

## ОПРАЦЮВАННЯ РЕЗУЛЬТАТІВ СПОСТЕРЕЖЕННЯ НА ОСНОВІ НАБЛИЖЕНОГО МЕТОДУ ПОРЯДКОВИХ СТАТИСТИК

© Михайло Дорожовець, Іванна Попович, 2014

Національний університет "Львівська політехніка", кафедра інформаційно-вимірювальних технологій,  
вул. С. Бандери, 12, 79013, Львів, Україна

*Запропоновано наближений метод порядкових статистик для опрацювання випадкових спостережень за апіорі невідомого розподілу ймовірності генеральної сукупності. Використання наближеного методу не потребує складних розрахунків інтегралів і коваріаційна матриця визначається за допомогою простих арифметичних операцій. Подано результати наближеного методу і продемонстровано його ефективність.*

*Предложен приближенный метод порядковых статистик для обработки случайных наблюдений при априори неизвестном распределении вероятности генеральной совокупности. Использование приближенного метода не требует сложных расчетов интегралов и ковариационная матрица определяется с помощью простых арифметических операций. Представлены результаты приближенного метода и продемонстрировано его эффективность.*

*In the article the approximate method of order statistics for the processing of the random observations of unknown a priori probability density distribution is proposed. Using approximate method does not require complex calculations of integrals, and the covariance matrix is determined using simple arithmetic operations. Presents the results of a study of approximate methods and demonstrated its effectiveness.*

**1. Вступ.** З метою підвищення точності вимірювань широко використовують статистичне опрацювання результатів спостережень [1]. Найкраща оцінка результату і його стандартної непевності типу А великою мірою залежить від моделі густини розподілу генеральної сукупності, з якої отримано вибірку результатів спостережень (вбірка) [1]. Стандартна методика опрацювання серії некорельованих спостережень  $x_1, x_2, \dots, x_n$  ( $n$  – кількість зареєстрованих спостережень) забезпечує мінімальне значення стандартної непевності типу А в результаті оцінки (середнє значення) тільки у випадку нормального розподілу ймовірності генеральної сукупності  $p(x)$  або відповідного близького йому розподілу. Загалом густина розподілу генеральної сукупності дає інформацію про частість появи тих чи інших результатів спостережень, а також про їх взаємне розташування. Тобто різним моделям густини розподілу генеральної сукупності відповідає різне взаємне розміщення результатів спостережень на числовій осі.

Відомо, що найточнішими вимірюваннями є вимірювання із безпосереднім порівнянням вимірюваної величини із мірою. Цей принцип можна застосувати також і до статистичного опрацювання результатів спостережень. Однак постає проблема створення «міри» для випадкових спостережень.

**2. Методика порядкових статистик.** Якщо густина розподілу спостережень істотно відрізняється від нормальної, існують інші параметри положення спостережень, крім середнього значення, в яких стандартна непевність менша від стандартної непевності середнього значення. У [2, 3] наведено метод, оснований на порядкових статистиках, в якому безпосередньо використовується інформація про розподіл  $p(x)$ . В [4] доведено, що в цьому методі для дисперсії  $\text{var}(\hat{m})$  оцінки положення  $\hat{m}$  і дисперсії середнього значення  $\text{var}(\bar{x})$  існує така нерівність:

$$\text{var}(\hat{m}) \leq \frac{S^2}{n} = \text{var}(\bar{x}), \quad (1)$$

де рівність  $\hat{m} = \bar{x}$  справджується тільки для нормального розподілу.

Однак необхідною умовою для визначення найкращого результату з найменшою стандартною непевністю є точно відомий розподіл ймовірності спостереження  $p(x)$ . Якщо розподіл не відомий, але відомо, що він може бути одним з безлічі можливих моделей, які будуть застосовуватися, тоді можна використовувати метод, описаний у [5–8]. Відповідно до цього методу, впорядковані входні спостереження  $\mathbf{X}_s = (x_{(1)}, x_{(2)}, \dots, x_{(n)})^T$  порівнюються з набором серії  $J$  з такої самої

кількості так званих зразкових спостережень  $\mathbf{X}ref_1=(xref_{1,1}, xref_{2,1}, \dots, xref_{n,1})^T$ ,  $\mathbf{X}ref_2=(xref_{1,2}, xref_{2,2}, \dots, xref_{n,2})^T$ , ...,  $\mathbf{X}ref_j=(xref_{1,j}, xref_{2,j}, \dots, xref_{n,j})^T$ , що відповідають вибраним функціям розподілу ймовірностей  $f_1(x), f_2(x), \dots, f_j(x)$  (рис. 1).




Рис.1. Приклади наборів зразкових спостережень – математичних сподівань позиційних статистик для різних густин розподілів ( $n=19$ )


Принцип визначення найкращої оцінки параметра положення (центра групування) результатів спостереження  $\mu$  і параметра ширини розподілу  $\sigma$  вибірки за допомогою цього методу полягає в попередньому впорядкуванні спостережень  $x_{(1)}, x_{(2)}, \dots, x_{(n)}$ , а потім у мінімізації суми квадратів  $S_R^2$  відхилень

$$v_k = m + E[s_k] \cdot s - x_{(k)} = xref'_k - x_{(k)},$$

де  $xref'_k = m + xref_k \cdot s$  (рис. 2, а).

Для кожної моделі  $p_j(x)$  ( $j = 1, 2, \dots, J$ ) густини розподілу генеральної сукупності розподілу ймовірностей параметри  $\mu_j$  і  $\sigma_j$  вибірки визначаються на підставі вагового методу найменших квадратів (ВМНК), що у матричному представленні має вигляд [5–8]:

$$(\hat{m}_j, \hat{s}_j)^T = (\mathbf{A}_j^T \cdot \mathbf{W}_j \cdot \mathbf{A}_j)^{-1} \mathbf{A}_j^T \cdot \mathbf{W}_j \cdot \mathbf{X}_s = \mathbf{REC}_j \cdot \mathbf{X}_s, \quad (2)$$



де  $\mathbf{REC}_j = (\mathbf{A}_j^T \cdot \mathbf{W}_j \cdot \mathbf{A}_j)^{-1} \mathbf{A}_j^T \cdot \mathbf{W}_j$  (рис. 2, б) є так звана реконструктивна матриця;

$$\mathbf{A}_j^T = \begin{pmatrix} 1 & 1 & \mathbf{L} & 1 \\ xref_{j,1} & xref_{j,2} & \mathbf{L} & xref_{j,n} \end{pmatrix}, \quad \mathbf{W}_j = \mathbf{COV}_j^{-1}$$

– є вагова матриця, зворотна до коваріаційної матриці  $\mathbf{COV}_j$  порядкових статистик, елементи якої визначають з обчислення подвійного інтеграла:

$$Cov_{j;k,l} = \iint_{x_j > x_k} s \cdot z \cdot p_{2j;k,l}(s, z) ds dz - xref_{j;k} xref_{j;l}, \quad (3)$$

де

$$p_{2j;k,l}(s, z) = C(n, k, l) \cdot [F_j(s)]^{k-1} [F_j(z) - F_j(s)]^{l-k-1} [1 - F_j(z)]^{n-l} p_j(s) p_j(z), \quad (4)$$

є сумісним розподілом ймовірностей  $k$ -ї ( $s$ ) і  $l$ -ї ( $z$ ) порядкових статистик [9];  $F_j(x)$  – функція розподілу;

$$C(n, k, l) = \frac{n!}{(n-l)! \cdot (l-k-1)! \cdot (k-1)!}.$$

На основі аналізу суми квадратів відхилень

$$S_{R,1}^2, S_{R,2}^2, \dots, S_{R,j}^2, \dots, S_{R,J}^2 = \frac{(\mathbf{X}_s - \mathbf{A}_j \cdot (\hat{m}_j, \hat{s}_j)^T)^T \cdot \mathbf{W}_j \cdot (\mathbf{X}_s - \mathbf{A}_j \cdot (\hat{m}_j, \hat{s}_j)^T)}{n-2}, \quad (5)$$

розраховуються значення для положення і ширини ( $\hat{m}, \hat{s}$ ) вхідної (досліджуваної) вибірки, для яких спостереження в найкращий спосіб (за ВМНК) узгоджуються з відповідною зразковою вибіркою (рис. 2, б).




Рис. 2. Принцип визначення параметрів  $\mu$  і  $\sigma$  за допомогою методу порядкових статистик (а), блок-схема опрацювання спостережень відповідно до методу порядкових статистик (б)

Основною проблемою практичного застосування вищевказаного методу є складність розрахунку коваріаційної матриці **COV**. За виразом (3) для обчислення елемента коваріаційної матриці  $Cov_{j;k,l}$  необхідно обчислювати подвійний інтеграл від виразу, що залежить від сумісного розподілу ймовірностей  $p_{2;j;k,l}(s,z)$   $k$ -ї ( $s$ ) і  $l$ -ї ( $z$ ) порядкових статистик, який загалом є складною функцією густини та функції розподілу випадкової величини. Крім того, точність розрахунку коваріаційної матриці, а далі оберненої до неї, зменшується зі збільшенням кількості спостережень  $n$ .

**Метою роботи** є розроблення методики опрацювання результатів спостережень на основі наближеного методу порядкових статистик, а також дослідження ефективності методики методом Монте-Карло.

### 3. Наближений метод порядкових статистик.

Для того, щоб значно спростити розрахунок коваріаційної матриці, запропоновано використовувати асимптотичне наближення для дисперсії та коефіцієнтів кореляції між двома позиційними статистиками для більше ніж  $n \rightarrow \infty$  [9]. Для виведення цих формул використаємо властивості параметрів позиційних статистик, а саме квантілі  $x_{(k1)}$  і  $x_{(k2)}$  з вибірки, взятої з генеральної сукупності з розподілом  $p(x)$ , якщо  $n \rightarrow \infty$ , мають асимптотично нормальний розподіл з параметрами [9]:

$$m_1 = x_{(1,1)}, m_2 = x_{(1,2)}, s_1^2 \approx \frac{I_1(1-I_1)}{n(p(x_{(1,1)}))^2},$$

$$s_2^2 \approx \frac{I_2(1-I_2)}{n(p(x_{(1,2)}))^2}, r_{1,2} \approx \sqrt{\frac{I_1(1-I_2)}{I_2(1-I_1)}}, \quad (6)$$

де  $m_1$ ,  $m_2$  – математичні сподівання (очікувані значення);  $s_1^2$ ,  $s_2^2$  – дисперсії та  $r_{1,2}$  – коефіцієнт кореляції обох квантилів.

Визначаючи значення квантіля для  $1 \leq k \leq n$ , як  $I_k = k/(n+1)$ , для якого  $x_{ref;j;k} \approx x_{(1,j;k)} = qF_j(I_k) = F_j^{-1}(I_k)$  на підставі залежностей (6) наближені значення коефіцієнтів коваріаційної матриці можна обчислити відповідно до співвідношення:

$$Cov_{j;k,l} \approx r_{k,l} \cdot s_{j,k} \cdot s_{j,l} =$$

$$= \frac{k \cdot (n+1-l)}{n(n+1)^2} \cdot \frac{1}{p_j(x_{(1,j;k)}) \cdot p_j(x_{(1,j;l)})}, \quad 1 \leq k < l \leq n. \quad (7)$$

**4. Дослідження наближеного методу порядкових статистик.** Дослідження проводилося у два етапи. У першому порівнювались очікувані значення порядкових статистик і значення елементів автоковаріаційної матриці, які розраховані на основі точних і наближених залежностей, а також значення коефіцієнтів точної та наближеної дворядкової реконструктивної матриці **REC**. Дослідження виконано для кількості спостережень  $n = 21, 41$  і  $61$  і для вибраних ймовірнісних розподілів: Лапласа, нормального і типу арксинусоїдного. Рівномірний розподіл було розглянуто на другому етапі. Виявилось, що значення матриці **REC** коефіцієнтів, розраховані на основі наближеної коваріаційної матриці (7), менше відрізняються від теоретичних значень, ніж розрахунок на основі «точної» коваріаційної матриці (3).

Зокрема, досліджено вплив наближення на точність розрахунку матриці реконструкції **REC** на основі наближеної коваріаційної матриці. Для нормального розподілу значення всіх коефіцієнтів першого рядка

$$\mathbf{REC}_j = \begin{pmatrix} g_{1,j} & g_{2,j} & \mathbf{K} & g_{[(n+1)/2],j} & \mathbf{K} & g_{2,j} & g_{1,j} \\ -g_{1,j} & -g_{2,j} & \mathbf{L} & 0 & \mathbf{L} & g_{2,j} & g_{1,j} \end{pmatrix}, \quad (8)$$

мають бути однаковими і дорівнювати  $1/n$ . Однак у разі обчислення у середовищі Mathcad 13 із точністю представлення чисел  $10^{-13}$ , якщо кількість спостережень  $n=41$  і  $n=61$ , значення частини коефіцієнтів істотно відрізняються від  $1/n$ , причому тим більше, чим більше  $n$  (рис. 3). Подібна ситуація спостерігається у випадку інших густин розподілу спостережень. Оскільки неточність матриці **REC** безпосередньо впливає на неточність обчислюваних у (2) параметрів  $(\hat{m}, \hat{s})$ , то цей факт має важливе значення. З досліджень випливає, що у разі збільшення кількості спостережень точність обчислюваних значень вища у наближеному методі.

На другому етапі ефективність наближеного методу протестовано за допомогою методу Монте-Карло з кількістю симуляцій (реалізацій)  $M = 10^5$ . Наведені нижче результати дослідження стосуються значення параметрів положення  $\mu_0 = 5,000$  і ширини  $\sigma = 0,200$ . Ефективність цих двох методів порівнювали за допомогою статистичного аналізу значень похибок  $\Delta_j^{(n)} = \hat{m}_j^{(n)} - m_0$  параметра положення і його стандартної непевності  $u_{A,j}^{(n)}(\hat{m})$ . Нормалізоване до теоретичного значення стандартного відхилення  $s_{\bar{m}} = s / \sqrt{n}$  від середнього значення параметрів похибок і стандартна непевність результатів, отриманих для точних і наближених методів, залежно від кількості спостережень  $n$ , подані в таблиці.




Рис.3. Значення коефіцієнтів першого рядка «точної» матриці REC (●) та наближеної RECApr (○) для нормального розподілу спостережень за кількості n=41 та n=61

**Характеристики стандартних похибок і непевності точних і наближених методів**

Розподіл Лапласа								
n	Характеристики похибок				Характеристики непевності			
	Точна		Наближена		Точна		Наближена	
	$E_{\Delta\hat{m}}^-/s_m^-$	$E_{s_{\Delta(\hat{m})}}^-/s_m^-$	$E_{\Delta\hat{m}}^-/s_m^-$	$E_{s_{\Delta(\hat{m})}}^-/s_m^-$	$E_{u(\hat{m})}^-/s_m^-$	$E_{s_{u(\hat{m})}}^-/s_m^-$	$E_{u(\hat{m})}^-/s_m^-$	$E_{s_{u(\hat{m})}}^-/s_m^-$
21	$3.43 \cdot 10^{-3}$	0.886	$3.73 \cdot 10^{-3}$	0.922	0.782	0.247	0.817	0.303
41	$-2.96 \cdot 10^{-3}$	0.842	$-5.05 \cdot 10^{-3}$	0.863	0.799	0.193	0.820	0.210
61	$6.77 \cdot 10^{-3}$	0.831	$8.59 \cdot 10^{-3}$	0.845	0.800	0.168	0.802	0.180
Розподіл нормальний								
n	Характеристики похибок				Характеристики непевності			
	Точна		Наближена		Точна		Наближена	
	$E_{\Delta\hat{m}}^-/s_m^-$	$E_{s_{\Delta(\hat{m})}}^-/s_m^-$	$E_{\Delta\hat{m}}^-/s_m^-$	$E_{s_{\Delta(\hat{m})}}^-/s_m^-$	$E_{u(\hat{m})}^-/s_m^-$	$E_{s_{u(\hat{m})}}^-/s_m^-$	$E_{u(\hat{m})}^-/s_m^-$	$E_{s_{u(\hat{m})}}^-/s_m^-$
21	$4.71 \cdot 10^{-3}$	1.079	$5.14 \cdot 10^{-3}$	1.077	0.822	0.266	0.860	0.285
41	$3.25 \cdot 10^{-3}$	1.030	$3.62 \cdot 10^{-3}$	1.033	0.937	0.203	0.962	0.211
61	$10.9 \cdot 10^{-3}$	1.019	$11.0 \cdot 10^{-3}$	1.019	0.976	0.158	0.993	0.162
Розподіл арксинусоїдний								
n	Характеристики похибок				Характеристики непевності			
	Точна		Наближена		Точна		Наближена	
	$E_{\Delta\hat{m}}^-/s_m^-$	$E_{s_{\Delta(\hat{m})}}^-/s_m^-$	$E_{\Delta\hat{m}}^-/s_m^-$	$E_{s_{\Delta(\hat{m})}}^-/s_m^-$	$E_{u(\hat{m})}^-/s_m^-$	$E_{s_{u(\hat{m})}}^-/s_m^-$	$E_{u(\hat{m})}^-/s_m^-$	$E_{s_{u(\hat{m})}}^-/s_m^-$
21	$-8.79 \cdot 10^{-3}$	0.470	$-8.10 \cdot 10^{-3}$	0.423	0.269	0.204	0.235	0.259
41	$-2.54 \cdot 10^{-3}$	0.459	$-2.85 \cdot 10^{-3}$	0.476	0.168	0.152	0.176	0.175
61	$-0.10 \cdot 10^{-3}$	0.099	$-0.41 \cdot 10^{-3}$	0.100	0.134	0.127	0.150	0.141
Розподіл рівномірний								
n	Характеристики непевності (р. рівномірного)							
	$E_{\Delta\hat{m}}^-/s_m^-$	$E_{s_{\Delta(\hat{m})}}^-/s_m^-$	$E_{u(\hat{m})}^-/s_m^-$	$E_{s_{u(\hat{m})}}^-/s_m^-$				
	21	$8.93 \cdot 10^{-3}$	0.771	0.516	0.257			
41	$4.12 \cdot 10^{-3}$	0.619	0.460	0.237				
61	$10.3 \cdot 10^{-3}$	0.552	0.399	0.240				

**5. Висновки.** Як видно з даних, наведених у таблиці, у разі відхилення розподілу ймовірностей нормального розподілу обидва методи дають менші стандартне відхилення похибок і стандартну непевність результату (параметр положення) порівняно зі стандартним відхиленням похибки та стандартною непевністю середнього значення. Зі збільшенням кількості спостережень ефективність точних і наближених методів зростає, причому тим більше, чим більше параметр положення відрізняється від середнього значення.

Різниця між середніми значеннями стандартних відхилень похибок визначає параметр положення в обох методах і не перевищує декількох відсотків. Вона становить:

- для розподілу Лапласа: 4.0 % ( $n=21$ ), 2.5 % ( $n=41$ ), 1.7 % ( $n=61$ );
- для нормального: 0.26 % ( $n=21$ ), 0.25 % ( $n=41$ ), 0.02 % ( $n=61$ );
- для типу арксинусоїдного: 9.9 % ( $n=21$ ), 3.4 % ( $n=41$ ), 0.4 % ( $n=61$ ).

Різниця між середніми значеннями стандартної непевності параметра положення в обох методах трохи більша, а саме:

- для розподілу Лапласа: 4,5 % ( $n=21$ ), 2,6 % ( $n=41$ ), 0,3 % ( $n=61$ );
- для нормального: 4, 6 % ( $n=21$ ), 2,7 % ( $n=41$ ), 1,7 % ( $n=61$ );
- для типу арксинусоїдного: 12,5 % ( $n=21$ ), 4,9 % ( $n=41$ ), 11,7 % ( $n=61$ ).

Ці дані підтверджують ефективність запропонованого наближеного методу порядкових статистик.

1. *Guide of the Expression of Uncertainty in Measurement. International Organisation for Standardisation. – Switzerland, 1993, 1995. 2007. – S. 1–13.*
2. Lloyd E.H. *Least-squares estimation on location and scale parameters using order statistics. Biometrika, 39 (1952). 88.*
3. Downton F. *A note of ordered least-squares estimation // Biometrika, 40 (1953). – 457.*
4. Kendall M. G. and Stuart A. *The Advanced Theory of Statistics, Vol. 2. Charles Griffin and Co Ltd, London. – 3-d edition, 1973.*
5. Dorozhovets M. *Investigation of the Test Samples Method, Used for the Evaluation of Measurement Result and its Uncertainty. Proc. of Int. Conf. on Precision Measurement. TU Ilmenau. 08–12 Sept. 2008. 91–92.*
6. Дорожовець М. *Дослідження застосування зразкових вибірок для оцінювання результату вимірювання а його стандартної непевності // Відбір і обробка інформ. – 2008. – Вип. 28 (104).*
7. Dorozhovets M. *Metoda opracowania wyników obserwacji bazująca na ich porównaniu z próbkami referencyjnymi // Pomiar. Automatyka. Kontrola. 55 (2009), nr.9. – S. 754–757.*
8. Dorozhovets M., Kochan O. *Estimation of the best measurement result and its standard uncertainty by input observations processing using the method of reference samples based on order statistics // Proc. of the 5-th IEEE International Workshop on Intelligent Data Acquisition and Advanced Computing Systems: Technology and Applications. 21–23 September 2009, Rende (Cosenza), Italy. – 351–354.*
9. Fisz M. *Probability Theory and Mathematical Statistics. – John Willey & Sons, London, 1963.*