i=1}^n a_i,$$

$$S_{a,b} = \sum_{i=1}^n (a_i - \bar{a})(b_i - \bar{b}) = \frac{n \sum_{i=1}^n a_i b_i - (\sum_{i=1}^n a_i)(\sum_{i=1}^n b_i)}{n},$$

$$\Phi_{a,b} = S_{az} S_{bz} + R(S_{az} S_{bz} - S_{ab});$$

dosazující za písmena a, b v předešlých dvou vztazích písmena x, y, z , dostaneme vztahy určující $\Phi_{xx}, \Phi_{xy}, \Phi_{yy}, \bar{x}, \bar{y}, \bar{z}$.

Halperin ukázal, že s pravděpodobností $1 - \gamma$ je

$$(1.1) \quad n(\bar{y} - \alpha - \beta\bar{x})^2 + \Phi_{xx}(\beta^* - \beta)^2 \leq \beta^{*2} \Phi_{xx} - \Phi_{yy},$$

kde

$$(1.2) \quad \beta^* = \Phi_{xy} / \Phi_{xx}.$$

Tento výsledek umožňuje simultánní odhad neznámých parametrů α a β . Jak ukážeme, umožňuje též simultánní intervalový odhad všech hodnot $r(u)$ funkce r .

Označme symbolem $r^*(u)$ bodový odhad $\bar{y} + \beta^*(u - \bar{x})$ funkční hodnoty $r(u) = \alpha + \beta u$ a položíme

$$(1.3) \quad d(u) = \begin{cases} \left[\frac{\Phi_{xy}^2 - \Phi_{xx}\Phi_{yy}}{n\Phi_{xx}^2} (\Phi_{xx} + n(u - \bar{x})^2) \right]^{1/2}, & \text{je-li } \Phi_{xx} > 0, \\ +\infty & \text{jinak.} \end{cases}$$

Pak vztah

$$(1.4) \quad |r(u) - r^*(u)| \leq d(u) \text{ pro všechna } u,$$

plyne z (1.1) a je tedy splněn s pravděpodobností aspoň $1 - \gamma$.

Intervalovým odhadem je tedy pás mezi oběma funkcemi $r^*(u) - d(u)$ a $r^*(u) + d(u)$.

2. Poznámka. Výsledek metody je neužitečný, je-li $\Phi_{xx} \leq 0$. Pravděpodobnost tohoto nežádoucího jevu je, zhruba řečeno, tím menší, čím jsou z_i lepšími odhady čísel Ex_i (ve skutečnosti záleží jen na chování posloupností $l_i = (z_i - a)/b$, kde a a b jsou volena tak, aby $\Sigma l_i = 0, \Sigma l_i^2 = 1$; viz [1]).

Bylo by ovšem prakticky velmi cenné, kdyby se podařilo metodu modifikovat (např. v sekvenční) tak, aby přinesla užitečné rozhodnutí vždy.

¹⁾ Vztahy jsou poněkud upraveny, aby skýtaly výhodnější návod pro výpočet.

Vztah pro Φ_{ab} na str. 198 má být

$$\Phi_{ab} = S_{az}S_{bz}/S_{zz} + R(S_{az}S_{bz}/S_{zz} - S_{ab});$$

3. Důkaz.

3.1. Toto pomocné tvrzení lze odvodit z prvé derivace pravé strany: Pro $b > 0$, $a \geq 0$ je

$$(3.1.1) \quad \max_{t \in \langle 0, (a/b)^{1/2} \rangle} [t + (a - bt^2)^{1/2}] = \sqrt{\left(\frac{a(1+b)}{b}\right)}.$$

3.2. Označme $h(u) = r^*(u) - r(u)$, $t = |\alpha + \beta\bar{x} - \bar{y}|$, $A = (\beta^{*2}\Phi_{xx} - \Phi_{yy})/\Phi_{xx}$, $B = n/\Phi_{xx}$. Z (1.1) plyne

$$(3.2.1) \quad (\beta^* - \beta)^2 \leq A - Bt^2,$$

aspoň je-li $\Phi_{xx} > 0$, což můžeme zřejmě předpokládat, neboť případ $\Phi_{xx} \leq 0$ je triviální. Z (1.1) plyne také

$$(3.2.2) \quad 0 \leq t \leq (A/B)^{1/2}.$$

Označíme-li $A(u) = (u - \bar{x})^2 A$ a $B(u) = (u - \bar{x})^2 B$, plyne z (3.2.1)

$$|\beta^* - \beta| |u - \bar{x}| \leq (A(u) - B(u)t^2)^{1/2}.$$

Protože je $|h(u)| \leq |\beta^* - \beta| |u - \bar{x}| + t$, je dále

$$|h(u)| \leq t + (A(u) - B(u)t^2)^{1/2};$$

odtud a z (3.1.1) a (3.2.2) dostáváme

$$h^2(u) \leq \frac{A(u)(1 + B(u))}{B(u)} = \frac{A}{B}(1 + B(u)).$$

Odtud, z definic čísel A , B , $B(u)$ a ze vztahu (1.2) plyne (1.4) jednoduchou algebraickou úpravou.

Literatura

- [1] Max Halperin: Fitting of straight lines and prediction when both variables are subject to error. Journal Amer. Statist. Ass., 56 (1961), 657–669.
[2] Jaroslav Janko: Statistické tabulky. NČSAV, Praha 1958.

Резюме

ЗАМЕЧАНИЕ К МЕТОДУ ГАЛПЕРИНА ПРОКЛАДЫВАНИЯ ПРЯМОЙ В СЛУЧАЕ, КОГДА ОБЕ ПЕРЕМЕННЫЕ НАБЛЮДАЮТСЯ С ПОГРЕШНОСТЬЮ

ВАЦЛАВ ФАБИАН (Václav Fabian)

Из результата Галперина (см. [1]) выведен симультанный доверительный интервал функциональных значений $r(u)$ (для всех u) изучаемой линейной функ-

ции r . Оценка дана соотношением (1.4), причем $d(u)$ определено в (1.3) и $r^*(u) = \bar{y} + \beta^*(u - \bar{x})$. Остальные символы имеют то же значение, как в статье [1], вероятность события (1.4) равна по крайней мере $1 - \gamma$.

Summary

NOTE ON HALPERIN'S METHOD OF FITTING STRAIGHT LINES WHEN BOTH VARIABLES ARE SUBJECT TO ERROR

VÁCLAV FABIAN

From Halperin's result (cf. [1]) there is derived a simultaneous interval estimate of the function values $r(u)$ (for all u) of the considered linear function r . This estimate is given in (1.4) with $d(u)$ defined by (1.3) and with $r^*(u) = \bar{y} + \beta^*(u - \bar{x})$, other notation remaining as in [1]; the probability that the event (1.4) will occur is at least $1 - \gamma$.

Adresa autora: Dr. Václav Fabian C. Sc., Výzkumný ústav matematických strojů, Loretánské nám. 3, Praha 1 — Hradčany.