

УДК 519.237.5

## РОЗРОБКА КОМП'ЮТЕРНОЇ ПРОГРАМИ ДЛЯ РЕГРЕСІЙНОГО АНАЛІЗУ СТАТИСТИЧНИХ ДАНИХ З ПОХИБКАМИ ВИМІРЮВАНЬ

Студ. І.С. Хорунжа, гр.МгІТ-2-17,  
Науковий керівник проф. С.М. Краснитський  
Київський національний університет технологій та дизайну

**Мета роботи** – розробити комп'ютерну програму для регресійного аналізу статистичних даних з урахуванням можливості похибок вимірювань регресорів.

**Завдання роботи** полягає у розробці програмного забезпечення для оптимального в певному сенсі рішення поставленої задачі, зокрема створення програмного продукту для регресійного аналізу статистичних даних з похибками вимірювань, а також порівняння отриманих результатів та формулювання висновків про якість роботи розглянутих алгоритмів.

**Об'єктом дослідження** є математичні моделі регресійного типу.

**Предметом дослідження** є статистичні дані, з наявними похибками вимірювань.

**Методи та засоби дослідження.** При побудові алгоритму побудови моделей:

- елементи теорії ймовірностей;
- методи оцінювання параметрів регресійних залежностей;
- статистичні дані;
- використання середньо геометричної функціональної залежності;

Для програмної реалізації програми використовувалася середа Microsoft Visual FoxPro.

**Наукова новизна та практичне значення отриманих результатів.** У різних галузях науки, техніки, економіки доводиться зустрічатися із ситуаціями, коли дані, що використовуються для побудови математичних моделей досліджуваних процесів, напевне містять похибки вимірювань, якими не можна нехтувати. У даний час виконується чимало досліджень, що мають на меті подолати вказані недоліки у вихідних даних. Однією з відомих останніх робіт, що присвячена даній тематиці, є книга [2]. Проте доступних і зручних у використанні комп'ютерних програм для реалізації, ще не вистачає.

**Результати дослідження.** Автор даної роботи пропонує програмне забезпечення для реалізації методу роботи з даними з похибками, що базується на принципі, котрий має назву середньгеометричної функціональної залежності.

Роздивимось спочатку звичайну ситуацію, коли ми маємо відгук  $Y$  та один предиктор  $X$ , та при цьому постулюється функція відгуку

$$Y = \beta_0 + \beta_1 X + \varepsilon \quad (1)$$

у вигляді рівняння прямої з випадковим доданком. В таких випадках припускається, що відгук  $Y$  містить помилку, тоді як  $X$  — ні. Але можливо, що змінна  $X$  також схильна до помилки? Нехай  $\eta_i$  — істинне значення змінної  $Y_i$ , а  $\xi_i$  — істинна величина  $X_i$ ,  $i=1,2,\dots,n$ . Тоді спостережувані значення  $Y_i$  та  $X_i$  виражаються співвідношеннями

$$Y_i = \eta_i + \varepsilon_i$$

$$X_i = \xi_i + \delta_i,$$

Іє  $\varepsilon_i$  та  $\delta_i$  є випадковими похибками, які додаються до  $\eta_i$  та  $\xi_i$  відповідно, а  $\varepsilon_i$  незалежна від  $\xi_i$  та  $\delta_i$ ;  $\delta_i$  незалежна від  $\eta_i$  та  $\varepsilon_i$ . Постулована нами модель має вигляд

$$\eta_i = \beta_0 + \beta_1 \xi_i$$

Підставляючи відповідні вирази, отримаємо

$$Y_i = \beta_0 + \beta_1 \xi_i + \varepsilon_i^*$$

де  $\varepsilon_i^* = (\varepsilon_i - \beta_1 \delta_i)$

Бачимо, що у випадку, коли змінні  $X$  схильні до похибок, як і змінні  $Y$ , то регресійна задача помітно ускладнюється, навіть коли модель однофакторна. Тому завжди корисно по можливості так організувати експеримент, щоб відношення  $\sigma_\delta^2 / \sigma_\xi^2$  було малою величиною. Практично це означає, що розкид величини  $\xi$  мірою якої служить  $\sigma_\xi^2$ , повинно суттєво перевищувати розкид помилок, які містяться в змінних  $X$ . Те ж само й вірно для інших предикторів. Після того, як це забезпечено, помилками в змінних  $X$  можна знехтувати та використовувати звичайний метод найменших квадратів. Якщо цього зробити не можна, то при використанні звичайного аналізу можуть виникнути ускладнення.

У даному випадку в роботі [1] рекомендується використання замість класичних оцінок методу найменших квадратів в моделі (1) використовувати оцінки середньгеометричної функціональної залежності

$$\hat{\beta}_1 = (S_{YY} / S_{XX})^{1/2},$$

$$\hat{\beta}_0 = \bar{Y} - \hat{\beta}_1 \bar{X}.$$

Тут і далі  $\bar{X}, \bar{Y}$  — середні арифметичні спостережуваних значень  $X, Y$  відповідно,

$$S_{XY} = \sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y}), S_{XX} = \sum_{i=1}^n (X_i - \bar{X})^2, S_{YY} = \sum_{i=1}^n (Y_i - \bar{Y})^2.$$

Оцінка  $\hat{\beta}_1$  тут являє собою середнє геометричне величин

$$b_1 = S_{XY} / S_{XX}, \alpha_1^{-1} = (S_{XY} / S_{XX})^{-1},$$

де  $b_1, \alpha_1$  — кутові коефіцієнти, що підібрані методом найменших квадратів для залежностей  $Y$  від  $X$  і  $X$  від  $Y$ :

$$\hat{Y} = b_0 + b_1 X, \hat{X} = \alpha_0 + \alpha_1 Y.$$

Таким чином, геометричне середнє  $\hat{\beta}_1 = (b_1 \alpha_1^{-1})^{1/2}$  є компромісним значенням, що лежить між двома кутовими коефіцієнтами рівнянь залежності  $Y$  від  $X$ . Обґрунтування вказаного методу одержуємо, застосовуючи метод максимальної правдоподібності, який при відомому значенні  $\lambda$  приводить до виразу

$$\hat{\beta}_1 = [S_{YY} - \lambda S_{XX} + \{(S_{YY} - \lambda S_{XX})^2 + 4\lambda S_{XY}^2\}^{1/2}] / 2S_{XY}, \hat{\beta}_0 = \bar{Y} - \hat{\beta}_1 \bar{X}.$$

Наведені вище оцінки  $\hat{\beta}_1, \hat{\beta}_0$  одержуємо, поклавши в останніх двох рівностях

**Висновки.** Програмне забезпечення, що реалізує вищеописані кроки, дозволить раціоналізувати роботу дослідника. Знання сумісних характеристик поведінки моделей лінійного регресійного типу дозволить ефективно впровадити це на практиці, а саме — дасть змогу ефективно використовувати ці методи в різних галузях.

**Ключові слов:** регресійний аналіз, регресійний метод, статистика.

#### ЛІТЕРАТУРА

1. Дрейпер Н, Смит Г. Прикладной регрессионный анализ — М-К, D: 2007. - 911 с.