

## КОМПАКТНЫЙ ГЕНЕТИЧЕСКИЙ АЛГОРИТМ ВЫБОРА РАЗМЕРА ОКОН ПРИ НЕЙРОСЕТЕВОМ ПРОГНОЗИРОВАНИИ ВРЕМЕННЫХ РЯДОВ

**Государственный университет информатики и искусственного интеллекта  
(Украина, Донецк)**

*Рассмотрена задача предобработки данных для прогнозирования временных рядов с помощью многослойных нейронных сетей. Предложен компактный генетический алгоритм определения размера окон для построения обучающей выборки. Описан способ кодирования хромосом, разработана фитнес-функция и способы остановки генетического алгоритма. Приведено численное сравнение результатов прогнозирования различных типов временных рядов с помощью известных методов и нейросетевого прогнозирования с использованием разработанного алгоритма, подтвердившее эффективность применения предложенного подхода.*

### **Введение.**

Принятие эффективных решений современных задач невозможно без получения информации о будущем, т.е. без прогнозирования. Исходными данными для построения прогноза являются временные ряды, описывающие поведение случайной величины (объекта прогнозирования) на некотором временном интервале. Если объект прогнозирования описывается одним параметром, то выполняется однорядное прогнозирование, если несколькими – многорядное [1].

На сегодняшний день разработано значительное количество методов прогнозирования, каждый из которых можно отнести к одной из двух групп [2]:

- 1) методы экспертных оценок;
- 2) вероятностные методы.

Методы экспертных оценок основаны на субъективной оценке экспертом текущего состояния объекта и перспектив его развития, а, значит, могут обладать низкой достоверностью получаемых результатов [3]. Применяются эти методы только в случаях большой неопределенности в параметрах объекта или дефиците времени на составление прогноза. Методы экспертных оценок включают в себя методы “комиссий”, “коллективной генерации идей” (мозговая атака), “Дельфи”, матричный метод и другие.

Вероятностные методы основаны на поисках закономерностей во временных рядах большого размера, их эффективность существенно снижается при зашумленности, коррелированности и пропусках в данных [5]. К вероятностным методам прогнозирования относятся следующие группы:

- методы экстраполяции;
- методы средних и скользящих средних;
- методы Хольта и Брауна;
- метод Винтерса;
- регрессионные и нейросетевые методы прогнозирования.

Среди этих методов наиболее эффективными являются нейросетевые методы, использующие многослойные нейронные сети персептронного типа с обучением по алгоритму обратного распространения ошибки [6, 7].

В качестве критерия оценки качества прогнозирования может использоваться горизонт прогнозирования – число периодов прогноза, для которых прогноз действителен с заданной точностью [1]. Под точностью понимается разность между реальными значениями и результатом прогноза.

Одним из наиболее важных этапов обучения нейронной сети для построения прогнозов временных рядов является формирование обучающей выборки по исходным данным [5, 8, 9]. Для обучения нейронной сети должна быть задана обучающая выборка, содержащая две группы данных:

входные данные и требуемые (эталонные) результаты выходов [8].

Формирование обучающей выборки из временного ряда традиционно выполняется с использованием «метода скользящих окон», основанного на теореме Рюэля - Такенса [10]. Согласно этому методу два окна заданного размера перемещаются вдоль временного ряда с некоторым шагом  $S$ . Объекты, попавшие в первое (входное) окно будут соответствовать признакам объекта обучающей выборки ( входы нейронной сети). Объекты, попавшие во второе (выходное) окно, – требуемым (эталонным) значениям выходов нейронной сети. Каждый следующий объект выборки получается путем сдвига окон по временному ряду слева направо.

Очевидно, что размер окон оказывает существенное влияние на обучающую выборку, а, значит, на результаты обучения нейронной сети и качество прогнозирования. Выбор большого размера входного окна приведет к уменьшению количества объектов обучающей выборки, что ухудшит качество обучения. Выбор малого размера входного окна не позволит нейронной сети установить внутренние зависимости между данными временного ряда. Выбор размера выходного окна зависит от требуемого количества прогнозируемых значений, однако это количество может быть также достигнуто, например, уменьшением выходного окна в два раза и выполнением двух шагов прогнозирования.

При выполнении многорядного прогнозирования данные каждого ряда имеют свою специфику, поэтому необходимость установления для каждого из них собственного размера окон также является очевидной.

**Целью работы** является создание метода выбора размера окон для формирования обучающей выборки при нейросетевом прогнозировании временных рядов.

## Генетический алгоритм выбора размера окон для формирования обучающей выборки

Задача определения размера окон является оптимизационной задачей, поэтому для её решения в данной работе предлагается использовать генетические алгоритмы – одну из наиболее эффективных современных технологий решения оптимизационных задач и задач комбинаторного типа.

Для задачи выбора размера окон при однорядном прогнозировании хромосома генетического алгоритма будет состоять из двух генов:  $X = \{X_1, X_2\}$ , где  $X_1$  - размер входного окна,  $X_2$  - выходного. Поскольку интервал принимаемых значений для  $X_1$  и  $X_2$  достаточно мал (для временного ряда размером 1000 элементов входное окно будет содержать не более 50 элементов), то в генетическом алгоритме предлагается использовать двоичное кодирование генов.

Тогда хромосома генетического алгоритма будет иметь вид:

$$X = \{x_{11}, \dots, x_{1n_1}, x_{21}, \dots, x_{2n_2}\}.$$

В качестве фитнес-функции генетического алгоритма могут использоваться критерии оценки качества прогнозирования временного ряда:

- абсолютная ошибка прогнозирования  $E_a = |y_t - y_k|$ , где  $y_t$  - наблюдаемое значение в момент времени  $t$ ,  $y_k$  - результат прогнозирования;

- относительная ошибка прогнозирования  $E_o = \frac{100\% \cdot |y_t - y_k|}{y_t}$ .

В работе в качестве фитнесфункции используется относительная ошибка прогнозирования, поскольку она не зависит от размерности прогнозируемых величин. Для  $k$  прогнозируемых значений временного ряда фитнес-функция будет рассчитываться по формуле:

$$FF = \frac{\sum_{i=1}^k \frac{100\% \cdot |(y_t)_i - (y_k)_i|}{(y_t)_i}}{k}.$$

Для решения оптимизационных задач и задач комбинаторного типа, решения которых представимы бинарными векторами традиционно используется простой генетический алгоритм, в котором на каждой итерации генерируется популяция хромосом и с помощью генетических операторов генерируются хромосомы-потомки. Решаемая в данной работе задача характеризуется большим объемом вычислений при расчете фитнесс-функций хромосом и относительно небольшим количеством возможных решений. Для таких задач в последнее время используются компактные генетические алгоритмы [11]. Особенностью компактных алгоритмов является использование на каждом шаге итерации только двух случайно сгенерированных хромосом и, как следствие, отсутствие популяции хромосом и генетических операторов селекции и кроссинговера. В работе используется модель *PBIL* (*Population-Based Incremental Learning*) компактных генетических алгоритмов. Процесс работы этого алгоритма сводится к генерации пар хромосом, определении хромосомы – «победителя» на основе фитнессфункции и корректировке вектора вероятностей, устанавливающего частоту появления гена «1» в соответствующей позиции при бинарном кодировании хромосом.

Решение задачи представляется вектором вероятностей, равным по размеру длине хромосом

$$P = \{p_{11}, \dots, p_{1n_1}, p_{21}, \dots, p_{2n_2}\}.$$

На начальном этапе осуществляется инициализация вектора  $P$ , которая заключается в присваивании

$$p_{ij} = 0,5; i = 1, 2; j = \overline{1, n}.$$

Далее на каждой итерации алгоритма выполняется:

1) генерация пары хромосом  $X_1$  и  $X_2$  случайным образом пропорционально текущим вероятностям вектора  $P$ ;

2) расчет фитнесс-функций  $FF(X_1)$  и  $FF(X_2)$ ;

3) выбор лучшей по фитнесс-функции хромосомы:

$$s = \max(FF(X_1), FF(X_2));$$

4) изменение вектора вероятностей  $P$  путем приращения некоторого малого значения к вероятности  $p_{ij}$ , если соответствующий ген лучшей хромосомы  $X_s$  равен единице  $x_{ij} = 1$ , и уменьшения вероятности  $p_{ij}$  на ту же величину, если соответствующий ген лучшей хромосомы  $X_s$  равен нулю  $x_{ij} = 0$ ;

5) мутация вектора вероятностей  $P$ , заключающаяся в изменении некоторых случайно выбранных элементов этого вектора на малую случайную величину.

В [11] в качестве критерия остановки алгоритма предлагается ограничение по количеству итераций. Тогда результатом работы компактного генетического алгоритма является вектор, полученный в результате округления элементов вектора  $P$ , полученного после последней выполненной итерации. Такой подход позволяет решить проблему зацикливания алгоритма, однако неверный выбор количества итераций может привести к ухудшению качества результатов его работы.

Для решения этой проблемы в работе предложена модификация компактного генетического алгоритма модели PBIL, которая состоит в следующем. Если после выполнения очередной итерации алгоритма некоторый элемент вектора вероятностей  $P$  равен нулю  $p_{ij} = 0$  или единице  $p_{ij} = 1$ , то этот элемент фиксируется и в дальнейшем не изменяется. Алгоритм заканчивает свою работу, если все элементы вектора вероятностей зафиксированы или достигнута максимально возможная итерация (в этом случае все незафиксированные вероятности округляются).

Для решения задачи многорядного прогнозирования предлагается использовать двумерную матрицу вероятностей и двоич-

ную матрицу для представления хромосом компактного генетического алгоритма.

### **Результаты экспериментальных исследований**

Для анализа эффективности разработанного генетического алгоритма был проведен ряд экспериментальных исследований на временных рядах. Были реализованы известные методы прогнозирования временных рядов: линейный прогноз, усреднение с постоянным и скользящим средним, аддитивная и мультипликативная модели среднего темпа, нейронная сеть персептронного типа с обучением по алгоритму обратного распространения ошибки и формированием обучающей выборки по «методу скользящих окон». А также предлагаемый в работе нейросетевой метод прогнозирования с генетическим алгоритмом формирования обучающей выборки. Для анализа

использовались четыре типа временных рядов:

- 1) возрастающий ряд тестовых данных;
- 2) убывающий ряд тестовых данных;
- 3) периодический ряд тестовых данных;
- 4) временные ряды реальных данных.

В качестве реальных данных использовались данные об объемах еженедельных продаж бензина различных марок в сети АЗС.

Для увеличения точности получаемых результатов во всех экспериментах использовалось по 10 временных рядов длиной 50 – 150 значений, а результаты усреднялись. Для нейросетевого прогнозирования использовалась трехслойная нейронная сеть с обучением по алгоритму обратного распространения ошибки с 80 нейронами в скрытом слое, сигмоидальной и линейной на выходном слое активационными функциями и коэффициентом обучения 0,01.

Результаты прогнозирования периодического ряда приведены на рис. 1.

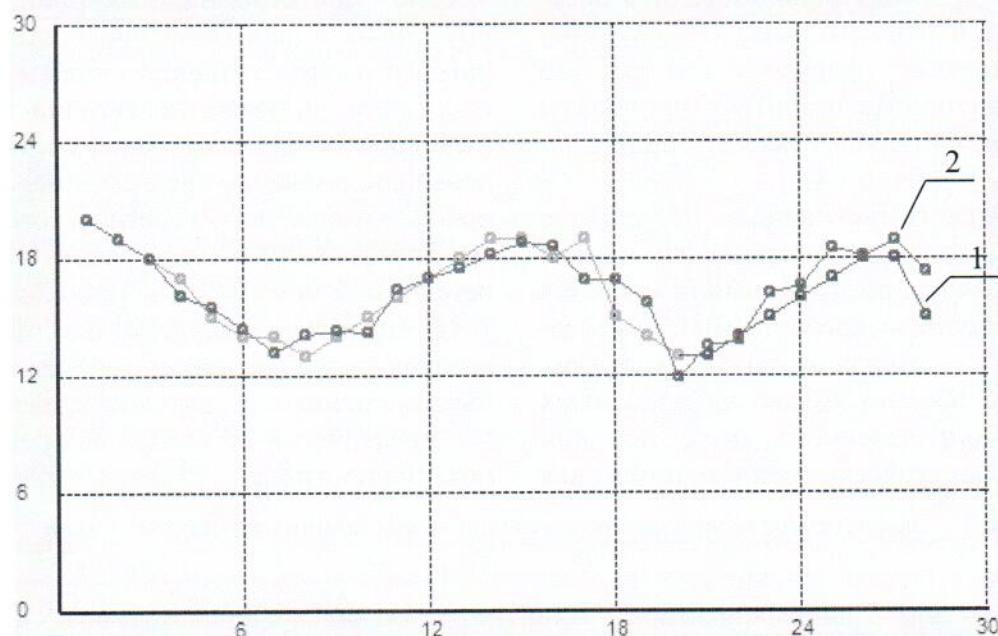


Рис.1 – Результаты прогнозирования периодического ряда  
1 – ряд исходных данных; 2 – результат прогнозирования с использованием нейронных сетей

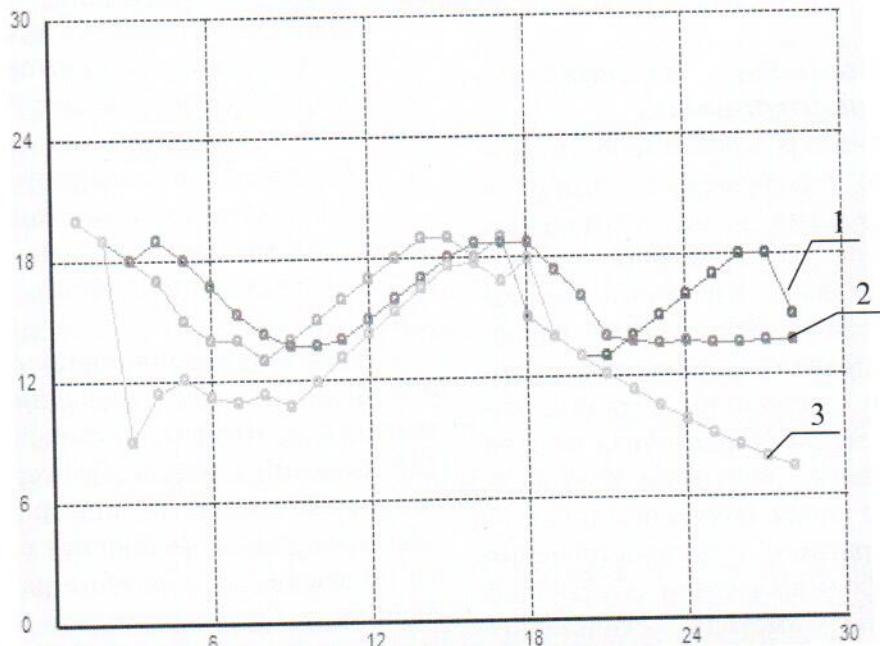


Рис.2 – Результаты прогнозирования периодического ряда

1 – ряд исходных данных; 2 – метод усреднения со скользящим средним; 3 - мультипликативная модель среднего темпа

В качестве критериев оценки качества прогноза использовались абсолютная и относительная ошибки прогнозирования, формулы для расчета которых приведены выше. Результаты экспериментальных исследований приведены в табл. 1 – 4.

Анализ полученных результатов показывает, что большинство известных методы прогнозирования являются «узкоспециализированными методами», т.е. позволяют получить эффективный прогноз только на временных рядах определенного типа, но, при этом, практически неприменимы для

других типов рядов. Прогнозирование с помощью многослойных нейронных сетей, обученных с использованием алгоритма обратного распространения ошибки позволяет в среднем получить достаточно эффективный прогноз для всех типов временных рядов. Использование предложенного в данной работе компактного генетического алгоритма позволяет улучшить работу нейронных сетей более чем на 2,5%. Необходимо отметить, что использование компактной модели генетического алгоритма требует минимальных временных и вычислительных затрат, т.е. практически не влияет на время формирования прогноза..

Таблица 1 – Эффективность прогнозирования для возрастающих временных рядов

Метод	Ошибка	
	Абсолютная	Относительная
Линейный прогноз	2,24	2,72 %
Усреднение с постоянным средним	15,8	19,19 %
Усреднение со скользящим средним	6,11	7,4 %
Средний темп (аддитивная модель)	0,76	0,93 %
Средний темп (мультипликативная модель)	11,7	14,1 %
Нейронная сеть	7,06	8,55 %
Нейронная сеть с генетическим алгоритмом выбора размера окон	1,87	2,36%

Таблица 2 – Ефективність прогнозування для убываючих временных рядов

Метод	Ошибка	
	Абсолютна	Относительна
Лінейний прогноз	6,7	2,9 %
Усереднення з постійним середнім	82,82	33,58 %
Усереднення з скользящим середнім	28,47	11,73 %
Середній темп (аддитивна модель)	4,47	1,77 %
Середній темп (мультиплікативна модель)	33,71	13,75 %
Нейронна сеть	30,49	12,49 %
Нейронна сеть з генетичним алгоритмом вибору розміру окона	12,6	7,14%

Таблица 3 – Ефективність прогнозування для періодичних временных рядов

Метод	Ошибка	
	Абсолютна	Относительна
Лінейний прогноз	4,22	12,87 %
Усереднення з постійним середнім	6,68	24,27 %
Усереднення з скользящим середнім	5,23	16,23 %
Середній темп (аддитивна модель)	5,82	16,86 %
Середній темп (мультиплікативна модель)	8,81	26,79 %
Нейронна сеть	5,17	16,58 %
Нейронна сеть з генетичним алгоритмом вибору розміру окона	3,94	10,54%

Таблица 4 – Ефективність прогнозування на реальних даних

Метод	Ошибка	
	Абсолютна	Относительная
Лінейний прогноз	13,24	17,24%
Усереднення з постійним середнім	11,07	15,33%
Усереднення з скользящим середнім	9,94	13,75%
Середній темп (аддитивна модель)	9,46	13,02%
Середній темп (мультиплікативна модель)	10,74	14,26%
Нейронна сеть	7,64	9,76%
Нейронна сеть з генетичним алгоритмом вибору розміру окона	5,12	7,02%

## Выводы

В работе рассмотрена задача прогнозирования временных рядов. По результатам анализа существующих методов прогнозирования показано, что одним из наиболее важных этапов решения задачи прогнозирования является предобработка исходного временного ряда, которая для нейросетевого метода прогнозирования состоит в формировании обучающей выборки по «методу скользящих окон». Выяснено,

что задание размера окон без учета исходных данных может существенно ухудшать результат прогнозирования. Для решения этой проблемы в работе предложен компактный генетический алгоритм определения размера окон, позволяющий в процессе обучения нейронной сети выбирать оптимальные размеры входных и выходных окон для каждого из рядов прогнозирования. В экспериментах на тестовых данных (убывающих, возрастающих и периодических рядах) предложенный метод показал не наи-

лучший результат, однако в экспериментах на реальных данных предложенный подход позволил улучшить качество прогнозирования более чем на 2,5%. Такие результаты можно объяснить тем, что известные методы позволяют получать оптимальные результаты только на временных рядах определенного вида. На произвольных же рядах они показывают низкие результаты. Предложенный подход показал хорошие результаты на всех типах исходных данных, что делает его универсальным эффективным методом прогнозирования временных рядов.

В дальнейшем для данной задачи планируется переход к иерархическим генетическим алгоритмам, что позволит осуществлять оптимальный выбор не только размера окон, но и параметров нейронных сетей, алгоритмов их обучения и реализовывать каскадные модели прогнозирования.

### **Список литературы**

1. Рабочая книга по прогнозированию / Отв. ред. И.В. Бестужев - Лада. - М.: Мысль, 1982. – 430 с.
2. Гречин С.Б., Трифонов Ю.В. Применение генетического программирования для прогнозирования состояния предприятий // Вестник Нижегородского университета им. Н.И. Лобачевского, Серия: Экономика и финансы. – 2007. – № 5. – С. 130 – 133.
3. Бушуева Л.И. Методы прогнозирования объема продаж // Маркетинг в России и за рубежом. – 2002. – №1. – С. 15-29.
4. Кричевский М.Л. Интеллектуальные методы в менеджменте: Нейронные сети; Нечеткая логика; Генетические алгоритмы; Динамические системы. – СПб.: Питер, 2005. – 304 с.
5. Резниченко Е.В., Кочегурова Е.А. Методы краткосрочного прогнозирования финансовых рынков // Известия Томского политехнического университета. – 2007. – Т. 311, № 6. – С. 19 – 23.
6. Гнусов Ю.В., Ерохин А.Л. Использование нейросетевых методов для прогнозирования временных рядов // Искусственный интеллект. – 2002. – № 4. – С. 686 – 691.
7. Кузнецов А.А. Применение нейросетей для прогнозирования финансовых временных рядов // Научная сессия МИФИ-2001. – Т. 12 Компьютерные системы и технологии. Информационные системы и среды, технологии проектирования, электронный бизнес. – С. 95 - 96.
8. Хайкин С. Нейронные сети: полный курс. – М.: Вильямс, 2006. – 1104 с.
9. Крисилов В.А., Чумичкин К.В., Кондратюк А.В. Представление исходных данных в задачах нейросетевого прогнозирования // V Всероссийская науч.-техн. конф. «Нейроинформатика-2003»: Сб. науч. трудов. – Т.1. – Москва: МИФИ. – 2003. – С. 184-191.
10. Ruelle D. On the Nature of Turbulence / D. Ruelle, F. Takens // Commun. Math. Phys. – 1971. – Vol. 20. – P. 167 – 192.
11. G. Harik, F. Lobo and D. Goldberg. The Compact Genetic Algorithm // IEEE Transactions on Evolutionary Computation. – 1999. – № 3. – P. 287 – 309.