
СИСТЕМНЫЙ АНАЛИЗ, УПРАВЛЕНИЕ И ОБРАБОТКА ИНФОРМАЦИИ

УДК 004.855.5

СРАВНИТЕЛЬНЫЙ АНАЛИЗ ВАРИАНТОВ ОПТИМИЗАЦИИ ПРИ РАЗРАБОТКЕ МОДЕЛЕЙ ПРОГНОЗИРОВАНИЯ НА ОСНОВЕ СТРОГО БИНАРНЫХ ДЕРЕВЬЕВ¹

Статья поступила в редакцию 19.05.2016, в окончательном варианте 12.06.2016.

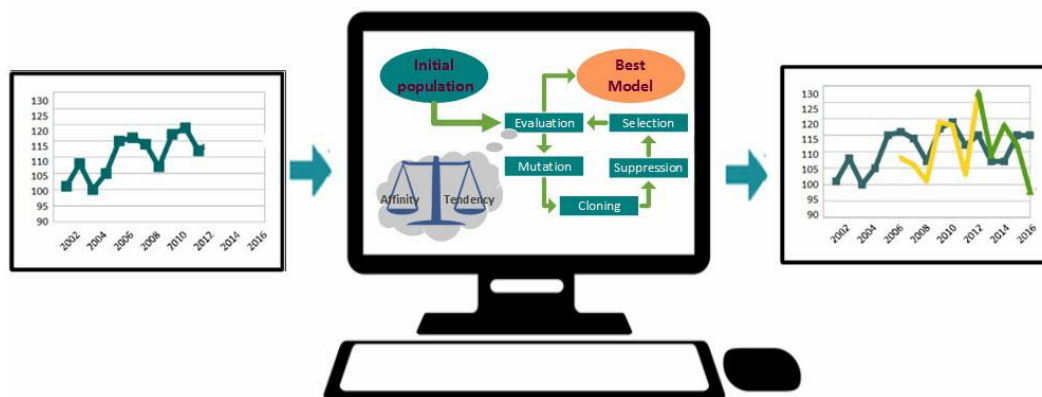
Астахова Надежда Николаевна, аспирант, Рязанский государственный радиотехнический университет, 390005, Российская Федерация, г. Рязань, ул. Гагарина, 59 / 1, e-mail: asnadya@yandex.ru

Демидова Лилия Анатольевна, доктор технических наук, профессор, Рязанский государственный радиотехнический университет, 390005, Российская Федерация, г. Рязань, ул. Гагарина, 59 / 1, e-mail: liliya.demidova@rambler.ru

Рассматривается задача оптимизации, возникающая при разработке моделей прогнозирования (МП) на основе строго бинарных деревьев (СБД). Целью работы является сравнительный анализ вариантов оптимизации, используемых при разработке МП на основе СБД. При этом первый вариант оптимизации предполагает применение одного показателя качества МП – показателя аффинитета, основанного на вычислении средней относительной ошибки прогнозирования. Второй вариант с использованием понятия «Парето-множество» реализует учет двух показателей качества МП: показателя аффинитета и показателя несовпадения тенденций. В обоих вариантах оптимизации поиск лучших МП осуществляется посредством применения модифицированного алгоритма клонального отбора. Для поддержания высокого разнообразия популяции МП предложено при реализации второго варианта оптимизации учитывать значения расстояния скученности МП. Приведены результаты экспериментальных исследований, подтверждающие эффективность использования модифицированного алгоритма клонального отбора на основе второго варианта оптимизации для разработки искомых МП.

Ключевые слова: временной ряд, модель прогнозирования, строго бинарное дерево, модифицированный алгоритм клонального отбора, вариант оптимизации, показатель аффинитета, показатель несовпадения тенденций, Парето-доминирование, расстояние скученности

Графическая аннотация (Graphical annotation)



¹ Работа поддержана грантом РФФИ, номер заявки 16-08-00771, тема «Интеллектуальные программно-математические средства индивидуального и группового прогнозирования временных рядов».

COMPARATIVE ANALYSIS OF THE OPTIMIZATION VARIANTS
FOR THE DEVELOPMENT OF THE FORECASTING MODELS
ON THE BASE OF THE STRICTLY BINARY TREES

Astakhova Nadezhda N., post-graduate student, Ryazan State Radio Engineering University, 59 / 1 Gagarin St., Ryazan, 390005, Russian Federation, e-mail: asnadya@yandex.ru

Demidova Liliya A., D.Sc. (Engineering), Professor, Ryazan State Radio Engineering University, 59 / 1 Gagarin St., Ryazan, 390005, Russian Federation, e-mail: liliya.demidova@rambler.ru

The optimization problem dealing with the development of the forecasting models on the base of strictly binary trees is considered. The aim of paper is comparative analysis of the optimization variants which are applied for the development of the forecasting models on the base of the strictly binary trees. A herewith the first optimization variant assumes the application of one quality indicator of the forecasting model – the affinity indicator based on the calculation of the average forecasting error rate, and the second variant realizes the account with use of the notion «Pareto-set» of two quality indicators of the forecasting model – the affinity indicator and an the indicator of the tendencies' discrepancy. In both optimization variant the search of the best forecasting models is carried out by means of application of the modified clonal selection algorithm. For maintenance of a high variety of population of the forecasting models it is offered to consider values of the crowding-distance of the forecasting models at the realization of the second optimization variant. The results of experimental studies confirming the use efficiency of the modified clonal selection algorithm on the base of the second optimization variant for the development of the required forecasting models are given.

Keywords: time series, forecasting model, strictly binary tree, modified clonal selection algorithm, optimization variant, affinity indicator, indicator of the tendencies' discrepancy, Pareto-dominance, crowding-distance

Введение. Инструментарий эффективного решения задач прогнозирования является важной компонентой средств поддержки принятия решений, особенно для задач управления сложными техническими и социально-экономическими системами. Несмотря на большое количество работ по этой тематике, некоторые группы методов, алгоритмов и моделей прогнозирования остаются исследованными недостаточно полно. Одну из таких групп образуют модели прогнозирования на основе СБД. В связи с этим целью настоящей статьи является сравнение возможных вариантов построения моделей прогнозирования на основе СБД.

Общая характеристика проблематики статьи. При решении задачи прогнозирования временных рядов (ВР) особое внимание уделяется вопросу выбора адекватной МП. В случае применения эволюционных алгоритмов оптимизации поиск такой МП обычно сводится к выбору «лучшей» модели с точки зрения какого-либо одного показателя качества (ПК) из популяции моделей. В качестве такого ПК может быть использован, например, показатель аффинитета, основанный на вычислении средней относительной ошибки прогнозирования, которая должна быть минимизирована.

При разработке МП на основе СБД и модифицированного алгоритма клонального отбора (МАКО) [1, 5, 6], показавших эффективность при решении задач краткосрочного прогнозирования ВР, основной принцип формирования МП заключается в представлении их в виде антител, закодированных с помощью случайно выбранных символов. Впоследствии антитела преобразуются в аналитические зависимости, применяемые для получения прогнозных значений ВР. Поиск искомой МП осуществляется в процессе итерационных вычислений. При этом на каждом шаге такого процесса выявляются «лучшие» антитела (и соответствующие им «лучшие» МП), которые на следующем шаге становятся родителями для нового поколения антител (и соответствующих им МП) [1, 2, 5–8, 15–17, 22, 23]. Очевидно, что правильный выбор «лучших» антител позволит обеспечить эффективность применения МАКО при разработке МП.

Обычно при разработке моделей краткосрочного прогнозирования ВР (в том числе моделей на основе СБД и МАКО) выполняется оценивание моделей с учетом одного ПК, например, показателя аффинитета [1, 2, 6–8, 15–17, 22, 23]. Однако использование только одного ПК далеко не всегда является достаточным для получения действительно лучшей МП. Зачастую целесообразно учитывать дополнительные ПК МП, позволяющие учесть соответствие сезонным тенденциям или тренду ВР; отсутствие выбросов; уровень сложности МП и т.п. [8]. Чаще всего не представляется возможным выбрать единственный ПК МП. Поэтому актуальной является проблема разработки подходов к созданию МП, при оценке качества которых одновременно учитывается несколько ПК.

При оценке качества МП на основе СБД и МАКО с целью повышения их эффективности при решении задачи краткосрочного прогнозирования, а также обеспечения возможности их применения при решении задачи среднесрочного прогнозирования, целесообразно дополнительно (наряду с ПК, основанным на вычислении средней относительной ошибки прогнозирования [8]) использовать ПК, который позволит оценить общую тенденцию изменения значений известных элементов ВР (например, показатель несовпадения тенденций ВР) [1].

В данной статье предполагается рассмотреть и исследовать два варианта оптимизации в контексте решения задачи разработки МП на основе СБД. При этом в первом варианте оптимизации будет использован один ПК МП – показатель аффинитета. Во втором варианте будет реализован учет двух ПК МП – показателя аффинитета и показателя несовпадения тенденций.

Теоретическая часть. В настоящее время известны и широко используются различные подходы к разработке МП ВР [13]. Модели, основанные на эволюционных алгоритмах оптимизации, в частности, на генетических алгоритмах (ГА) [11, 13] и алгоритмах клонального отбора (АКО) [2, 11, 13, 15] обеспечивают высокую точность прогнозов при приемлемых временных затратах. Такая эффективность объясняется использованием принципов естественного отбора, обеспечивающих посредством случайной генерации хромосом (антител) широкий горизонт покрытия множества допустимых решений, а также «выживаемость» лучших МП. В итоге многократных итерационных вычислений удается найти МП, наилучшим образом описывающую известные значения элементов ВР.

Так, например, МАКО, моделирующий законы функционирования естественной иммунной системы, обеспечивает формирование сложных аналитических зависимостей при разработке МП на основе СБД [2, 22]. В [1, 2, 22] приведено подробное описание МАКО, реализующего построение и отбор МП на основе СБД. При этом каждой МП соответствует некоторое антитело, которое интерпретируется в виде аналитической зависимости, применяемой для получения прогнозных значений ВР. В процессе реализации МАКО должна быть определена МП, наилучшим образом описывающая известные значения ВР и обеспечивающая получение минимального значения средней относительной ошибки прогнозирования (Average Forecasting Error Rate) *AFER* :

$$AFER = (100\% / (n - k)) \cdot \sum_{j=k+1}^n |(f^j - d^j) / d^j|, \quad (1)$$

где d^j и f^j – соответственно реальное (фактическое) и предсказанное значения для j -ого элемента ВР; n – количество элементов ВР.

В контексте работы с МАКО средняя относительная ошибка прогнозирования *AFER* [1, 5, 6] выступает в роли такого ПК МП как показатель аффинитета (affinity) *Aff* .

В МАКО в простейшем виде реализованы принципы распознавания антигенов с помощью антител. При этом для представления антигена *Ag* используются известные значения элементов прогнозируемого ВР, а в роли антитела *Ab* выступает некоторая аналитическая зависимость, определяющая МП. В качестве «лучшего» антитела *Ab* выбирается антитело, обеспечивающее минимальное значение показателя аффинитета *Aff* [1, 2, 22, 23].

Кодирование антитела *Ab* осуществляется посредством записи в строку символов, выбираемых из трёх символьных алфавитов [1, 22]: алфавита арифметических операций (операций сложения, вычитания, умножения и деления) – *Operation* = { '+', '-', '/', '}' ; алфавита функционалов *Functional* = { 'S', 'C', 'Q', 'L', 'E', '_' }, в котором символы 'S', 'C', 'Q', 'L', 'E' определяют математические функции «синус», «косинус», «квадратный корень», «натуральный логарифм», «экспонента», а символ '_' – отсутствие математической функции; алфавита терминалов *Terminal* = { 'a', 'b', ..., 'z', '?' }, в котором символы 'a', 'b', ..., 'z' определяют аргументы аналитической зависимости, а символ '?' – константу. При использовании указанных выше трёх символьных алфавитов удается обеспечить корректное преобразование случайным образом формируемых антител, структура которых может быть описана с помощью СБД, в аналитические зависимости [3, 5, 7, 11].

Количество символов из алфавита терминалов *Terminal* в антителе *Ab* определяет максимально возможный порядок K МП ($K \geq k$, где k – реальный порядок модели) [3, 5]. Если максимально возможный порядок МП равен K , то это означает, что на момент времени j при прогнозировании значения элемента d^j ВР могут использоваться K значений элементов ВР: $d^{j-K}, \dots, d^{j-2}, d^{j-1}$.

Для обеспечения высокой точности прогнозирования ВР со сложно формализуемым математическим законом при формировании антител используются СБД, структура которых аналогична тому, что приведено на рисунке 1 [1, 2, 22]. При этом искомое СБД получается в результате композиции одного «левого» поддерева максимально возможного порядка $K = 3$ и некоторого количества «правых» поддереьев максимально возможного порядка $K = 2$. В данном случае термины «левое» и «правое» поддерево используются для указания того, в какую ветвь (левую или в правую) некоторого уровня СБД следует включать новое поддерево [1, 22].

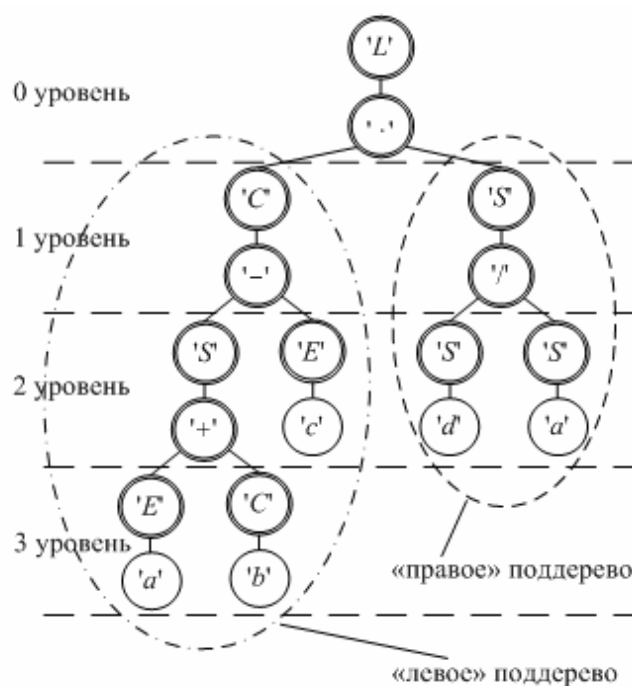


Рис. 1. Пример строго бинарного дерева

При формировании антитела целесообразно сначала реализовать разбиение СБД на поддерева. Далее выполнить обход вершин каждого поддерева с формированием упорядоченных списков символов, находящихся в его вершинах. Затем – последовательное объединение этих списков [22]. При формировании упорядоченного списка символов на основе поддерева осуществляется последовательный двукратный обход его вершин. При этом сначала при движении по поддереву «снизу-вверх» и «слева-направо» попарно обходятся вершины, содержащие символы из алфавита терминалов *Terminal*, и соответствующие им расположенные сверху вершины, содержащие символы из алфавита функционалов *Functional*. Затем при движении в том же направлении («снизу-вверх» и «слева-направо») попарно обходятся вершины, содержащие символы из алфавита арифметических операций *Operation*, и соответствующие им расположенные сверху вершины, содержащие символы из алфавита функционалов *Functional* [22].

Антитело (при движении по нему слева-направо) в качестве первых двух символов содержит пару символов нулевого уровня СБД из алфавита функционалов *Functional* и алфавита арифметических операций *Operation*. Затем в антителе располагаются списки символов, соответствующие «правым» поддереьям максимально возможного порядка $K = 2$ (при движении по СБД «сверху-вниз»), и, наконец, список символов, входящих в «левое» поддерево максимально возможного порядка $K = 3$ [22]. При использовании такого способа формирования антитела удастся обеспечить наглядность представления структуры СБД в виде объединения поддереьев. При этом само антитело легко интерпретируется в виде аналитической зависимости.

Так, антитело, сформированное на основе СБД, представленном на рисунке 1, кодируется строкой символов:

$$L \cdot S/SeSdC - S + EaCbEa. \quad (2)$$

При разработке МП k -ого порядка при $k = 4$ код антитела (2) с учетом упорядоченности символов a, b, c, d в алфавите терминалов *Terminal* может быть записан как:

$$f(d^{j-1}, d^{j-2}, d^{j-3}, d^{j-4}) = \ln(\cos(\sin(\exp(d^{j-1}) + \cos(d^{j-2})) - \exp(d^{j-3})) \cdot \sin(\sin(d^{j-4}) / \sin(d^{j-1}))). \quad (3)$$

МАКО, используемый для выбора «лучшего» антитела, определяющего «лучшую» аналитическую зависимость, включает в себя подготовительную часть, которая отвечает за формирование начальной популяции антител, и итерационную часть. В этой части последовательно реализуются следующие операции: упорядочение антител по возрастанию значений аффинитета *Aff*; отбор и клонирование части «лучших» антител (то есть антител с наименьшими значениями аффинитета *Aff*); гипермутация клонов антител; самоуничтожение клонов антител, «похожих» на другие клоны и антитела текущей популяции; вычисление аффинитета клонов антител и формирование новой популяции антител (которая становится текущей популяцией антител для очередной итерации); супрессия текущей популяции антител; генерация новых антител и добавление их к текущей популяции до получения ее исходного размера; проверка условия завершения работы МАКО. В работе [22] приведено подробное описание МАКО.

Как уже было отмечено выше, обычно качество МП на основе СБД и МАКО оценивается с помощью показателя аффинитета *Aff* по формуле (1). Для повышения эффективности данных МП при решении задачи краткосрочного прогнозирования и обеспечения возможности их применения при решении задачи среднесрочного прогнозирования при оценке качества моделей наряду с показателем аффинитета предлагается использовать еще один ПК – показатель несовпадения тенденций ВР *Tendency*. Он может быть вычислен как:

$$Tendency = h/(n - k - 1), \quad (4)$$

где h – количество отрицательных произведений $(f^{j-1} - f^j) \cdot (d^{j-1} - d^j)$ при $j = r + 2, n$; f^j и d^j – предсказанное и реальное значения ВР для j -го отсчета времени; n – количество элементов ВР; k – порядок модели; $n - k - 1$ – общее количество произведений $(f^{j-1} - f^j) \cdot (d^{j-1} - d^j)$.

Оба рассматриваемых ПК МП [*Aff* (1) и *Tendency* (4)] позволяют оценить сходство прогнозных значений известных элементов анализируемого ВР с реальными, но с применением разных принципов оценивания. Если показатель аффинитета *Aff* используется при реализации МАКО для оценки «приспособляемости» антитела *Ab* (и соответствующей ему МП) к антигену *Ag* (и соответствующему ему ВР), то показатель несовпадения тенденций *Tendency* позволяет оценить качество антитела *Ab* (и соответствующей ему МП) с учетом совпадения с трендом анализируемого ВР, соответствующего антигену *Ag*. При этом оба ПК должны быть минимизированы. То есть показатель аффинитета *Aff* оценивает, прежде всего, сходство и различие прогнозных и реальных значений известных элементов анализируемого ВР, а показатель несовпадения тенденций *Tendency* – сходство и различие направлений изменения прогнозных и реальных значений известных элементов анализируемого ВР. Это позволяет проанализировать тенденции изменения ВР, а также наличие сезонных колебаний. Таким образом, при разработке МП на основе СБД и МАКО очевидна целесообразность реализации одновременного учета при оценке качества МП наряду со значением показателя аффинитета *Aff* (1) еще и значения показателя несовпадения тенденций *Tendency* (4).

Использование дополнительного ПК позволит скорректировать направление поиска искомой МП, и, в итоге, сократить количество итераций для её определения. Для решения задачи одновременного учета двух ПК при разработке МП могут быть применены различные хорошо зарекомендовавшие себя подходы [4, 11–13]. При этом особо следует выделить подход, предполагающий использование тех

или иных алгоритмов многоцелевой оптимизации (МЦО) [12], в том числе эволюционных алгоритмов [9, 19], обеспечивающих решение проблемы учета нескольких целевых функций (критериев, ПК) при решении различных прикладных задач.

Наибольшее применение среди эволюционных алгоритмов МЦО в настоящее время находят ГА [19]. Следует также отметить наличие и АКО, предназначенных для решения задач МЦО [27, 33, 36]. Однако данные алгоритмы менее проработаны и, в своем большинстве, заимствуют принципы МЦО, заложенные в ГА. Возможность данного заимствования может быть объяснена многими сходными механизмами реализации эволюционного процесса в ГА и АКО.

На данный момент широко известны следующие ГА МЦО: VEGA (Vector Evaluated Genetic Algorithm) [29]; FFGA (Fonseca and Fleming's Genetic Algorithm) [28]; NPGA (Niche Pareto Genetic Algorithm) [32]; NSGA (Non-dominated Sorting Genetic Algorithm) [34]; NSGA-II (Non-dominated Sorting Genetic Algorithm-II) [24]; NSGA-III (Non-dominated Sorting Genetic Algorithm-III) [18]; SPEA (Strength Pareto Evolutionary Algorithm) [25].

В качестве наиболее известных АКО МЦО следует указать: MISA (Multiobjective Immune System Algorithm) [20]; MOIA (Multiobjective Immune Algorithm) [25]; MOCSA (Multiobjective Clonal Selection Algorithm) [21]; IDCMA (Immune Dominance Clonal Multiobjective Algorithm) [30]; ACSAMO (Adaptive Clonal Selection Algorithm for Multiobjective Optimization) [38]; CNMOIA (Constrained Nonlinear Multiobjective Optimization Immune Algorithm) [39]; NNIA (Nondominated Neighbor Immune Algorithm) [31].

В результате анализа работ, посвященных вопросам применения МЦО на основе эволюционных алгоритмов, в частности, ГА [18, 24–26, 28, 29, 32, 34] и АКО [20, 21, 25, 30, 31, 38, 39], было выявлено, что преобладающее большинство алгоритмов используют в своей реализации принципы Парето-доминирования. В связи с этим был сделан вывод о перспективности использования принципов Парето-доминирования при усовершенствовании МАКО, применяемого для отбора МП на основе СБД. С учетом особенностей решаемой задачи и вычислительных характеристик ГА и АКО МЦО было принято решение о целесообразности адаптации идей, заложенных в алгоритм NSGA-II.

В контексте решения задачи разработки МП на основе СБД и МАКО под решением следует понимать МП (и соответствующее ей антитело), а под целевой функцией – ПК модели. Используя понятие «Парето-доминирование», все МП можно разделить на доминируемые и недоминируемые.

Пусть $Q_{s,v}$ – значение v -ого ПК для S -ой МП; $v = \overline{1, V}$; $s = \overline{1, S}$; V – количество ПК МП; S – количество МП (например, в популяции, то есть размер популяции). Будем говорить, что S -ая МП доминируема Z -ой МП ($s = \overline{1, S}$; $z = \overline{1, S}$), если для всех значений v ($v = \overline{1, V}$) выполняется условие:

$$Q_{s,v} \geq Q_{z,v}, \quad (5)$$

при этом все v -ые ПК ($v = \overline{1, V}$) должны быть минимизированы.

Таким образом, S -ая МП является доминируемой, если существует Z -ая МП, которая не хуже S -ой МП по всем ПК. В противном случае, если такие Z -ые МП не существуют, то S -ая МП является недоминируемой.

Следует отметить, что в случае, когда какой-либо ПК должен быть максимизирован, он легко может быть преобразован к показателю, который необходимо минимизировать.

Для каждой S -ой МП ($s = \overline{1, S}$) вычисляется ранг R_s . Ранг S -ой МП равен количеству моделей в популяции, которые доминируют над S -ой МП. Так, если для некоторой МП ее значения ПК больше соответствующих значений ПК трех других МП или равны им, то ранг такой модели равен 3. Ранг R_s недоминируемой S -ой МП полагается равным нулю.

В случае, когда количество ПК МП равно 2 ($V = 2$), а $Q_{s,1} = Aff_s$, $Q_{s,2} = Tendency_s$, где Aff_s и $Tendency_s$ соответственно значения показателя аффинитета (1) и показателя несовпадения тенденций (4) для S -ой МП ($s = \overline{1, S}$), S -ая МП доминируема Z -ой МП ($s = \overline{1, S}$; $z = \overline{1, S}$), если выполняются условия:

$$Q_{s,1} \geq Q_{z,1} \text{ и } Q_{s,2} \geq Q_{z,2}, \text{ то есть } Aff_s \geq Aff_z \text{ и } Tendency_s \geq Tendency_z.$$

Для вычисления расстояний скученности τ_s ($s = \overline{1, S}$) для всех МП может быть использован алгоритм [19], включающий следующие шаги.

1. Вычислить ранг всех МП в популяции. Модели, имеющие одинаковые значения ранга, объединить в одну группу.

2. Для каждой группы моделей:

- отсортировать МП по возрастанию значений каждого ПК;
- принять в качестве значений расстояний скученности τ_s для самой первой и самой последней в списке сортировки (то есть при $s = 1$ и $s = G_w$) максимально возможное наперед заданное значение η_{max} ; все остальные расстояния скученности τ_s при $s = \overline{2, G_w - 1}$ положить равными нулю ($w = \overline{1, W}$; W – количество групп; G_w – количество моделей в W -ой группе);

• вычислить расстояние скученности τ_s как:

$$\tau_s = \sum_{v=1}^V [(Q_{s-1,v} - Q_{s+1,v}) / (Q_v^{max} - Q_v^{min})], \quad (6)$$

где $Q_{s-1,v}$ и $Q_{s+1,v}$ – значения v -ого ПК ($v = \overline{1, V}$) для моделей с номерами $(s-1)$ и $(s+1)$, являющихся «соседями» для S -ой модели; Q_v^{min} и Q_v^{max} – минимальное и максимальное значения v -ого ПК ($v = \overline{1, V}$) соответственно.

На рисунке 2 представлена геометрическая интерпретация, применяемая при расчете расстояния скученности при наличии двух ПК. Закрашенные «кружочки» соответствуют моделям с минимальным (нулевым) значением ранга. Для определения расстояния скученности для S -ой модели требуется определить значения обоих ПК для $(s-1)$ -ой и $(s+1)$ -ой моделей, являющихся ближайшими к S -ой модели и имеющих тот же ранг, а также лучшее и худшее значения каждого ПК (вне зависимости от ранга модели). Расстояние скученности для S -ой модели с учетом двух ПК может быть вычислено как:

$$\tau_s = (Q_{s-1,1} - Q_{s+1,1}) / (Q_1^{max} - Q_1^{min}) + (Q_{s-1,2} - Q_{s+1,2}) / (Q_2^{max} - Q_2^{min}). \quad (7)$$

При реализации расчетов S -ая МП будет считаться лучшей, чем Z -ая модель, если:

- $R_s < R_z$;
- $R_s = R_z$ и $\tau_s > \tau_z$.

Если S -ая МП лучше, чем Z -ая модель, то S -ая модель является кандидатом для переноса в новое поколение.

Следует отметить, что модели (и соответствующие антители) в процессе реализации многоцелевого МАКО будут дважды подвергаться процедуре отбора, обеспечивающей поддержание разнообразия в популяции: сначала при выполнении супрессии антители (на основе сходства их кодировок), а затем – при одновременном анализе значений рангов и значений расстояний скученности.

Многоцелевой МАКО может быть описан следующей последовательностью шагов.

1. Сгенерировать популяцию антители, каждое из которых кодируется на основе СБД и определяет некоторую МП.

2. Отсортировать популяцию антители по «недоминированию» на основе значений двух ПК МП – значения показателя аффинитета Aff (1) и значения показателя несовпадения тенденций $Tendency$ (4).

3. Осуществить выбор антители-родителей для формирования следующего поколения антители-клонов на основе рангов и вычисленных «расстояний скученности», соответствующих МП для текущей популяции антители.

4. Перейти к п. 5, если достигнуты желаемые значения ПК или исчерпано количество поколений в МАКО. В противном случае перейти к п. 2.

5. Выбрать в последней популяции антител антитело с минимальным значением показателя аффинитета Aff (1) и считать его искомым («лучшим») антителом. Использовать «лучшее» антитело для построения искомой МП с целью выполнения краткосрочных и среднесрочных прогнозов.




Рис. 2. Геометрическая интерпретация, применяемая при расчете расстояния скученности

В результате реализации предлагаемого алгоритма будет получено Парето-множество недоминируемых (парето-оптимальных) МП, обеспечивающих лучшие сочетания значений используемых ПК МП для анализируемого ВР.

На основе вышеизложенного можно сделать вывод о наличии двух вариантов оптимизации, которые могут быть использованы при разработке МП на основе СБД. При этом первый вариант оптимизации предполагает применение одного ПК МП – показателя аффинитета, а второй вариант реализует учет двух ПК МП – показателя аффинитета и показателя несовпадения тенденций. Следует отметить перспективность использования второго варианта оптимизации при решении задач среднесрочного прогнозирования, а также для прогнозирования групп ВР [2, 15, 16], что значительно расширит сферу применения МП на основе СБД и МАКО.

Результаты вычислительных экспериментов. Оба предлагаемых варианта оптимизации были применены при разработке МП, предназначенных для прогнозирования количества упоминаний названий E-Commerce систем в требованиях к вакансиям, размещенных на сайтах двух известных рекрутинговых сетевых сервисов: HeadHunter.ru (Россия) и Indeed.com (США). Полученные таким образом результаты прогнозирования могут быть использованы для анализа тенденций на рынке труда. Каждый анализируемый ВР содержит информацию о количестве вакансий, содержащих определенное ключевое слово (Magento, OpenCart, PrestoShop, Hybris, Demandware), определяющее название E-Commerce системы для разработки интернет-магазинов. При этом было рассмотрено 7 ВР: 4 ВР с информацией о вакансиях в России и 3 ВР с информацией о вакансиях в США, помеченные (в скобках после названия ключевого слова) соответственно как RF и USA:

Hybris (RF) (период наблюдения 03.02.2016 – 06.04.2016, единица измерения – количество упоминаний) = [55; 55; 57; 56; 56; 55; 56; 62; 62; 61; 59; 57; 57; 57; 57; 58; 58; 58; 58; 58; 58; 56; 56; 56; 57; 57; 57; 57; 55; 54; 54; 53; 53; 54; 52; 51; 53; 53; 51; 51; 51; 54; 56; 58; 58; 58; 58; 58; 58; 58; 58; 58; 60; 63; 63; 62; 63; 65; 67; 67; 67; 66; 66; 69; 70];

Magento (RF) (период наблюдения 03.02.2016 – 06.04.2016, единица измерения – количество упоминаний) = [132; 131; 126; 125; 120; 128; 130; 133; 130; 128; 124; 121; 120; 123; 123; 127; 129; 123; 127;

129; 131; 133; 123; 123; 123; 123; 123; 120; 120; 118; 116; 117; 118; 129; 124; 120; 120; 127; 130; 131; 129; 129; 124; 129; 133; 134; 132; 133; 133; 132; 135; 136; 136; 136; 136; 142; 140; 147];

OpenCart (RF) (период наблюдения 03.02.2016 – 06.04.2016, единица измерения – количество упоминаний) = [84; 84; 82; 81; 80; 81; 89; 88; 89; 85; 85; 85; 88; 91; 93; 90; 88; 85; 90; 90; 91; 85; 83; 83; 77; 77; 77; 79; 79; 76; 72; 75; 73; 74; 76; 80; 75; 80; 80; 79; 86; 92; 93; 89; 90; 90; 90; 92; 94; 96; 98; 99; 99; 101; 115; 116; 116; 119; 120; 120; 112; 114; 114; 118];

PrestoShop (RF) = [32; 31; 33; 34; 34; 33; 33; 32; 32; 32; 30; 30; 30; 29; 29; 29; 26; 26; 24; 23; 23; 22; 22; 22; 25; 24; 25; 25; 28; 32; 30; 30; 29; 29; 29; 31; 31; 32; 31; 31; 31; 31; 31; 29; 28; 28; 28; 28; 27; 27; 28];

Hybris (USA) (период наблюдения 03.02.2016 – 06.04.2016, единица измерения – количество упоминаний) = [674; 688; 677; 672; 664; 680; 690; 693; 710; 706; 697; 692; 688; 689; 676; 668; 663; 648; 643; 637; 635; 642; 641; 641; 629; 629; 629; 631; 631; 666; 671; 663; 667; 672; 711; 703; 662; 715; 715; 709; 690; 665; 668; 657; 662; 659; 659; 660; 657; 658; 656; 653; 653; 646; 643; 630; 631; 649; 647; 647; 652; 654; 662; 650];

Magento (USA) (период наблюдения 03.02.2016 – 06.04.2016, единица измерения – количество упоминаний) = [1093; 1102; 1082; 1076; 1076; 1077; 1087; 1095; 1080; 1073; 1072; 1070; 1073; 1086; 1103; 1110; 1118; 1110; 1098; 1107; 1114; 1133; 1126; 1126; 1124; 1124; 1124; 1134; 1134; 1131; 1135; 1125; 1111; 1114; 1138; 1137; 1125; 1155; 1155; 1145; 1103; 1006; 1023; 1013; 1015; 1008; 1008; 1009; 1012; 1021; 1024; 1022; 1022; 1013; 1022; 1023; 1045; 1049; 1040; 1040; 1022; 1018; 1038; 1042];

Demandware (USA) (период наблюдения 03.02.2016 – 06.04.2016, единица измерения – количество упоминаний) = [335; 334; 334; 332; 332; 335; 339; 331; 332; 329; 331; 330; 326; 338; 341; 342; 342; 341; 339; 343; 344; 340; 344; 344; 357; 357; 357; 367; 385; 390; 389; 389; 400; 403; 404; 307; 397; 395; 388; 383; 389; 381; 373; 374; 374; 381; 376; 377; 372; 373; 373; 370; 369; 364; 372; 370; 371; 371; 374; 377; 378; 377].

При этом первые 59 значений элементов каждого ВР использовались в качестве обучающей последовательности данных, а последние 5 – в качестве тестовой последовательности.

Для каждого ВР с применением МАКО на основе двух вариантов оптимизации были разработаны соответствующие МП (табл. 1). В таблице 2 и на рисунках 3 и 4 продемонстрированы результаты прогнозирования с использованием данных моделей, полученные на обучающей и тестовой последовательностях данных. В таблице 2 представлены результаты прогнозирования с использованием данных моделей на 5 шагов вперед, а также значения показателя аффинитета (ошибки на обучающей последовательности данных) и средней относительной ошибки прогнозирования по 5 шагам (ошибки на тестовой последовательности данных).

Таблица 1

Сравнение моделей прогнозирования

| Временной ряд | Модель прогнозирования с использованием одного показателя качества | Модель прогнозирования с использованием двух показателей качества |
|------------------|--|--|
| Hybris (RF) | $\cos(\exp(\cos(\cos(\cos(d(t-4)) + \cos(d(t-1)))) - \sin(d(t-2)))) - \exp(\ln(d(t-3)))$ | $\exp(\sin(\sin(587.749/\cos(d(t-2)))) - 0.670) + \sin(d(t-4) + \sin(d(t-3))) - \sin(0.667 - \ln(d(t-1)))) - d(t-1) + \cos(d(t-2))$ |
| Magento (RF) | $\ln(\cos(\ln(\sin(\sin(\ln(d(t-1)) - \sin(d(t-3)))) \cdot d(t-4)) + \cos(d(t-5)) - \exp(d(t-2))) / \exp(\exp(d(t-7))) \cdot d(t-7)) + \exp(d(t-1) + \sin(d(t-1)))$ | $\cos(\sin(\exp(d(t-3)+d(t-2)) - \ln(d(t-5))) + \exp(d(t-2)) - \sin(d(t-5))) \cdot \cos(\ln(d(t-6))) \cdot \exp(d(t-7))) / \ln(\sin(d(t-4)) + \exp(d(t-2)))$ |
| OpenCart (RF) | $\sin(\sin(\ln(d(t-2)) \cdot \cos(d(t-1))) \cdot \sin(d(t-5))) - \cos(\sin(d(t-6)) \cdot d(t-4)) \cdot \sin(\cos(d(t-3)) / d(t-3)) - \ln(d(t-3)) - d(t-2))$ | $\exp(\sin(\cos(\sin(\sin(d(t-4))+\ln(d(t-3)))+\ln(d(t-2)))) + \cos(\exp(d(t-6)) \cdot \ln(d(t-1))) - \exp(\cos(d(t-3))) \cdot \sin(d(t-2))) - \ln(\exp(d(t-1)) - \sin(d(t-5)))$ |
| PrestoShop (RF) | $\ln(\sin(\exp(\sin(\ln(d(t-3))) \cdot \sin(d(t-2))) / \ln(d(t-4))) + \exp(\sin(d(t-2)) \cdot \cos(d(t-5))) \cdot \exp(d(t-1)) - \cos(d(t-5)) \cdot \cos(\ln(d(t-1))) \cdot \sin(d(t-1)))$ | $\sin(\ln(\sin(\sin(\cos(d(t-1))) \cdot \sin(d(t-3))) - \sin(d(t-6))) + \sin(\cos(d(t-2)) \cdot d(t-4)) - \cos(\ln(d(t-3)) - \ln(d(t-5)))) - \ln(\exp(d(t-1)) \cdot 2.3))$ |
| Demandware (USA) | $\ln(\exp(\sin(\cos(d(t-2)) - \cos(d(t-3))) \cdot 0.002 + \cos(\cos(d(t-2)) - d(t-4)) \cdot \exp(d(t-1) - \sin(d(t-3)))) + \exp(\sin(d(t-2)) - \ln(d(t-2)))$ | $\ln(\exp(\sin(\cos(\ln(d(t-2))) / \sin(d(t-4))) - \sin(d(t-3))) - \ln(\exp(d(t-1)) - \ln(d(t-3))) + \sin(d(t-1) / d(t-3))) + \exp(\sin(d(t-5)) - \ln(d(t-1)))$ |
| Magento (USA) | $\exp(\exp(\sin(\ln(\sin(d(t-6)) + \sin(d(t-1)))) + \cos(d(t-5))) \cdot \cos(\sin(d(t-2)) \cdot \ln(d(t-1))) / \exp(\exp(d(t-3)) - \cos(d(t-4))) \cdot \ln(d(t-1) + \cos(d(t-3)))$ | $\exp(\sin(\sin(\sin(\sin(\ln(d(t-6))) \cdot d(t-1)) / \ln(d(t-3))) + \cos(\sin(d(t-4)) / \sin(d(t-2)))) \cdot \sin(\sin(d(t-5)) \cdot 0.013) \cdot \ln(\ln(d(t-4)) + d(t)))$ |
| Hybris (USA) | $\ln(\exp(\sin(\sin(\sin(d(t-1))) \cdot \exp(d(t-3))) \cdot (-0.499)) + \exp(\cos(d(t-4)) - \cos(d(t-2)))) - \ln(d(t-4)) - d(t-4) + \sin(\sin(d(t-1)) - \ln(d(t-4)))$ | $\sin(\sin(\exp((\cos(d(t-2)) - 3.530) - \cos(d(t-3))) + \sin(0.968 \cdot \ln(d(t-4))) \cdot \exp(\sin(d(t-1)) / \cos(d(t-5)))) - d(t-1) - \sin(d(t-2)))$ |

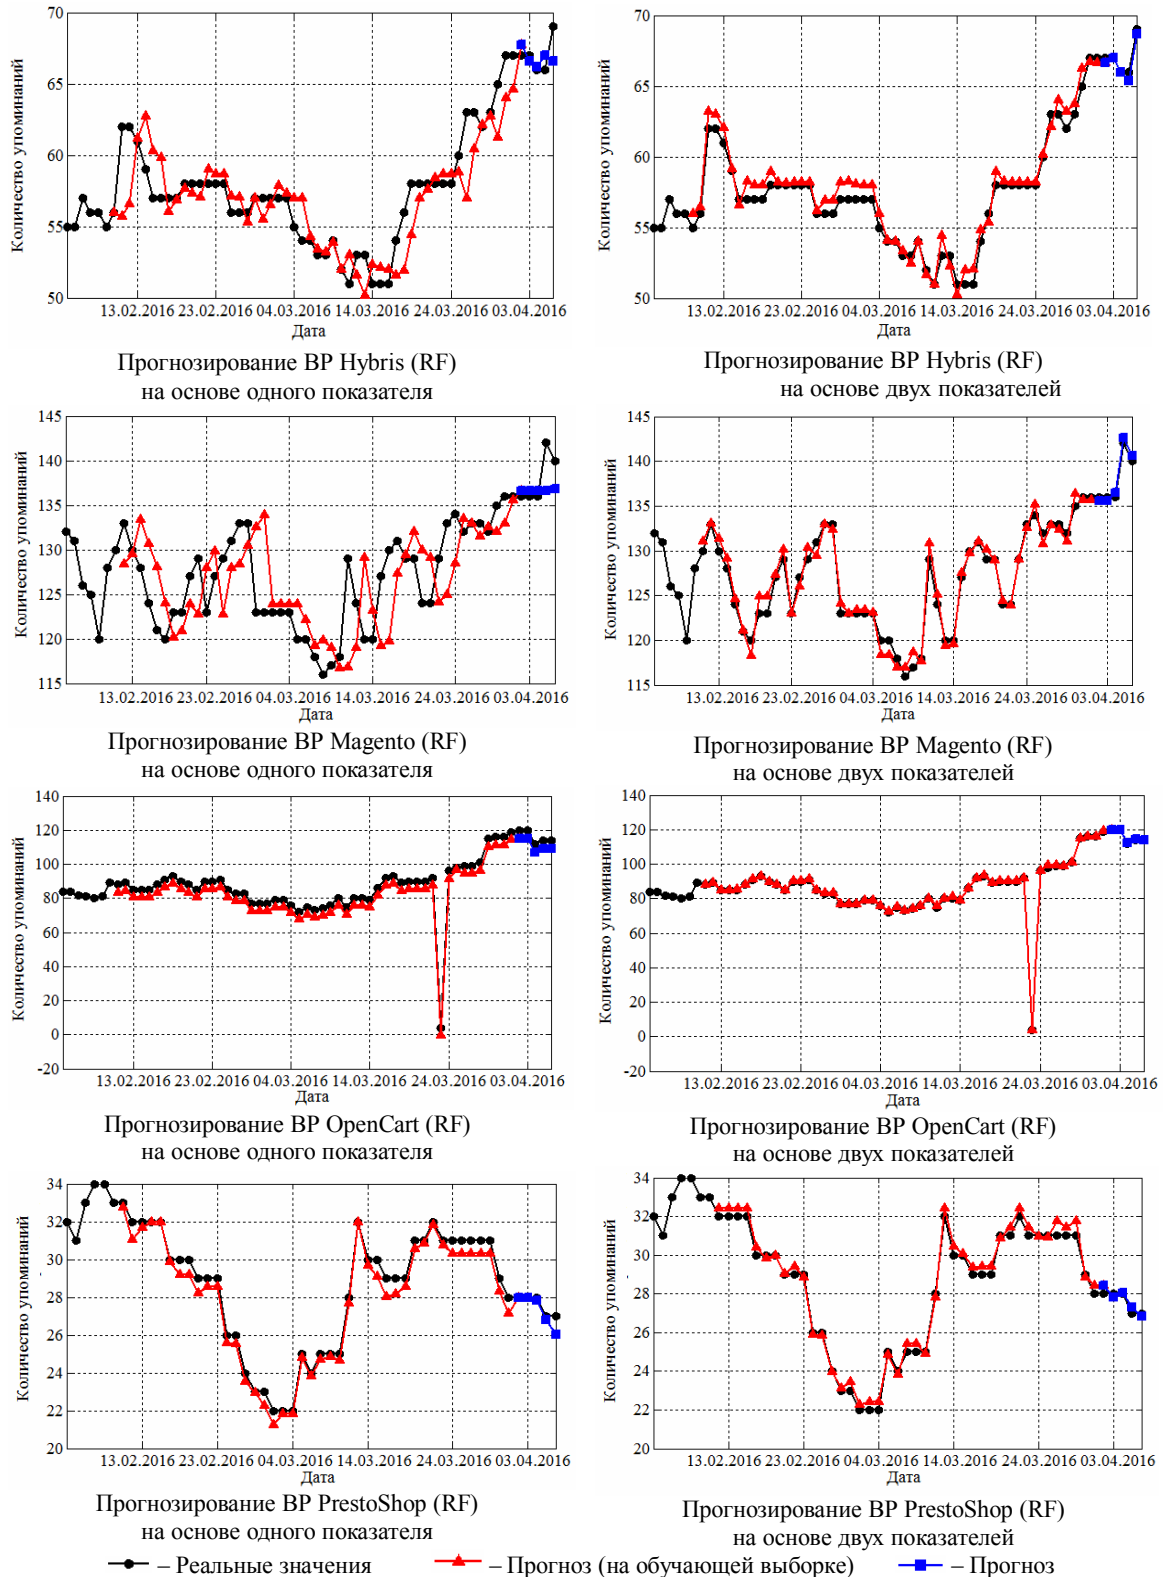


Рис. 3. Результаты прогнозирования BP, характеризующих количество упоминаний указанных E-Commerce систем на рекрутинговом ресурсе HeadHunter.ru (Россия)

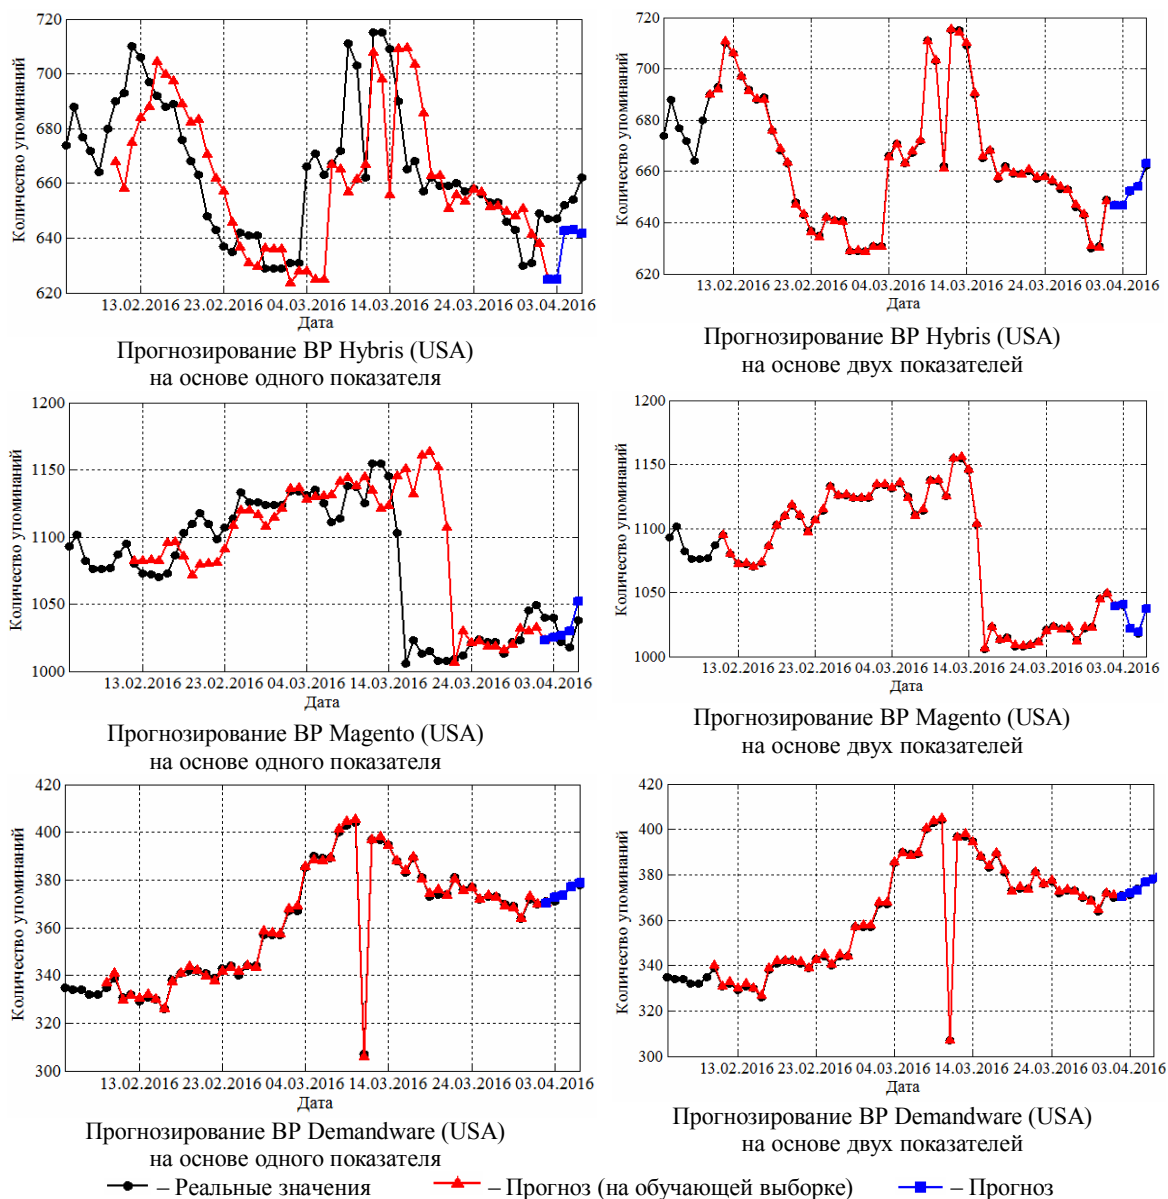


Рис. 4. Результаты прогнозирования BP, характеризующих количество упоминаний указанных E-Commerce систем на рекрутинговом ресурсе Indeed.com (США)

Таблица 2

Результаты прогнозирования

| Наименование BP | Aff (AFER), % | На 1 шаге | | На 2 шаге | | На 3 шаге | | На 4 шаге | | На 5 шаге | | Ср. отн. ошибка по 5 шагам, % |
|---------------------|---------------|-----------|---------|-----------|---------|-----------|---------|-----------|---------|-----------|---------|-------------------------------|
| | | факт | прогноз | факт | прогноз | факт | прогноз | факт | прогноз | факт | прогноз | |
| 1 показатель | | | | | | | | | | | | |
| Hybris (RF) | 2,56 | 67 | 67,75 | 67 | 66,55 | 66 | 66,2 | 66 | 67,02 | 69 | 66,56 | 1,43 |
| Magento (RF) | 0,44 | 136 | 136,6 | 136 | 136,6 | 136 | 136,6 | 142 | 136,6 | 140 | 136,8 | 1,48 |
| OpenCart (RF) | 6,86 | 120 | 115,2 | 120 | 115,2 | 112 | 107,2 | 114 | 109,2 | 114 | 109,3 | 4,11 |
| PrestoShop (RF) | 1,52 | 28 | 28 | 28 | 28 | 28 | 27,85 | 27 | 26,81 | 27 | 26,04 | 0,93 |
| Demandware (USA) | 0,22 | 371 | 370,4 | 371 | 372,6 | 374 | 373,6 | 377 | 377 | 378 | 378,9 | 0,43 |
| Magento (USA) | 2,46 | 1040 | 1023 | 1040 | 1025 | 1022 | 1027 | 1018 | 1030 | 1038 | 1052 | 0,94 |
| Hybris (USA) | 2,40 | 647 | 624,7 | 647 | 624,7 | 652 | 642,8 | 654 | 642,9 | 662 | 641,7 | 2,61 |

| 2 показателя | | | | | | | | | | | | |
|------------------|------|------|-------|------|-------|------|--------|------|-------|------|-------|------|
| Hybris (RF) | 1,06 | 67 | 66,65 | 67 | 67,01 | 66 | 66,01 | 66 | 65,35 | 69 | 68,7 | 0,39 |
| Magento (RF) | 0,32 | 136 | 135,6 | 136 | 135,6 | 136 | 136,5 | 142 | 142,7 | 140 | 140,6 | 0,37 |
| OpenCart (RF) | 0,32 | 120 | 120,1 | 120 | 120,1 | 112 | 112,1 | 114 | 114,2 | 114 | 114,2 | 0,12 |
| PrestoShop (RF) | 1,04 | 28 | 28,43 | 28 | 27,84 | 28 | 28,26 | 27 | 27,29 | 27 | 26,84 | 0,58 |
| Demandware (USA) | 0,17 | 371 | 370,1 | 371 | 382 | 374 | 373 | 377 | 376,6 | 378 | 378 | 0,17 |
| Magento (USA) | 0,06 | 1040 | 1039 | 1040 | 1040 | 1022 | 1022,1 | 1018 | 1019 | 1038 | 1037 | 0,06 |
| Hybris (USA) | 0,08 | 647 | 646,7 | 647 | 646,6 | 652 | 652,3 | 654 | 654,2 | 662 | 663,2 | 0,07 |


В таблице 3 приведены усредненные значения относительных ошибок прогнозирования на 5 шагах и усредненные значения показателей аффинитета Aff и несовпадения тенденций ВР $Tendency$, полученные по результатам 10 прогонов МАКО для каждого ВР. Также усредненные значения относительных ошибок прогнозирования на 5 шагах и усредненные значения показателей аффинитета Aff в разрезе всех ВР представлены графически на рисунке 5а.

Таблица 3
Усредненные значения ошибок прогнозирования на 5 шагах и усредненные значения показателей Aff (AFER) и $Tendency$

| Наименование ВР | Aff (AFER), % | Значение ошибки прогнозирования | | | | | | $Tendency$ | |
|---------------------|-----------------|---------------------------------|-----------|-----------|-----------|-----------|--------------------------|---------------------------------|--------------------------------|
| | | На 1 шаге | На 2 шаге | На 3 шаге | На 4 шаге | На 5 шаге | Ср. ошибка по 5 шагам, % | На обучающей последовательности | На тестовой последовательности |
| 1 показатель | | | | | | | | | |
| Hybris (RF) | 2,56 | 1,12 | 0,67 | 0,30 | 1,55 | 3,54 | 1,43 | 0,45 | 0,6 |
| Magento (RF) | 0,44 | 0,45 | 0,45 | 0,45 | 3,79 | 2,28 | 1,48 | 0,38 | 0,4 |
| OpenCart (RF) | 6,86 | 3,96 | 3,98 | 4,27 | 4,20 | 4,14 | 4,11 | 0,2 | 0 |
| PrestoShop (RF) | 1,52 | 1,32 | 0,83 | 0,74 | 0,55 | 1,21 | 0,93 | 0,09 | 0,4 |
| Demandware (USA) | 0,22 | 0,19 | 0,20 | 0,58 | 0,75 | 0,44 | 0,43 | 0,09 | 0,2 |
| Magento (USA) | 2,46 | 1,30 | 1,41 | 0,45 | 0,20 | 1,37 | 0,94 | 0,43 | 0,4 |
| Hybris (USA) | 2,40 | 3,45 | 3,45 | 1,41 | 1,70 | 3,07 | 2,61 | 0,4 | 0,4 |
| Среднее значение | 2,35 | 1,68 | 1,57 | 1,17 | 1,82 | 2,29 | 1,71 | 0,27 | 0,34 |
| 2 показателя | | | | | | | | | |
| Hybris (RF) | 1,06 | 0,52 | 0,02 | 0,02 | 0,98 | 0,44 | 0,39 | 0,11 | 0 |
| Magento (RF) | 0,32 | 0,27 | 0,28 | 0,35 | 0,48 | 0,45 | 0,37 | 0,06 | 0 |
| OpenCart (RF) | 0,32 | 0,07 | 0,06 | 0,12 | 0,20 | 0,17 | 0,12 | 0 | 0 |
| PrestoShop (RF) | 1,04 | 0,52 | 0,55 | 0,44 | 0,71 | 0,67 | 0,58 | 0,09 | 0,2 |
| Demandware (USA) | 0,17 | 0,15 | 0,15 | 0,20 | 0,23 | 0,15 | 0,17 | 0 | 0 |
| Magento (USA) | 0,06 | 0,05 | 0,04 | 0,04 | 0,09 | 0,10 | 0,06 | 0 | 0 |
| Hybris (USA) | 0,08 | 0,05 | 0,06 | 0,05 | 0,03 | 0,17 | 0,07 | 0 | 0 |
| Среднее значение | 0,43 | 0,23 | 0,16 | 0,17 | 0,39 | 0,31 | 0,25 | 0,04 | 0,03 |

Как видно из представленных таблиц и рисунков именно второй вариант оптимизации является более эффективным как для решения задач краткосрочного прогнозирования (на 1–3 шага вперед), так и среднесрочного прогнозирования (на 4 и 5 шагов вперед).

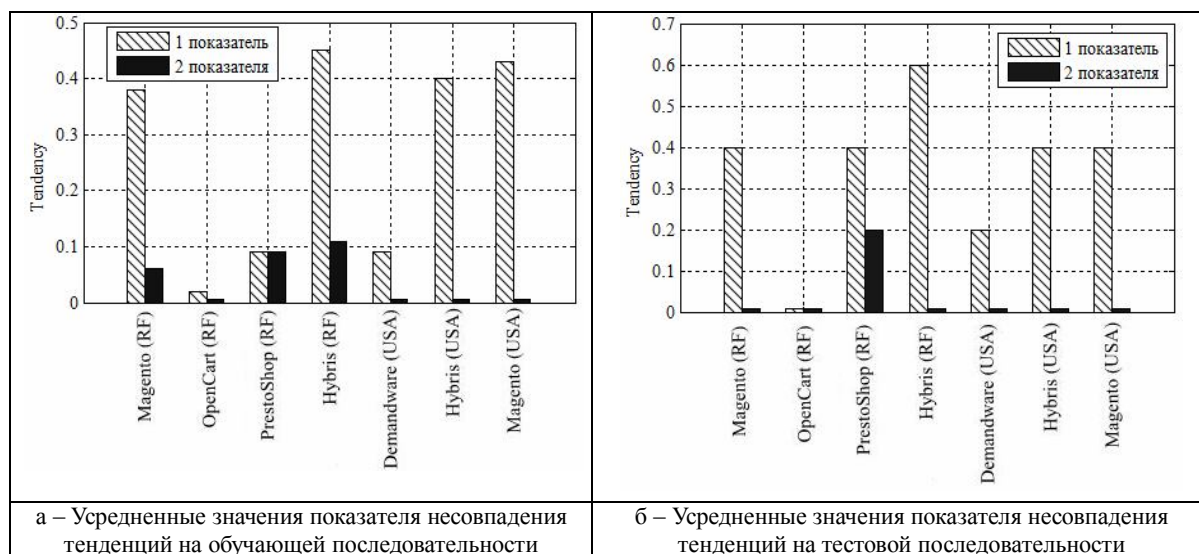
При этом второй вариант оптимизации позволяет не только получить меньшее значение показателя несовпадения тенденций ВР $Tendency$ по сравнению с первым вариантом оптимизации (табл. 3, рис. 6), но и во многих случаях уменьшить значение показателя аффинитета Aff (рис. 5б) благодаря соответствующей коррекции направления поиска искомой МП.



а – Усредненные значения ошибок прогнозирования на шагах 1–5 и усредненные значения показателя аффинитета по всем ВР

б – Усредненные значения показателя аффинитета для каждого ВР

Рис. 5. Сравнительный анализ усредненных значений ошибок прогнозирования на шагах 1–5 и усредненных значений показателя аффинитета для двух вариантов оптимизации



а – Усредненные значения показателя несовпадения тенденций на обучающей последовательности

б – Усредненные значения показателя несовпадения тенденций на тестовой последовательности

Рис. 6. Сравнительный анализ усредненных значений показателя несовпадения тенденций для двух вариантов оптимизации

В рассматриваемом примере при реализации одного прогона МАКО выполнялось 400 итераций для популяции из 20 антител при коэффициентах клонирования антител и размножения клонов, равных соответственно 0,3 и 0,8.

В вычислительных экспериментах использовалась ПЭВМ, работающая под 64-разрядной версией Windows 7, с оперативной памятью 2 Гб и двухядерным процессором Pentium 4 с тактовой частотой каждого ядра 3,4 ГГц. При этом для построения одной МП на основе одного ПК (для первого варианта оптимизации) в среднем требовалось 108,5 секунд.

Для построения МП на основе двух ПК (для второго варианта оптимизации) в среднем требовалось 120,9 секунды, что на 12,4 секунды (то есть на 10,3 %) больше, чем для первого варианта оптимизации.

Выводы. Сравнительный анализ двух вариантов оптимизации в контексте решения задачи разработки МП на основе СБД показал целесообразность и перспективность использования второго варианта, реализующего учет двух ПК МП – показателя аффинитета и показателя несовпадения тенденций ВР.

Использование принципов Парето-доминирования в ходе реализации МАКО при разработке МП на основе СБД позволяет получить эффективное решение задачи учета двух ПК при приемлемых временных затратах. При этом удастся расширить сферу применения МП на основе СБД и МАКО.

Таким образом, очевидна целесообразность выполнения исследований по дальнейшему усовершенствованию алгоритмов МЦО с целью их применения для решения задачи поиска адекватной МП ВР при приемлемых временных затратах.

Список литературы

1. Астахова Н. Н. Использование почти полных строго бинарных деревьев и модифицированного алгоритма клонального отбора при разработке моделей прогнозирования временных рядов с короткой актуальной частью / Н. Н. Астахова, Л. А. Демидова // Вестник Рязанского государственного радиотехнического университета. – 2013. – № 4–2 (46). – С. 89–96.
2. Астахова Н. Н. Метод прогнозирования групп временных рядов с применением алгоритмов кластерного анализа / Н. Н. Астахова, Л. А. Демидова // Прикаспийский журнал: управление и высокие технологии. – 2015. – № 2 (30). – С. 59–79.
3. Брумштейн Ю. М. Одно- и многомерные временные ряды: анализ возможных методов оптимизации отсчетов и оценки характеристик / Ю. М. Брумштейн, М. В. Иванова // Прикаспийский журнал: управление и высокие технологии. – 2012. – № 4. – С. 35–44.
4. Гуменникова А. В. Адаптивные поисковые алгоритмы для решения сложных задач многокритериальной оптимизации : автореф. дисс. ... канд. техн. наук / А. В. Гуменникова. – Красноярск : СибГАУ, 2006. – 515 с.
5. Демидова Л. А. Модифицированный алгоритм клонального отбора для анализа временных рядов с короткой длиной актуальной части / Л. А. Демидова, А. В. Корячко, Т. С. Скворцова // Системы управления и информационные технологии. – 2010. – Т. 42, № 4.1. – С. 131–136.
6. Демидова Л. А. Модели прогнозирования временных рядов с короткой актуальной частью на основе модифицированного алгоритма клонального отбора / Л. А. Демидова // Вестник Рязанского государственного радиотехнического университета. – 2012. – № 39–2. – С. 64–71.
7. Демидова Л. А. Оценка качества моделей прогнозирования на основе строго бинарных деревьев и модифицированного алгоритма клонального отбора / Л. А. Демидова // Cloud of Science. – 2014. – Т. 1, № 2. – С. 202–222.
8. Демидова Л. А. Подход к оценке качества моделей прогнозирования на основе строго бинарных деревьев и модифицированного алгоритма клонального отбора / Л. А. Демидова // Бизнес-информатика. – 2015. – № 1. – С. 58–68.
9. Жукова М. Н. Коэволюционный алгоритм решения сложных задач оптимизации : автореф. дисс. ... канд. наук / М. Н. Жукова. – Красноярск : СибГАУ, 2004. – 124 с.
10. Пилюгина А. В. Определение оптимальных параметров модели экспоненциального сглаживания временного ряда для прогнозирования валютного курса / А. В. Пилюгина, А. А. Бойко // Прикаспийский журнал: управление и высокие технологии. – 2016. – № 1. – С. 114–127.
11. Семенкин Е. С. Адаптивные поисковые методы оптимизации сложных систем / Е. С. Семенкин, О. Э. Семенкина, С. П. Коробейников. – Красноярск : СИБУП, 1997. – 355 с.
12. Сопов Е. А. Эволюционные алгоритмы моделирования и оптимизации сложных систем : автореф. дисс. ... канд. техн. наук / Е. А. Сопов. – Красноярск : СибГАУ, 2004. – 514 с.
13. Чубукова И. А. Data Mining : учеб. пособие / И. А. Чубукова. – Москва : Интернет-университет информационных технологий : БИНОМ : Лаборатория знаний, 2006. – 382 с.
14. Юдин Д. Б. Вычислительные методы теории принятия решений / Д. Б. Юдин. – Москва : Наука, 1989. – 320 с.
15. Astakhova N. N. Forecasting of Time Series' Groups With Application Of Fuzzy C-Mean Algorithm / N. N. Astakhova, L. A. Demidova, E. V. Nikulchev // Contemporary Engineering Sciences. – 2015. – Vol. 8, № 35. – P. 1659–1677.
16. Astakhova N. N. Forecasting Method for Grouped Time Series With the Use of K-Means Algorithm / N. N. Astakhova, L. A. Demidova, E. V. Nikulchev // Applied Mathematical Sciences. – 2015. – Vol. 9, № 97. – P. 4813–4830.
17. Astakhova N. The Description Problem Of The Clusters' Centroids / N. Astakhova, L. Demidova, V. Konev // Stability and Control Processes : International Conference in Memory of V. I. Zubov (SCP). – 2015. – P. 448–451.
18. Bentley P. J. Finding Acceptable Solutions in the Pareto-Optimal Range using Multiobjective Genetic Algorithms / P. J. Bentley, J. P. Wakefield // Proceedings of the 2nd On-Line World Conference on Soft Computing in Engineering Design and Manufacturing. – 1997. – P. 126–140.

19. Branke J. Memory Enhanced Evolutionary Algorithms for Changing Optimization Problems / J. Branke. – Institute AIFB, University of Karlsruhe, 1999. – P. 1049–1063.
20. Coello Coello C.A. An approach to solve multiobjective optimization problems based on an artificial immune system / C. A. Coello Coello, N. Cruz Cortés // Proceedings of the First International Conference on Artificial Immune Systems. – UK : University of Kent at Canterbury, September 9–11, 2002. – P. 212–221.
21. Campelo F. A novel multiobjective immune algorithm using nondominated sorting. In 11th International / F. Campelo, F. G. Guimarães, R. R. Saldanha, H. Igarashi, S. Noguchi, D. A. Lowther, J. A. Ramirez // IGTE Symposium on Numerical Field Calculation in Electrical Engineering. – 2004.
22. Demidova L. A. Time Series Forecasting Models On The Base Of Modified Clonal Selection Algorithm / L. A. Demidova // International conference on computer technologies in physical and engineering applications. – Санкт-Петербургский государственный университет, 2014. – P. 33–34.
23. Demidova L. A. Genetic Algorithm For Optimal Parameters Search In The One-Factor Forecasting Model Based On Continuous Type-2 Fuzzy Sets / L. A. Demidova // Automation and Remote Control. – 2013. – Vol. 74, № 2. – P. 313–320.
24. Deb K. A Fast and Elitist Multiobjective Genetic Algorithm: NSGA II / K. Deb, A. Pratap, S. Agarwal, T. Meyarivan // KanGAL Report No. 200001. – Kanpur, India : Indian Institute of Technology, 2000. – P. 182–197.
25. Deb K. An evolutionary many-objective optimization algorithm using reference-point based non-dominated sorting approach / K. Deb, H. Jain // Part I: Solving problems with box constraints. IEEE Transactions on Evolutionary Computation. – 2014. – Vol. 18 (4). – P. 577–601.
26. Deb K. Multiobjective Optimization using Evolutionary Algorithms. Chichester / K. Deb. – UK : Wiley. 2001. – P. 221–232.
27. Eberhart R. C. A new optimizer using particle swarm theory / R. C. Eberhart, J. Kennedy // Proceedings of the Sixth International Symposium on Micro Machine and Human Science. – Nagoya, Japan, Piscataway, NJ : IEEE Service Center, 1995. – P. 39–43.
28. Fonseca C. M. Multiobjective optimization and multiple constraint handling with evolutionary algorithms / C. M. Fonseca, P. J. Fleming // Technical report 564. – Sheffield, UK : University of Sheffield, January 1995. – Part I : A unified formulation. – P. 1–16.
29. Goldberg D. E. Genetic Algorithms in Search, Optimization, and Machine Learning / D. E. Goldberg // Reading. – Massachusetts : Addison-Wesley, 1989. – 372 p.
30. Jiao L. Clonal selection with immune dominance and energy based multiobjective optimization / L. Jiao, M. Gong, R. Shang, H. Du, B. Lu // 3rd International Conference on Evolutionary Multi-Criterion Optimization. – 2005. – P. 474–489.
31. Jiao L. Multiobjective immune algorithm with nondominated neighbor-based selection / L. Jiao, M. Gong, H. Du, L. Bo // Evolutionary Computation. – Summer 2008. – Vol. 16, issue 2. – P. 225–255.
32. Horn J. A niched Pareto genetic algorithm for multiobjective optimization / J. Horn, N. Nafpliotis, D. E. Goldberg // Proceedings of the First IEEE Conference on Evolutionary Computation. – 1994. – Vol. 1. – P. 82–87.
33. Kennedy J. A discrete binary version of the particle swarm algorithm / J. Kennedy, R. C. Eberhart // Proc. 1997 Conf. on Systems, Man, and Cybernetics Piscataway. – NJ : IEEE Service Center, 1997. – P. 4104–4109.
34. Knowles J. The Pareto archived evolution strategy: A new baseline algorithm for multiobjective optimization / J. Knowles, D. Corne // Proceedings of the 1999 Congress on Evolutionary Computation. – New Jersey : IEEE Service Center, 1999. – P. 98–105.
35. Luh G.-C., MOIA: Multi-Objective Immune Algorithm / G.-C. Luh, C.-H. Chueh, W.-W. Liu // Computers and Structures. – 2004. – Vol. 82. – P. 829–844.
36. Michalewicz Z. Genetic algorithms, numerical optimization and constraints / Z. Michalewicz // Proc. of the Sixth Int. Conf. on Genetic Algorithms and their Applications. – Pittsburgh, PA, 1995. – P. 239–247.
37. Srinivas N. Multiple-Objective function optimization using non-dominated sorting genetic algorithms / N. Srinivas, K. Deb // Evolutionary Computation. – 1995. – Vol. 2. – P. 221–248.
38. Wang X. L. ACSAMO: An Adaptive Multiobjective Optimization Algorithm using the Clonal Selection Principle / X. L. Wang, M. Mahfouf // 2nd European Symposium on Nature-Inspired Smart Information Systems. – 2006. – P. 1–12.
39. Zhang, Z. Constrained Multiobjective Optimization Immune Algorithm: Convergence and Application / Z. Zhang // Computers and Mathematics with Applications. – 2006. – Vol. 52 (5). – P. 791–808.

References

1. Astakhova N. N., Demidova L. A. Ispolzovanie pochty polnykh strogo binarnykh derev i modifitsirovannogo algoritma klonalnogo otbora pri razrabotke modeley prognozirovaniya vremennykh ryadov s korotkoy aktualnoy chastyu [Use of almost full strictly binary trees and modified clonal selection algorithm for developing forecasting models of time series with short actual part]. *Vestnik Ryazanskogo gosudarstvennogo radiotekhnicheskogo universiteta* [Bulletin of the Ryazan State Radio Engineering University], 2013, no. 4–2 (46), pp. 89–96.

2. Astakhova N. N., Demidova L. A. Metod prognozirovaniya grupp vremennykh ryadov s primeneniem algoritmov klaster'nogo analiza [The method of time series forecasting groups using algorithms of cluster analysis]. *Prikaspijskiy zhurnal: upravlenie i vysokie tekhnologii* [Caspian journal: management and high technologies], 2015, no. 2 (30), pp. 59–79.
3. Brumshteyn Yu. M., Ivanova M. V. *Oдно- i mnogomernye vremennyye ryady: analiz vozmozhnykh metodov optimizatsii otschetov i ochenki harakteristik* [One - and multidimensional time series: analysis of possible methods of optimization of counting and assessment of characteristics]. *Prikaspijskiy zhurnal: upravlenie i vysokie tekhnologii* [Caspian journal: management and high technologies], 2012, no. 4, pp. 35–44.
4. Gumennikova A. V. *Adaptivnyye poiskovyye algoritmy dlya resheniya slozhnykh zadach mnogokriterial'noy optimizatsii* [Adaptive search algorithms to solve complex problems multi-objective optimization], Krasnoyarsk, SibGAU Publ. House, 2006. 515 p.
5. Demidova L. A., Koryachko A. V., Skvortsova T. S. Modifitsirovannyi algoritm klonal'nogo otbora dlya analiza vremennykh ryadov s korotkoy dlinoy aktual'noy chasti [Modified clonal selection algorithm for analysis of time series with a short length of actual part]. *Sistemy upravleniya i informatsionnyye tekhnologii* [Control Systems and Information Technologies], 2010, vol. 42, no. 4.1, pp. 131–136.
6. Demidova L. A. Modeli prognozirovaniya vremennykh ryadov s korotkoy aktual'noy chastyu na osnove modifitsirovannogo algoritma klonal'nogo otbora [Time series' forecasting models with short actual part on the base of modified clonal selection algorithm]. *Vestnik Ryazanskogo gosudarstvennogo radiotekhnicheskogo universiteta* [Bulletin of the Ryazan State Radio Engineering University], 2012, no. 39–2, pp. 64–71.
7. Demidova L. A. Otsenka kachestva modeley prognozirovaniya na osnove strogo binarnykh derev'ev i modifitsirovannogo algoritma klonal'nogo otbora [Forecasting models' quality assessment on the base of strictly binary trees and modified clonal selection algorithm]. *Cloud of Science*, 2014, vol. 1, no. 2, pp. 202–222.
8. Demidova L. A. Podkhod k otsenke kachestva modeley prognozirovaniya na osnove strogo binarnykh derev'ev i modifitsirovannogo algoritma klonal'nogo otbora [An Approach to Evaluation of Forecasting Models Quality Using Strictly Binary Trees and Modified Clonal Selection Algorithm]. *Biznes-informatika* [Business-informatics], 2015, no. 1, pp. 58–68.
9. Zhukova M. N. *Koehvolyutsionnyy algoritm resheniya slozhnykh zadach optimizatsii* [The coevolution algorithm for solving complex optimization problems], Krasnoyarsk, SibGAU Publ. House, 2004. 124 p.
10. Pilyugina A. V., Bojko A. A. Opredelenie optimal'nykh parametrov modeli ehksponentsial'nogo sglazhivaniya vremennogo ryada dlya prognozirovaniya valyutnogo kursa [Determination of optimum parameters of the model of exponential smoothing of a time series for forecasting of the exchange rate]. *Prikaspijskiy zhurnal: upravlenie i vysokie tekhnologii* [Caspian journal: management and high technologies], 2016, no. 1, pp. 114–127.
11. Semenkin E. S., Semenkina O. E., Korobejnikov S. P. *Adaptivnyye poiskovyye metody optimizatsii slozhnykh sistem* [Adaptive search methods for optimization of complex systems], Krasnoyarsk, SIBUP Publ. House, 1997. 355 p.
12. Sopov E. A. *Evolutsionnyye algoritmy modelirovaniya i optimizatsii slozhnykh sistem* [Evolutionary algorithms for simulation and optimization of complex], Krasnoyarsk, Sib-GAU Publ. House, 2004. 514 p.
13. Chubukova I. A. *Data Mining* [Data Mining], Moscow, Internet University of Information Technologies Publ. House : BINOM Publ. : Laboratory of knowledge Publ., 2006. 382 p.
14. Yudin D. B. *Vychislitel'nye metody teorii prinyatiya reshenij* [Computational methods of decision making theory], M., Science. Gl. red. fiz.-mat. lit. Publ., 1989. 320 p.
15. Astakhova N. N., Demidova L. A., Nikulchev E. V. Forecasting Of Time Series' Groups with Application Of Fuzzy C-Mean Algorithm. *Contemporary Engineering Sciences*, 2015, vol. 8, no. 35, pp. 1659–1677.
16. Astakhova N. N., Demidova L. A., Nikulchev E. V. Forecasting Method For Grouped Time Series With The Use Of K-Means Algorithm. *Applied Mathematical Sciences*, 2015, vol. 9, no. 97, pp. 4813–4830.
17. Astakhova N., Demidova L., Konev V. The Description Problem of The Clusters' Centroids. *2015 International Conference «Stability and Control Processes» in Memory of V.I. Zubov (SCP)*, 2015, pp. 448–451.
18. Bentley P. J., Wakefield J. P. Finding Acceptable Solutions in the Pareto-Optimal Range using Multiobjective Genetic Algorithms. *Proceedings of the 2nd On-Line World Conference on Soft Computing in Engineering Design and Manufacturing*, 1997, pp. 126–140.
19. Branke J. *Memory Enhanced Evolutionary Algorithms for Changing Optimization Problems*, Institute AIFB Publ. House, University of Karlsruhe Publ. House, 1999, pp. 1049–1063.
20. Coello Coello C. A., Cruz Cortés N. An approach to solve multi-objective optimization problems based on an artificial immune system. *Proceedings of the First International Conference on Artificial Immune Systems*, UK, University of Kent at Canterbury Publ. House., September 9–11, 2002, pp. 212–221.
21. Campelo F., Guimarães F. G., Saldanha, R. R., Igarashi H., Noguchi S., Lowther D. A., Ramirez J. A. A novel multiobjective immune algorithm using nondominated sorting. In 11th International. *IGTE Symposium on Numerical Field Calculation in Electrical Engineering*, 2004.
22. Demidova L. A. Time Series Forecasting Models on the Base of Modified Clonal Selection Algorithm. *2014 International conference on computer technologies in physical and engineering applications (ICCTPEA)*, St. Petersburg State University Publ. House, IEEE (IEEE Catalog number CFP14BDA-USB), 2014, pp. 33–34.

23. Demidova L. A. Genetic Algorithm for Optimal Parameters Search in the One-Factor Forecasting Model Based On Continuous Type-2 Fuzzy Sets. *Automation and Remote Control*, 2013, vol. 74, no. 2, pp. 313–320.
24. Deb K., Pratap A., Agarwal S., Meyarivan T. A Fast and Elitist Multiobjective Genetic Algorithm: NSGA II. *KanGAL Report No. 200001*, Kanpur, India, Indian Institute of Technology Publ. House, 2000, pp. 182–197.
25. Deb K., Jain H. An evolutionary many-objective optimization algorithm using reference-point based non-dominated sorting approach, Part I: Solving problems with box constraints. *IEEE Transactions on Evolutionary Computation*, 2014, vol. 18 (4), pp. 577–601.
26. Deb K. *Multiobjective Optimization using Evolutionary Algorithms*. Chichester, UK, Wiley, 2001, pp. 221–232.
27. Eberhart R. C., Kennedy J. A new optimizer using particle swarm theory, *Proceedings of the Sixth International Symposium on Micro Machine and Human Science*, Nagoya, Japan, Piscataway, NJ, IEEE Service Center Publ., 1995, pp. 39–43.
28. Fonseca C. M., Fleming P. J. Multiobjective optimization and multiple constraint handling with evolutionary algorithms – Part I: A unified formulation. *Technical report 564*, Sheffield, UK, University of Sheffield Publ. House, January 1995, pp. 1–16.
29. Goldberg D. E. *Genetic Algorithms in Search, Optimization, and Machine Learning*. Reading, Massachusetts, Addison-Wesley Publ., 1989. 372 p.
30. Jiao L., Gong M., Shang R., Du H., Lu B. Clonal selection with immune dominance and anergy based multiobjective optimization. *3rd International Conference on Evolutionary Multi-Criterion Optimization*, 2005, pp. 474–489.
31. Jiao L., Gong M., Du H., Bo L. Multiobjective immune algorithm with nondominated neighbor-based selection. *Evolutionary Computation*, summer 2008, vol. 16, issue 2, pp. 225–255.
32. Horn J., Nafpliotis N., Goldberg D.E. A niched Pareto genetic algorithm for multiobjective optimization. *Proceedings of the First IEEE Conference on Evolutionary Computation*, 1994, vol. 1, pp. 82–87.
33. Kennedy J., Eberhart R. C. A discrete binary version of the particle swarm algorithm. *Proc. 1997 Conf. on Systems, Man, and Cybernetics Piscataway, NJ*, IEEE Service Center Publ., 1997, pp. 4104–4109.
34. Knowles J., Corne D. The Pareto archived evolution strategy: A new baseline algorithm for multiobjective optimization. *Proceedings of the 1999 Congress on Evolutionary Computation*, New Jersey, IEEE Service Center Publ., 1999, pp. 98–105.
35. Luh G.-C., Chueh C.-H., Liu W.-W. MOIA: Multi-Objective Immune Algorithm. *Computers and Structures*, 2004, vol. 82, pp. 829–844.
36. Michalewicz Z. Genetic algorithms, numerical optimization and constraints. *Proc. of the Sixth Int. Conf. on Genetic Algorithms and their Applications*, Pittsburgh, PA, 1995, pp. 239–247.
37. Srinivas N., Deb K. Multiple-Objective function optimization using non-dominated sorting genetic algorithms. *Evolutionary Computation*, 1995, vol. 2, pp. 221–248.
38. Wang X. L., Mahfouf M. ACSAMO: An Adaptive Multiobjective Optimization Algorithm using the Clonal Selection Principle. *2nd European Symposium on Nature-Inspired Smart Information Systems*, 2006, pp. 1–12.
39. Zhang Z. Constrained Multiobjective Optimization Immune Algorithm: Convergence and Application. *Computers and Mathematics with Applications*, 2006, vol. 52 (5), pp. 791–808.

УДК 004.5:612.88

НЕЙРОСЕТЕВОЙ АНАЛИЗ ВЗАИМОДЕЙСТВИЯ МЕХАНИЗМОВ ПОСТУРАЛЬНОГО КОНТРОЛЯ ПРИ ВВЕДЕНИИ ИСКУССТВЕННОЙ ОБРАТНОЙ СВЯЗИ

Статья поступила в редакцию 26.05.2016, в окончательном варианте 18.06.2016.

Горшков Олег Георгиевич, преподаватель, Донецкий национальный медицинский университет, 83003, ДНР, г. Донецк, пр. Ильича, 16, e-mail: olgor22@yahoo.com

Старченко Ирина Борисовна, доктор технических наук, профессор, Южный федеральный университет, 347922, Российская Федерация, г. Таганрог, ул. Шевченко, 2, e-mail: star@fer.tti.sfedu.ru

Слива Андрей Сергеевич, аспирант, Южный федеральный университет, 347922, Российская Федерация, г. Таганрог, ул. Шевченко, 2, e-mail: stabilan@orbritm.com.ru

В исследовании системы регуляции движений человека ключевое место принадлежит изучению поддержания им вертикальной позы. Большой вклад в изучении механизмов регуляции вертикальной позы человека внесли J.J. Collins и С.J. De Luca. Ими была предложена методика оценки фрактальных свойств стабилотрамм – stabilogram diffusion analysis (SDA). Эта методика позволила выделить два механизма постурального контроля (ПК) – «открытая петля» и «закрытая петля». В данной работе исследовалось взаимодействие этих механизмов ПК в антеропостериорном и медиолатеральном направлениях при искусственном усилении контроля за счет введения искусственной обратной