

Dopasowanie prostej do punktów z niepewnościami dla obydwu współrzędnych. Nowe wyniki dla problemu zapoczątkowanego w XIX wieku

A. Zięba

*Wydział Fizyki i Informatyki Stosowanej,
Akademia Górniczo-Hutnicza im. St. Staszica w Krakowie,
al. Mickiewicza 30, 30-059 Kraków
e-mail: andrzej.zieba@fis.agh.edu.pl*

Stosując metodę najmniejszych kwadratów, nie zawsze pamiętamy o założeniu, że niepewnościami $u(y_i)$ obarczona jest tylko zmienna zależna. Przypadek niezerowych niepewności dla obydwu współrzędnych (ang. *Errors-in-Variables*) budził mało uwagi. Tematem referatu jest uogólnienia metod: OLS (ang. *Ordinary Least Squares*) oraz WLS (ang. *Weighted Least Squares*) na przypadek $u(x_i) > 0$. Przedstawię spójną prezentację wyników znanych i rezultaty własne.

Model statystyczny problemu. Wariancja efektywna

Dla standardowego dopasowania prostej wartości zmiennej zależnej modeluje wzór

$$y_i = a_0 x_i + b_0 + e_{y,i}, \quad (1)$$

w którym parametry a_0 i b_0 określają „prawdziwą” prostą (nieznaną w eksperymencie), zaś składnik $e_{y,i}$ modeluje błąd przypadkowy zmiennej zależnej.

Gdy wartości x_i są ponadto obarczone błędami $e_{x,i}$, model przybiera postać

$$y_i = a_0(x_{0,i} + e_{x,i}) + b_0 + e_{y,i}. \quad (2)$$

Składnik $a_0 x_{0,i} + b_0$ jest deterministyczny, natomiast $a_0 e_{x,i} + e_{y,i}$ oznacza nową zmienną losową. Modele (1) i (2) mają te same właściwości stochastyczne, o ile zmiennej y_i we wzorze (1) przypiszemy wariancję efektywną

$$\text{Var}(y_i) = a_0^2 \text{Var}(e_{x,i}) + \text{Var}(e_{y,i}). \quad (3)$$

Punkty o różnych niepewnościach – uogólnienie metody WLS

Wyprowadzenie Reeda [1] równania (4) polegało na uproszczeniu pseudo-kubicznego równania Yorka [2]. Elementarne wyprowadzenie obejmuje następujące kroki:

- (i) efektywne wariancje przybliżamy jako niepewności efektywne:

$$u_{\text{eff}}(y_i) = [a^2 u^2(x_i) + u^2(x_i)]^{1/2}$$

i wykorzystujemy do zdefiniowania wag funkcji kryterialnej $M(a, b)$ metody WLS,


(ii) warunek $\partial M(a,b)/\partial b = 0$ można rozwiązać analitycznie, co redukuje problem do poszukiwania minimum funkcji jednej zmiennej $M(a)$,

(iii) warunek $\partial M(a)/\partial a = 0$ prowadzi do równania pseudo-kwadratowego

$$a = \frac{\sum (y_i - \bar{y})[(x_i - \bar{x}) + aC(y_i - \bar{y})]}{\sum (x_i - \bar{x})[(x_i - \bar{x}) + aC(y_i - \bar{y})]}, \quad (4)$$

w którym \bar{x} oraz \bar{y} oznaczają średnie ważone.

Równanie (4) rozwiązuje się metodą iteracyjną. Dla przykładowych danych (Rysunek 1) punktem startowym jest $a = -0.5396$ z metody OLS; kolejne iteracje dają: -0.4602 ; -0.4812 ; -0.4804 ; i -0.4805 .



Rysunek 1: Dopasowanie OLS i dopasowanie prawidłowe (linia ciągła) dla przykładowych danych

Punkty równoważne – uogólnienia metody OLS

Gdy niepewności są te same dla każdego punktu ale $u(x) \neq u(y)$, mamy dopasowanie Deminga (DR – od *Deming Regression*). Najprostszy jest model dopasowania ortogonalnego (OR – od *Orthogonal Regression*) dla którego $u(x) = u(y)$. Wzór na nachylenie prostej dla OR podał Adcock [3],

$$a = D \pm \sqrt{D^2 + 1}, \quad D = \frac{S_{yy} - S_{xx}}{2S_{xy}}, \quad (5)$$

gdzie

$$S_{xx} = \sum (x_i - \bar{x})^2, \quad S_{yy} = \sum (y_i - \bar{y})^2, \quad S_{xy} = \sum (x_i - \bar{x})(y_i - \bar{y}). \quad (6)$$

Natomiast niepewność nachylenia,

$$u^2(a) = \frac{M}{n-2} \frac{(1+a^2)(S_{xx} + S_{yy})}{(S_{xx} - S_{yy})^2 + 4S_{xy}^2}, \quad (7)$$

wyprowadził Petrolini [4] – ponad sto lat później.

Omówione też zostanie znaczenie formalizmu dla danych o różnym stopniu rozrzutu.

Podziękowania

Dziękuję Cameronowi Reed'owi za użyteczną korespondencję. Temat opracowałem dla przygotowanego podręcznika analizy danych [5].

Bibliografia

- [1] Reed B. C., Am. J. Phys. 60, 59 (1992).
- [2] York D., Can. J. Phys. 44, 1079 (1966).
- [3] Adcock R. J., Analyst 5, 53-54 (1878).
- [4] Petrolini A., Am. J. Phys. 82, 1178 (2014).
- [5] Zięba A., Analysis of Experimental Data in Science and Technology, Cambridge Scholar Publishing, Newcastle, UK (2023).