

МЕРЫ ВАРИАБЕЛЬНОСТИ ОЦЕНОК ПАРАМЕТРОВ В ЗАДАЧАХ ВОССТАНОВЛЕНИЯ ЗАВИСИМОСТЕЙ ПО ИНТЕРВАЛЬНЫМ ДАННЫМ

С.П. ШАРЫЙ,
ФИЦ ИВТ и НГУ,
Новосибирск, Россия
shary@ict.nsc.ru

***Аннотация.** Представлены две возможные конструкции количественной меры вариабельности оценки параметров в задаче восстановления линейной зависимости по интервальным данным. Они показывают степень изменчивости и неоднозначности оценки, и необходимость их введения вызвана тем, что в условиях интервальных данных ответ к задаче, как правило, неединствен. Обсуждаются содержательные мотивации и смысл новых величин с точки зрения других известных характеристик данных. Применение предложенных мер вариабельности иллюстрируется на конкретных примерах.*

***Ключевые слова:** задача восстановления зависимостей, интервальная неопределённость данных, метод максимума совместности, мера вариабельности.*

Цель нашей работы — представить две возможные конструкции количественной меры вариабельности для оценки параметров функциональной зависимости в интервальном анализе данных. Это сравнительно молодая ветвь современной науки об обработке данных, которая не опирается на аппарат теории вероятностей, но широко использует методы интервального анализа (см., к примеру, [1, 2, 3]).

Термином «вариабельность» мы называем степень изменчивости и неоднозначности оценки, и необходимость её введения диктуется тем обстоятельством, что в задачах обработки интервальных данных ответ, как правило, неединствен. Обычно мы получаем целое множество различных оценок, одинаково пригодных в качестве ответов к задаче и согласующихся с её данными. То, насколько мало

или обширно это множество, как раз так характеризуется термином «вариабельность».

Мы рассматриваем задачу восстановления линейной зависимости вида

$$y = \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n, \quad (1)$$

в которой x_1, x_2, \dots, x_n – независимые переменные (называемые также *входными* или *предикторными* переменными), y – зависимая переменная (называемая также *выходной* или *критериальной* переменной), а $\beta_1, \beta_2, \dots, \beta_n$ – некоторые коэффициенты. Эти неизвестные коэффициенты должны быть определены на основе ряда измерений значений x_1, x_2, \dots, x_n и y . Результаты измерений неточны, и мы предполагаем, что они являются некоторыми интервалами, которые дают двусторонние границы точных значений измеренных величин. Будем считать, что в результате i -го измерения получаются такие интервалы $x_{i1}, x_{i2}, \dots, x_{in}, y_i$, что истинное значение x_1 лежит в x_{i1} , истинное значение x_2 лежит в x_{i2} и т. д. вплоть до y , истинное значение которого лежит в y_i . Иными словами, мы рассматриваем интервальные данные

$$\begin{array}{l} x_{11}, x_{12}, \dots, x_{1n}, y_1, \\ x_{21}, x_{22}, \dots, x_{2n}, y_2, \\ \dots \dots \dots \dots \dots \\ x_{m1}, x_{m2}, \dots, x_{mn}, y_m, \end{array} \quad (2)$$

а также построенные из них матрицу $X = (x_{ij})$ и вектор $y = (y_i)$.

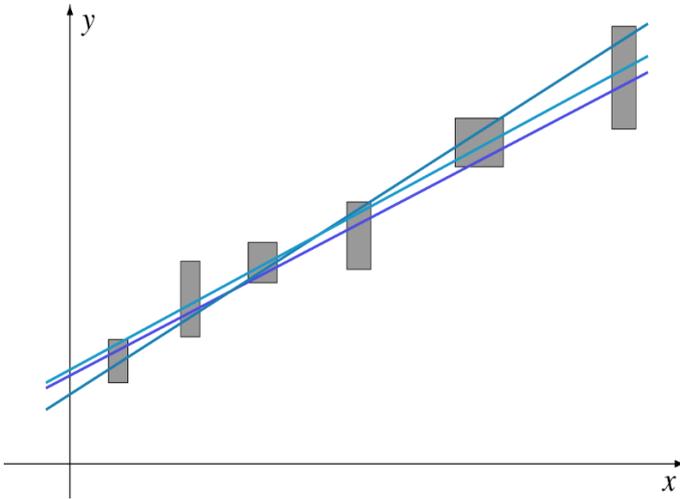
Нам необходимо найти или оценить коэффициенты β_j , $j = 1, 2, \dots, n$, для которых линейная функция (1) «наилучшим образом» приближает данные (2) (см. рисунок).

На сегодняшний день разработано немало методов решения поставленной задачи, но мы будем работать с методом максимума совместности [4], который является, по-видимому, наиболее универсальным и хорошо разработанным. В этом методе оценка $\hat{\beta} = (\hat{\beta}_1, \hat{\beta}_2, \dots, \hat{\beta}_n)$ для параметров линейной зависимости (1) берётся как аргумент максимума специального «распознающего функционала», некоторой функции $Tol: \mathbb{R}^n \rightarrow \mathbb{R}$, с помощью

которой определяется количественная мера совместности интервальной системы уравнений, построенной по данным задачи:

$$\text{Tol}(\beta, X, y) = \min_{1 \leq i \leq m} \left\{ \text{rad } y_i - \left| \text{mid } y_i - \sum_{j=1}^n x_{ij} \beta_j \right| \right\},$$

где $\text{rad } y_i$ и $\text{mid } y_i$ — радиус и середина интервала y_i .



В качестве величины, характеризующей чувствительность и вариабельность оценки вектора параметров $\hat{\beta} = (\hat{\beta}_1, \hat{\beta}_2, \dots, \hat{\beta}_n)$ линейной зависимости (1), которая получена методом максимума согласования по данным (3), мы предлагаем величины

$$\text{IVE}(X, y) = \sqrt{n} \max_{\mathbb{R}^n} \text{Tol} \cdot (\min_{X \in X} \text{cond}_2 X) \cdot \frac{\|\arg \max_{\mathbb{R}^n} \text{Tol}\|}{\|\hat{y}\|}$$

и

$$\text{IDE}(X, y) = \sqrt{n} \max_{\mathbb{R}^n} \text{Tol} \cdot \text{cond}_2 X \cdot \frac{\|\arg \max_{\mathbb{R}^n} \text{Tol}\|}{\|\hat{y}\|}.$$

В выписанных формулах переменные и величины имеют следующий смысл:

n – размерность вектора параметров восстанавливаемой функции;

$\|\cdot\|$ – евклидова норма векторов (2-норма), определяемая для векторов $y \in \mathbb{R}^n$ как

$$\|y\| = (\sum_{i=1}^n y_i^2)^{1/2};$$

$\text{cond}_2 X$ — спектральное число обусловленности матрицы X , определяемое как

$$\text{cond}_2 X = \sigma_{\max}(X) / \sigma_{\min}(X),$$

т.е. как отношение максимального и минимального сингулярных чисел матрицы X ; $\text{cond}_2 X$ является распространением на прямоугольный случай известного в вычислительной линейной алгебре понятия числа обусловленности квадратной матрицы;

\mathcal{X} – специальная точечная матрица, называемая *матрицей комбинаций концов* для интервальной матрицы X , имеющая размеры $N \times n$, где $N \leq m \cdot 2^n$, и составленная из концов интервальных элементов вдоль каждой строки матрицы X ;

\hat{y} – это «наиболее представительная» точка интервального вектора данных y , определяемая как

$$\hat{y} = \frac{1}{2} (|\text{mid } y + \text{rad } y| + |\text{mid } y - \text{rad } y|),$$

где операции «mid» и «rad» применяются покомпонентно. Мы показываем, что в случае неотрицательного maxTol величины IVE и IDE дают, фактически, оценки размеров множества решений задачи.

Литература

1. «Интервальный анализ и его приложения» — тематический веб-сайт <http://www.nsc.ru/interval/>
2. Moore R.E., Kearfott R.B., Cloud M.J. Introduction to interval analysis. – SIAM: Philadelphia, 2009.
3. Шарый С.П. Конечномерный интервальный анализ. – ИВТ СО РАН: Новосибирск, 2003-2021. – Электронная книга, см. <http://www.nsc.ru/interval/?page=Library/InteBooks>
4. Shary S.P Weak and strong compatibility in data fitting problems under interval uncertainty // Advances in Data Science and Adaptive Analysis. – 2020. – Vol. 12, No. 1. – 2050002.
5. Shary S.P. A variability measure for estimates of parameters in interval data fitting. 20 p. Deposited in arXiv as document [arXiv:2003.05126](https://arxiv.org/abs/2003.05126)