

УДК 6:004.8

## **ПОБУДОВА АВТОРЕГРЕСІЙНИХ МОДЕЛЕЙ НА ОСНОВІ КОМБІНАТОРНО-ГЕНЕТИЧНОГО АЛГОРИТМУ**

О.Г.Мороз

*Міжнародний науково-навчальний центр інформаційних технологій  
та систем (МННЦ ІТС)НАН та МОН України,*

*olhahryhmoroz@gmail.com*

Розроблено теоретичні основи перебірної гібридної алгоритму КОМБІ-ГА для моделювання складних процесів у класі авторегресійних моделей. Ефективність розробленого алгоритму продемонстровано на тестових задачах моделювання.

*Ключові слова:* індуктивне моделювання, МГУА, перебірні алгоритми, генетичні алгоритми, алгоритм КОМБІ-ГА, модель авторегресії.

The theoretical foundations of a COMBI-GA hybrid algorithm for complex process modeling in the autoregressive models class have been developed. The effectiveness of the developed algorithm is demonstrated by a test modeling tasks.

*Keywords:* inductive modeling, GMDH, sorting-out algorithms, genetic algorithm, COMBI-GA algorithm, autoregressive model.

Разработаны теоретические основы переборного гибридного алгоритма КОМБИ-ГА для моделирования сложных объектов в классе авторегрессионных моделей. Эффективность разработанного алгоритма продемонстрирована на тестовых задачах моделирования.

*Ключевые слова:* индуктивное моделирование, МГУА, переборные алгоритмы, генетические алгоритмы, алгоритм КОМБИ-ГА, модель авторегрессии.

### **Вступ**

Загальну модель авторегресії – ковзного середнього (autoregression-moving-average models, ARMA), частковим випадком якої є модель авторегресії (Autoregression, AR [1]), було описано в 1951 році в дисертації Пітера Уїтгла «Перевірка гіпотез в аналізі часових рядів» і популяризовано в книзі Джорджа Боксата Гвилима Дженкінса в 1970 році.

Будується ARMA за стаціонарними часовими рядами. Це система рівнянь, в якій кожна змінна (компонента багатовимірного часового ряду) в даний момент часу є лінійною комбінацією всіх змінних у попередні моменти. Порядок такої моделі визначається порядком запізнюваних значень (лагів).

Авторегресійна модель використовується також для побудови залежності окремо взятої змінної від самої себе, вірніше від того, якою вона була в минулі періоди (день, місяць, рік тощо). Можна припустити практично для будь-якого показника, що його поточний рівень в якійсь мірі залежить від того який він був раніше, тобто значення досліджуваного процесу виражається через скінченну лінійну сукупність попередніх значень процесу і деякої похибки. Саме пошук цієї залежності часто дозволяє будувати досить точні моделі, за якими можна зробити прогноз. Така модель використовується в багатьох економічних та фінансових задачах, де необхідно прогнозувати різні показники, наприклад, прогнозування значень ВВП, обсягу продажів товарів на підприємстві, вартості цінних паперів тощо, а також для опису стаціонарних часових рядів різної природи.

Одними з найбільш ефективних засобів для побудови моделі за експериментальними даними є алгоритми на основі методу групового урахування аргументів (МГУА) [2], які поділяються на дві групи: ітераційні та перебірні алгоритми. Серед перебірних алгоритмів індуктивного моделювання ефективним та перспективним є гібридний комбінаторно-генетичний алгоритм КОМБІ-ГА [3], який одночасно поєднує основні переваги та усуває недоліки комбінаторного алгоритму МГУА (КОМБІ) [4] та генетичного алгоритму(ГА) [5]. У роботах [3,6,7] цей алгоритм успішно застосовано для побудови лінійних та нелінійних моделей тестових і реальних статичних об'єктів у лінійному за параметрами класі.

В [8] прогнозування складних процесів у класі моделей векторної авторегресії на основі рекурентно-паралельного алгоритму.

В цій роботі алгоритм КОМБІ-ГА вперше застосовується для моделювання динамічних процесів за допомогою авторегресійної моделі на тестових даних.

## 1 Модифікація алгоритму КОМБІ-ГА для побудови авторегресійної моделі

Початковим етапом роботи алгоритму КОМБІ-ГА для розв'язання задачі індуктивного моделювання [2] є її зведення до задачі, лінійної за параметрами, введенням узагальнених «лінійних» аргументів. Спосіб формування цих аргументів залежить від класу функцій, в якому моделюється процес чи об'єкт. Так, наприклад, при моделюванні у лінійному класі алгоритм не потребує додаткових перетворень (початкові змінні є вхідними, тобто тими, з якими працює алгоритм) [3], при моделюванні нелінійних об'єктів необхідно здійснити відповідне перетворення початкових змінних [6].

Розглянемо процедуру лінеаризації для побудови авторегресійної моделі. В загальному випадку авторегресійна або різницева модель порядку  $L$  є такою:

$$z_k = f(z_{k-1}, z_{k-2}, \dots, z_{k-L}, \theta) = \theta_1 z_{k-1} + \dots + \theta_L z_{k-L} = \sum_{j=1}^L \theta_j z_{k-j}, k=L+1, L+2, \dots, N,$$

де  $\theta_j$  – коефіцієнти авторегресії, тобто оцінювані параметри, які описують ступінь залежності формальної «вихідної» змінної  $z$  від впливаючих факторів, в даному разі від її значень в минулі періоди регресії;

$z_1, \dots, z_L$  – задані початкові значення (початкові умови цієї різницевої моделі);

$z_{k-j}, j=1, \dots, L$  – попередні значення часового ряду як фактори впливу на поточні значення  $z_k$ ;

$z_k$  – формальна «залежна» змінна в моменти часу  $k = 1, \dots, N$ .

Нехай наявні початкові дані – це вектор-стовпець  $z = [z_1, z_2, \dots, z_N]^T$ , що містить  $N$  значень часового ряду. Припускаємо, що цей часовий ряд описується авторегресійною моделлю невідомого порядку  $L$  з невідомим складом попередніх (запізнюваних) значень цього часового ряду та з невідомими параметрами. Задача полягає у знаходженні оптимальної структури моделі та оцінки її параметрів. Оцінювання параметрів авторегресії в цьому випадку здійснюється аналогічно оцінюванню параметрів множинної лінійної регресії.

Ввівши узагальнені вектори аргументів

$$x_j = [z_{L-j+1} \quad z_{L-j+2} \quad \dots \quad z_{N-j}]^T, \quad j = 1, \dots, L,$$

одержимо матрицю  $X[n \times m]$  еквівалентних вхідних аргументів та відповідний вихідний вектор  $y[n \times 1]$ , де  $n = N - L$ ,  $m = L$ :

$$X = [x_1 \quad x_2 \quad \dots \quad x_m] = \begin{bmatrix} z_L & z_{L-1} & \dots & z_1 \\ z_{L+1} & z_L & \dots & z_2 \\ \dots & \dots & \dots & \dots \\ z_{N-1} & z_{N-2} & \dots & z_{N-L} \end{bmatrix}, \quad y = \begin{bmatrix} y_1 \\ y_2 \\ \dots \\ y_n \end{bmatrix} = \begin{bmatrix} z_{L+1} \\ z_{L+2} \\ \dots \\ z_N \end{bmatrix}.$$

Взагалі кажучи, до таким чином перетворених початкових даних можна формально застосовувати будь-який алгоритм МГУА. Зокрема, відповідна модифікація алгоритму КОМБІ-ГА дозволяє розв'язувати за його допомогою задачі моделювання динаміки процесів, заданих у формі часових рядів.

Якщо  $k$  – період прогнозування, індекс точки прогнозу  $k=N+1, \dots, N+k$  та задано початкові умови  $k=N-L+1, N, \dots, N$ , то решта  $N+1 \dots N+k$  обчислюються за формулою:

$$\hat{y}_{N+p} = \theta_1 y_{L+p-1} + \dots + \theta_L y_p, \quad p=1, 2, \dots, k$$

Оригінальність побудови моделей за алгоритмом КОМБІ-ГА у вказаному класі полягає в тому, що знаходиться не тільки оптимальний порядок авторегресії, але й оптимальний склад запізнюваних (лагових) змінних цієї моделі. Тим самим виявляються приховані внутрішні закономірності інерційних ефектів післядії в цьому процесі, що підвищує прогнозні можливості такої моделі.

## 2 Тестування ефективності модифікованого алгоритму КОМБІ-ГА

**Опис початкових даних.** Нехай вектор-стовпець початкових даних має розмірність  $N = 60$ , тобто  $z[60 \times 1]$ , а порядок авторегресії  $L = 10$  випадково згенерованих значень, відповідно перетворена матриця  $X$  матиме розмірність  $[50 \times 10]$ , а вектор  $y[50 \times 1]$ . Щоб згенерувати тестові дані для перевірки коректності роботи модифікованого алгоритму в задачі побудови моделі авторегресії, слід задати перші 10 значень вектора  $z$  (вони ж будуть у першому рядку матриці  $X$ ), які визначають порядок авторегресії  $L$  – в даному разі ми використали випадково згенеровані числа в інтервалі  $[-5, 5]$ . Після цього, використовуючи задану тестову «істинну» модель авторегресії, розраховуються 50 точних значень виходу тестової моделі.

Авторегресійні моделі будувалися алгоритмом КОМБІ-ГА з еволюційним ускладненням структур моделей [3] з модифікацією для побудови авторегресійних моделей для збіжного і розбіжного часового ряду з шумом та без нього.

**Побудова моделі для збіжного ряду.** Шукана тестова модель за відсутності шуму має 5 «істинних аргументів», тобто окремих запізнюваних значень з усіх 10 можливих:

$$y = -0.2x_1 - 0.1x_4 + 0.5x_7 + 0.4x_8 + 0.3x_{10}$$

Матрицю  $X$  перетворених початкових даних у векторі  $z$  подано в Табл. 1.

Табл. 1. Матриця  $X$  перетворених початкових даних у векторі  $z$

Номер точки	$x_1$	$x_1$	$x_2$	$x_3$	$x_4$	$x_5$	$x_6$	$x_7$	$x_8$	$x_9$
1	2.4	-1.3	-0.6	-2.2	-0.6	-4.9	-0.5	-4.1	0.7	1.9
2	-1.3	-0.6	-2.2	-0.6	-4.9	-0.5	-4.1	0.7	1.9	-1.6
3	-0.6	-2.2	-0.6	-4.9	-0.5	-4.1	0.7	1.9	-1.6	-1.9
...	...	...	...	...	...	...	...	...	...	...
49	0.2	0.2	-0.1	-0.1	0.4	0.1	-0.1	-0.1	-0.01	0.01
50	0.2	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.01	0.01	-0.1

На Рис. 1. представлено порівняння значень точного часового ряду, модельного із зашумленим вектором  $u$  та модельним із зашумленим вектором  $z$ . З нього видно, що повне зашумлення має більший вплив на процес.

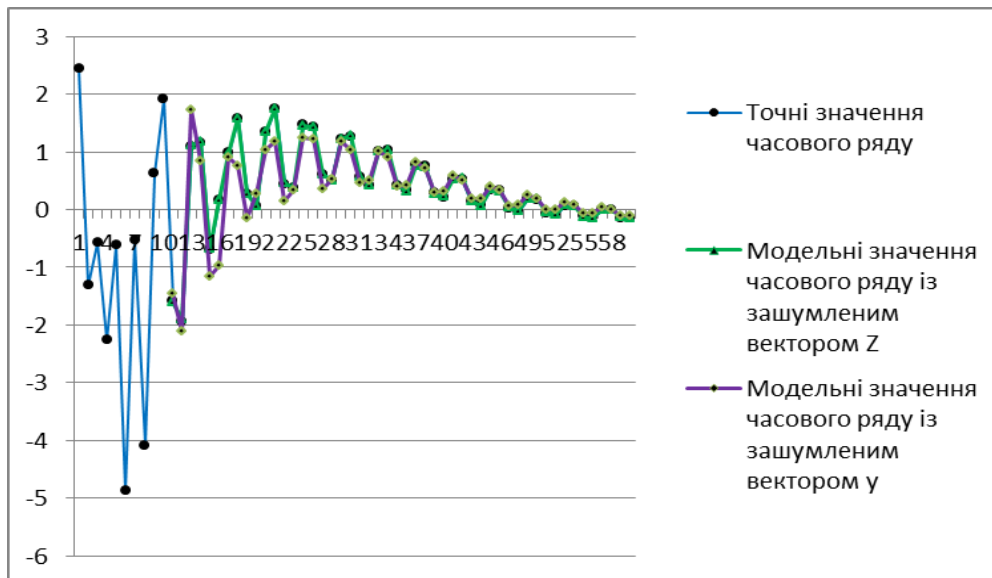


Рис. 1 Значення часового ряду: точні, модельні з зашумленим вектором  $u$ , модельні з зашумленим вектором  $z$ .

Враховуючи специфіку задачі при побудові моделі в авторегресійному класі, що полягає у наявності залежності між значеннями початкової змінної  $z_i, i=L+1, \dots, N$  та відповідно між елементами матриці  $X_i$  вектора  $u$  традиційний спосіб зашумлення даних набуває некоректного характеру. Надалі для більш коректних експериментів було здійснено зашумлення усього вектора початкових даних  $z$ , а не лише формальної «вихідної» змінної  $u$ , одержаної після перетворення.

Комбінаторно-генетичним алгоритмом було отримано модель:

$$y = -0.193x_1 - 0.117x_4 + 0.524x_7 + 0.413x_8 + 0.327x_{10}$$

Результат, отриманий алгоритмом КОМБІ-ГА при наявності шуму 30% у перетвореному векторі вихідної змінної у спрощує складність моделі з втратою точності у коефіцієнтах при значущих аргументах  $x_1, x_8, x_{10}$ :

$$y = -0.144 x_1 + 0.601 x_8 + 0.73 x_{10}$$

На Рис.2 представлено графік зашумленого збіжного ряду, який загалом зберігає характер істинного процесу.

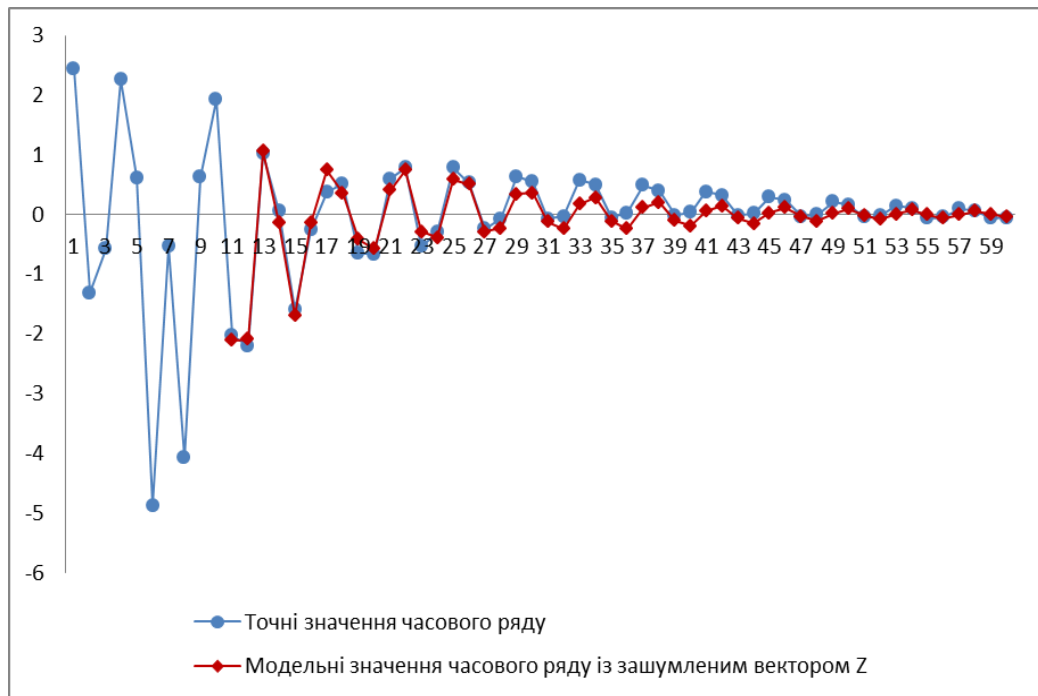


Рис. 2. Значення часового ряду: точні, модельні з зашумленим вектором Z.

**Побудова моделі для розбіжного ряду.** У чисельному експерименті за відсутності шуму тестова модель має 5 «істинних аргументів», тобто окремих запізнюваних значень з усіх 10 можливих:

$$y = -0.3x_1 + 0.9x_3 + 0.5x_5 + 0.6x_7 - 0.3x_9$$

Комбінаторно-генетичний алгоритм знайшов модель:

$$y = -0.312x_1 + 0.886 x_3 + 0.502x_5 + 0.624x_7 - 0.311x_9$$

При зашумленні усього вектора початкових даних  $z$ , алгоритм КОМБІ-ГА зменшує складність моделі:

$$y = -0.569 x_1 + 0.545 x_7$$

Ступінь зашумленості початкових даних візуалізована на Рис.3. На Рис.4 показано незначна різниця між точним і модельним значенням часового ряду без шуму.

Модель за зашумленими даними розбіжного процесу хоч і неточна, але зберігає розбіжний характер, що представлено на Рис.5.

Для перевірки достовірності результату роботи адгоритму було здійснено порівняння знайдених ним оптимальних моделей з результатом повного перебору варіантів частинних моделей комбінаторним алгоритмом при чому для всіх випадків результати КОМБІ та КОМБІ-ГА співпадали.




Рис. 3. Значення часового ряду: точні, зашумлені.




Рис. 4. Значення часового ряду: точні, модельні.



Рис. 5. Значення часового ряду: точні, модельні з зашумленим вектором  $z$ .

## Висновки

При розв'язанні тестової задачі індуктивного моделювання як зі збіжним так і розбіжним часовим рядом алгоритмами КОМБІ та КОМБІ-ГА у авторегресійному класі було отримано однакові оптимальні моделі як з шумом, так і без нього при малих часових витратах та вимог до вхідних даних. КОМБІ-ГА знаходив модель більш ніж у 2 рази швидше.

При наявності шуму 30% у векторі  $z$  початкових змінних оптимальні моделі для обох рядів спрощувалися. Побудована КОМБІ-ГА модель розбіжного часового ряду втратила більше істинних значень, тому застосування авторегресії при невеликому рівні шуму є доцільним. Точність відтворення істинного процесу в авторегресійному класі сильно залежить від рівня шуму через наявність залежності між значеннями початкового вектору.

Проведені тестові експерименти показують, що алгоритм КОМБІ-ГА можна ефективно використовувати при розв'язанні задач індуктивного моделювання в авторегресійному класі навіть у випадку зашумлених даних  $i$ , отже, доцільним є його використання при розв'язанні задач з реальними даними.

## Література

- [1] Льюнг Л. Идентификация систем. Теория для пользователей. М.: Наука, 1991. 492 с.
- [2] Ивахненко А.Г., Степашко В.С. Помехоустойчивость моделирования. Киев: Наукова думка, 1985. 216

[3] Moroz O., Stepashko V. Hybrid Sorting-Out Algorithm COMBI-GA with Evolutionary Growth of Model Complexity / N. Shakhovska, V. Stepashko. *Advances in Intelligent Systems and Computing II* Editors, AISC book series. Vol. 689. Cham: Springer, 2017. P. 346–360.

[4] Степашко В.С., Єфіменко С.М., Савченко Є.А. Комп'ютерний експеримент в індуктивному моделюванні. Київ: Наукова думка, 2014. 222 с.

[5] Мороз О.Г. Аналіз застосування генетичних алгоритмів у задачах глобальної оптимізації. *Управляющие системы и машины*. 2018. № 2. С. 73–79.

[6] Мороз О.Г., Степашко В.С. Тестування комбінаторно-генетичного алгоритму в задачі пошуку оптимальної нелінійної моделі. Міжнародна наукова конференція «Інтелектуальні системи прийняття рішень і проблеми обчислювального інтелекту». Залізний Порт, 2018. С. 256–258.

[7] Moroz O. Stepashko V. Data reconstruction of seasonal changes of amyolytic microorganisms amount in copper polluted soils. *Proceedings of the XIII IEEE International Conference CSIT-2018 & International Workshop on Inductive Modeling*. Lviv, Ukraine, 2018. P. 492–495.

[8] Єфіменко С.М. Прогнозування складних процесів у класі моделей векторної авторегресії на основі рекурентно-паралельного алгоритму COMBI МГУА. Індуктивне моделювання складних систем: Зб. наук. пр. К.: МННЦ ІТС НАН та МОН України, 2015. Вип. 7. С. 129–139.