

УДК 519.71(575.1)

ГИБРИДНЫЙ АЛГОРИТМ ОБУЧЕНИЯ ДЛЯ ОПТИМИЗАЦИИ РЕШЕНИЯ ЗАДАЧ МОНИТОРИНГА

Ниёзматова Н.А.

старший научный сотрудник-исследователь Центра разработки программных продуктов и аппаратно-программных комплексов при Ташкентском университете информационных технологий, тел.: +(99893) 506-26-22, e-mail: n_nilufar@mail.ru

В прикладных интеллектуальных системах мониторинга и поддержки принятия слабо формализуемых решений основными функциональными задачами являются классификация, кластеризация, распознавание образов, прогнозирование, оценка состояний, выявление закономерностей между параметрами различных типов, оптимизация и принятие решений. Отличительными особенностями решаемых задач указанных типов являются большая размерность, многокритериальность, наличие неопределенностей в исходной информации и ситуации, динамичность изменения параметров внешней среды, предсказуемость которых, зачастую, является затруднительной или невозможной. Эти особенности обуславливают использование для решения указанных задач, наряду с традиционными методами и средствами исследования операций и интеллектуального анализа данных (ИАД), интеллектуальных технологий, основанных на неформальных эмпирических знаниях экспертов и логических рассуждениях, а также на природно-биологических механизмах обучения, эволюции, адаптации и оптимизации.

Ключевые слова: гибридный алгоритм, задача оптимизации, интеллектуальная система, многокритериальность.

HYBRID ALGORITHM OF LEARNING FOR OPTIMIZATION OF SOLUTIONS FOR MONITORING

Niyozmatova N.A.

The application of intelligent monitoring systems and support decision-making weakly formalized basic functional tasks are classification, clustering, pattern recognition, forecasting, assessment of conditions, identification of patterns between the parameters of different types of optimization and decision making. Distinctive features of these types of tasks are the following: large dimensionality multicriteriality, the uncertainties in the initial information and the situation, the dynamic changes in the environment settings, predictability which often is difficult or impossible. These features cause the use to solve these problems, along with traditional methods and tools of operations research and data mining (IBP), intelligent technologies based on informal empirical knowledge of experts and logical reasoning, as well as natural and biological mechanisms of learning, evolution, adaptation and optimization.

Keywords: hybrid algorithm, optimization problem, an intelligent system, multicriteriality.

МОНИТОРИНГ МАСАЛАСИНИ ЕЧИМИНИ ОПТИМАЛЛАШТИРИШ УЧУН ЎҚИТИШНИНГ ГИБРИД АЛГОРИТМИ

Ниёзматова Н.А.

Мониторинг ва сушт шаклланган ечимларни қабул қилишни қўллаб қувватлашнинг амалий интеллектуал тизимларида асосий функционал масалалар классификация, кластеризация, тимсолларни аниқлаш, башоратлаш, ҳолатларни баҳолаш, турли типдаги параметрлар ўртасида қонуниятни аниқлаш, оптимизация ва қарор қабул қилиш ҳисобланади. Кўрсатилган типдаги ечиладиган масалаларнинг фарқли хусусияти қуйидагилар ҳисобланади: ўлчамнинг катталиги, кўп мезонлилиқ, бошланғич ахборот ва ҳолатларда ноаниқликларни мавжудлиги, ташқи муҳит параметрлари ўзгаришининг динамиклиги, уларни башорат қилиш қийин ва мумкин эмас ҳисобланади. Ушбу хусусиятлар кўрсатилган масалаларни ечиш учун маълумотларни интеллектуал таҳлил қилиш ва амалларни тадқиқ қилиш анъанавий усул ва воситалари билан бир қаторда мантиқий фикрлаш ва экспертларнинг ноформал эмпирик билимларига, ҳамда оптимизация, мослашув, эволюция ва ўқитиш механизмларига асосланган интеллектуал технологияларни қўллашни талаб этади.

Таянч иборалар: гибридный алгоритм, оптимизация масаласи, интеллектуал тизим, кўп мезонлилиқ.

1. Введение

В настоящее время системы мониторинга являются весьма эффективной технологией автоматизированного управления динамическими системами во

многих отраслях промышленности. Современные системы мониторинга имеют схожие возможности и принципы функционирования, которые позволяют решать типовые задачи, такие как: мониторинг и сбор данных о протекании технологического

процесса, управление при наличии четких алгоритмов и полной формализованной модели объекта управления.

Интеллектуализация является главным направлением развития современных технологий, а свойство интеллектуальности присуще всем новейшим информационно-управляющим системам. Эти выводы вытекают из практического опыта работы ведущих промышленных фирм и компаний, занимающихся проблемами автоматизации управления в самых различных областях. Опыт последнего десятилетия по решению множества практических задач и созданию практически действующих систем показал, что именно интеллектуальные технологии оказываются наиболее конструктивными и экономически оправданными при разработке современных систем автоматизированного управления [1, 2].

Примерами таких интеллектуальных технологий, получивших наибольшее развитие и использование, являются экспертные системы (ЭС), технологии Soft Computing (SC), включающие нечеткие множества, нейронные сети (НС) и генетические алгоритмы (ГА); эволюционные алгоритмы (Swarm intelligence – роевого интеллекта: муравьиные, пчелиные, стаи птиц и рыб) [3-10]. Поэтому представляет интерес исследование возможностей и определения основных направлений по совместному использованию интеллектуальных технологий для создания гибридных интеллектуальных, в том числе эволюционных, алгоритмов и программных средств, которые обеспечат более высокую эффективность решения исследуемых задач [11-15].

2. Гибридный алгоритм обучения

Гибридный алгоритм обучения нечетких сетей можно считать вариантом гибридного алгоритма обучения радиальных сетей [3-4].

Алгоритм реализуется чередованием двух этапов:

1 - при зафиксированных значениях нелинейных параметров c_{ij} , s_{ij} и b_{ij} первого слоя нейронов отыскиваются значения линейных параметров p_{ij} третьего слоя сети;

2 - при зафиксированных значениях линейных параметров p_{ij} третьего слоя уточняются нелинейные параметры c_{ij} , s_{ij} и b_{ij} первого слоя сети.

Этап 1. На данном этапе обучения нелинейные параметры фиксированы. Выходной сигнал определяется как

$$y(X) = \sum_{i=1}^M (w' * (p_{i0} + \sum_{j=1}^N (p_{ij} * x_j))),$$

где

$$w' = v_i = \text{prod}[j=1:N](\mu_{ij}(x_j)) / \sum_{i=1}^M [(\prod_{j=1}^N (\mu_{ij}(x_j)))] = \text{const.}$$

Для K обучающих выборок $\langle X^k, d^k \rangle$, $k=1, 2, \dots, K$, получаем систему K линейных уравнений:

$$A * P = D,$$

где $P = [p_{10}, p_{11}, \dots, p_{1N}, p_{M0}, p_{M1}, \dots, p_{MN}]^T$ - вектор весов третьего слоя сети, а $D = [d^1, d^2, \dots, d^k]^T$ - вектор ожидаемых значений, составленный из всех K обучающих выборок.

Матрица A имеет вид

$$\begin{matrix} v_1^1 & v_1^1 * x_1^1 & \dots & v_1^1 * x_N^1 & \dots & v_M^1 & v_M^1 * x_1^1 & \dots & v_M^1 * x_N^1, \\ v_1^2 & v_1^2 * x_1^2 & \dots & v_1^2 * x_N^2 & \dots & v_M^2 & v_M^2 * x_1^2 & \dots & v_M^2 * x_N^2, \\ \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots, \\ v_1^k & v_1^k * x_1^k & \dots & v_1^k * x_N^k & \dots & v_M^k & v_M^k * x_1^k & \dots & v_M^k * x_N^k. \end{matrix}$$

Количество строк K матрицы A значительно больше количества ее столбцов $M(N+1)$. Решение этой системы линейных алгебраических уравнений можем получить за один шаг следующим образом:

$$P = A^{-1} * D,$$

где A^{-1} - обратная матрица A .

Этап 2. Здесь фиксируются значения коэффициентов полиномов третьего слоя, и осуществляется уточнение (обычно многократное) коэффициентов функции Гаусса для первого слоя сети стандартным методом градиента:

$$\begin{aligned} c_{ij}^{k+1} &= c_{ij}^k - v_c * \partial E^k / \partial c_{ij}^k, \\ s_{ij}^{k+1} &= s_{ij}^k - v_s * \partial E^k / \partial s_{ij}^k, \\ b_{ij}^{k+1} &= b_{ij}^k - v_b * \partial E^k / \partial b_{ij}^k, \end{aligned}$$

где k - номер очередного цикла обучения (в режиме онлайн он совпадает с номером обучающей выборки).

С технической точки зрения получение аналитических выражений для производных целевой функции по нелинейным параметрам проблем не представляет. Однако здесь в силу громоздкости эти выражения не приводятся. Они приведены в [16-21].

Поскольку в череде этапов этап уточнения нелинейных параметров функции Гаусса имеет много меньшую скорость сходимости, то в ходе обучения реализацию этапа 1, как правило, сопровождает реализация нескольких этапов 2.

3. Нечеткие сети с самоорганизацией

Сети данного типа на этапе обучения осуществляют группирование входных векторов X^k , $k=1, 2, \dots, p$, в M кластеров, каждый из которых определяется своим центром $C_i, i=1, 2, \dots, M$. На этапе классификации сеть отождествляет очередной входной вектор данных X с одним из ранее определенных кластеров.

Нечеткая сеть с самоорганизацией имеет простую двухслойную структуру.

Нейроны первого слоя реализуют обобщенную функцию Гаусса в рациональной форме:

$$\mu_{ij}(x_j) = 1 / (1 + ((x_j - c_{ij}) / s_{ij})_{ij}^{2*b}).$$

Каждый нейрон второго слоя характеризуется центром $C_i = [u_{1i}, u_{2i}, \dots, u_{Ni}]^T$.

4. Алгоритм нечеткой самоорганизации C-means

В данном алгоритме подаваемый на вход очередной обучающий вектор X^k принадлежит различным кластерам (представленным своими центрами $C_i, i=1, 2, \dots, M$) в степени $u_i^k, 0 < u_i^k < 1$, при соблюдении условия

$$\sum_{i=1}^M (u_i^k) = 1.$$

При этом значение u_i^k тем больше, чем ближе X^k к C_i .

Погрешность соотнесения обучающих векторов X^k и центров C_i для всех p обучающих векторов выражается следующим образом:

$$E = \sum_{i=1}^M \left(\sum_{k=1}^p (u_i^k)^m * |X^k - C_i|_2 \right),$$

где m - показатель, выбираемый из ряда 1, 2, 3, ...

Цель обучения - подбор таких значений центров C_i , которые обеспечивают минимальное значение погрешности E при одновременном соблюдении условия

$$\sum_{i=1}^M (u_i^k) = 1.$$

Решение этой задачи можно свести к минимизации функции Лагранжа в виде

$$LE = \sum_{i=1}^M \left(\sum_{k=1}^p ((u_i^k)^m * |X^k - C_i|_2) \right) + \sum_{k=1}^p (L_k * (\sum_{i=1}^M (u_i^k) - 1)),$$

где $L_k, k=1, 2, \dots, p$ - множители Лагранжа.

Доказано, что решение этой задачи можно представить в виде

$$C_i = \frac{\sum_{k=1}^p ((u_i^k)^m * X^k)}{\sum_{k=1}^p ((u_i^k)^m)},$$

$$u_i^k = 1 / \sum_{l=1}^M (((d_i^k)^2 / (d_l^k)^2))^{1/(m-1)},$$

где $d_i^k = |X^k - C_i|_2$ - евклидово расстояние между X^k и C_i .

Алгоритм обучения, реализующий описанную выше идею, получил название C-means. Он носит итерационный характер и описывается следующим образом:

1. Выполнить случайный выбор коэффициентов u_i^k из диапазона $[0,1]$ при соблюдении условия $\sum_{i=1}^M (u_i^k) = 1$.

2. Вычислить все M центров C_i по приведенной выше формуле.

3. Рассчитать значение погрешности E . Если это значение меньше установленного порога или незначительно изменилось относительно

предыдущей итерации, то закончить вычисления. Иначе перейти к п. 4.

4. Рассчитать новые значения u_i^k по приведенной выше формуле и перейти к п. 2.

Описанный выше итерационный алгоритм ведет к достижению минимума погрешности E , который, однако, необязательно будет глобальным минимумом. На вероятность отыскания глобального минимума влияет выбор начальных значений u_i^k и C_i . Специально для подбора «хороших» начальных значений центров C_i разработаны процедуры инициализации, две из которых представлены ниже.

5. Алгоритм пикового группирования

Для отыскания «первого приближения» к наилучшему расположению центров C_i в данном алгоритме используются так называемые *пиковые* функции. При подаче на вход сети p обучающих векторов X^k создается равномерная сетка, покрывающая все пространство, занимаемое данными векторами [16-19].

Узлы сетки обозначим как V_j , для каждого из них рассчитывается значение пиковой функции

$$m(V_j) = \sum_{k=1}^p (\exp(-(|X^k - V_j|_2^{2*b} / (2 * s^2))),$$

где s - константа, индивидуально подбираемая для каждой задачи.

Значение $m(V_j)$ пропорционально количеству обучающих векторов X^k , находящихся в окрестности потенциального центра V_j . Малое значение $m(V_j)$ говорит о том, что V_j в области, где количество векторов X^k мало. Следует отметить, что коэффициент s оказывает незначительное влияние на соотношение значений V_j для разных узлов сетки, поэтому подбор его величины не является критичным.

После расчета $m(V_j)$ для всех потенциальных центров (узлов сетки) отбирается узел, имеющий наибольшее значение пиковой функции. С этим узлом отождествляется первый центр C_1 . Для выбора аналогичным образом следующего центра из рассмотрения исключаются центр C_1 и соседние с ним узлы сетки. Это удобно сделать переопределением пиковой функции:

$$m_{new}(V_j) = m(V_j) - m(C_1) * \exp(-(|V_j - C_1|_2^{2*b} / (2 * s^2))),$$

где $m(C_1)$ - значение пиковой функции в центре C_1 .

Процесс последовательного отыскания центров C_1, C_2, C_3, \dots завершается после обнаружения центра C_M .

Основной недостаток алгоритма пикового группирования - экспоненциальный рост сложности с увеличением размерности векторов входных данных X^k . Следовательно, он применим лишь при небольшом количестве входных сигналов N .

Представленный далее алгоритм также имеет экспоненциальный рост сложности, но это рост в зависимости от количества обучающих выборок p .

6. Алгоритм разностного группирования

В этом алгоритме в качестве потенциальных центров рассматриваются обучающие векторы $X^k, k = 1, 2, \dots, p$. Пиковая функция $m(X^i)$ определяется в следующем виде [19-23]:

$$m(X^i) = \sum_{k=1}^p (\exp(-(|X^k - X^i|^{2* b} / (r_1 / 2)^2))),$$

где значение коэффициента r_1 определяет размер сферы соседства. При большой плотности входных векторов вокруг X^i значение функции велико, и, напротив, малое значение $m(X^i)$ свидетельствует о незначительном количестве соседей.

После расчета значений $m(X^i)$ для всех входных векторов в качестве первого центра C_1 принимается X^i с наибольшим значением пиковой функции.

Для отыскания второго центра используется модифицированная пиковая функция в виде

$$m_{new}(X^i) = m(X^i) - m(C_1) * \exp(-(|X^k - C_1|_2^{2* b} / (r_2 / 2)^2)),$$

где r_2 задает новый размер сферы соседства, обычно $r_2 \geq r_1$.

Пиковая функция $m_{new}(X^i)$ принимает нулевое значение для $X^i = C_1$.

7. Иммунный алгоритм для интеллектуальной обработки информации

Иммунные алгоритмы (ИА) широко используются в различных областях интеллектуальной обработки информации [24]. Свойства искусственных иммунных систем (ИИС), такие как распознавание, разнообразие, обучение, память, распределенное обнаружение и др., позволяют использовать иммунные принципы для решения таких задач, как распознавание образов, поиск данных, компьютерная безопасность, обнаружение ошибок, классификация, оптимизация и др. [1].

В ИИС используется способность естественной иммунной системы вырабатывать новые типы антител и отбирать наиболее подходящие из них для взаимодействия с попавшими в организм антигенами [25]. Для объяснения иммунологических механизмов существуют различные теории – теория иммунной сети, принципы клонального и негативного отбора.

Естественная иммунная система состоит из большого количества защитных элементов, молекул и органических соединений, поддерживающих организм в здоровом состоянии, борясь с болезнями, служащими причиной заболеваний. Защитные элементы, используемые в естественной иммунной системе, называются лимфоцитами (белые кровяные

тельца), главная задача которых – борьба с антигенами, молекулами, принадлежащими чужеродным телам, таким, как бактерии или вирусы, которые внедрились в организм.

Защитная реакция организма в борьбе с болезнью состоит в том, что он начинает вырабатывать клетки (антитела), способные распознать и нейтрализовать антигены. Клетки, полученные в результате мутационного процесса, имеют большое сходство с антигенами, и большее время жизни остаются в организме на случай, если в будущем атака повторится (память клетки). Пока процент клонирования прямо пропорционален сходству с антигенами, процент мутации обратно пропорционален такой схожести, поэтому, чем ближе клетка к антигену, тем меньше процент ее мутации. С другой стороны, если сходство антигена и клетки очень низкое, высокий процент мутации применяется в надежде повысить значение сходства [25].

Для эволюционных алгоритмов известно [3], что сходимость к глобальному оптимуму в задаче оптимизации достигается в том случае, если есть уверенность в том, что алгоритм находит решение за конечное число шагов, и если такое решение будет оставаться в дальнейшем в популяции. Поскольку состояния переходов эволюционных алгоритмов имеют стохастический характер, детерминированная концепция сходимости не может быть использована для определения срока действия таких алгоритмов. Существуют две широко используемые меры стохастической сходимости эволюционных алгоритмов – это полное совпадение и совпадение по значению [7].

В вычислительных процедурах иммунокомпьютинга в качестве аналога расстояния используется понятие энергии связи, основанное на сингулярном разложении матрицы. Энергия связи между объектами A и M представляется следующим образом:

$$\omega_i = -U_i^T M V_i, U_i^T U_i = 1, V_i^T V_i = 1, i = 1, 2, \dots, r,$$

где U_i, V_i – соответственно правые и левые сингулярные векторы матрицы A, r – ранг матрицы.

Алгоритм вычислительной процедуры обучения с экспертом состоит из следующих шагов:

Шаг 1. Сворачивание вектора в матрицу. Заданный вектор X размерности $(n \times 1)$ сворачиваем в матрицу M размерности $n_U \times n_V = n$.

Шаг 2. Формируем матрицы A_1, A_2, \dots, A_k для эталонных классов $c = 1, \dots, k$ и вычисляем их сингулярные векторы:

$$\{U_1, V_1\} - \text{для } A_1, \{U_2, V_2\} - \text{для } A_2, \\ \{U_k, V_k\} - \text{для } A_k.$$

Шаг 3. Распознавание. Для каждого входного образа M вычисляем k значений энергии связи между каждой парой сингулярных векторов:

$$\omega_1 = -U_1^T M V_1, \dots, \omega_k = -U_k^T M V_k.$$

Шаг 4. Определяем класс, к которому принадлежит входной образ M . Минимальное значение энергии связи ω^* определяет этот класс:

$$c = \omega^* = \min_c \{\omega_c\}.$$

Основные вычислительные процедуры оценки состояния слабоформализуемых процессов основаны на свойствах сингулярного разложения произвольных матриц и математическом аппарате иммунокомпьютинга.

Как известно, для произвольной матрицы A размерности $(m \times n)$ существует так называемое сингулярное разложение, т.е. представление матрицы в виде

$$A = USV^T,$$

где $U - (m \times m)$ и $V - (n \times n)$ – ортогональные квадратные матрицы, удовлетворяющие критерию ортогональности:

$$VV^T = V^T V = E_{m \times m},$$

$$UU^T = U^T U = E_{n \times n};$$

здесь E – единичные матрицы соответствующих размерностей.

Матрица S состоит из квадратного диагонального блока размерности $r \times r$ ($r = \min(m, n)$) с неотрицательными элементами на главной диагонали и, если $n \neq m$, из дополнительных нулевых строк или столбцов:

$$S = [S'; 0], \text{ если } m < n,$$

$$S = [S'; 0]^T, \text{ если } m > n,$$

$$S = S', \text{ если } m = n,$$

$$S' = \text{diag}\{s_1, s_2, \dots, s_r, s_1 \geq s_2 \geq \dots \geq s_r\}.$$

Числа $s_i, i = 1, 2, \dots, r$ называются сингулярными числами матрицы A , которые определяются матрицей A однозначно.

Сингулярное разложение вещественной прямоугольной матрицы A в покомпонентной форме имеет следующее представление:

$$A = s_1 U_1 V_1^T + s_2 U_2 V_2^T + \dots + s_r U_r V_r^T, \quad (1)$$

где s_i – сингулярные числа матрицы A ; U_i, V_i – соответственно правые и левые сингулярные векторы, r – ранг матрицы.

Эти сингулярные числа и сингулярные векторы удовлетворяют следующим соотношениям:

$$s_1 \geq s_2 \geq \dots \geq s_r \geq 0,$$

$$s_i = U_i^T A V_i, U_i^T U_i = 1,$$

$$V_i^T V_i = 1, i = 1, \dots, r \quad (2)$$

Известно, что процессы сингулярного разложения для любой вещественной матрицы A обладают весьма полезными свойствами для теории и приложений, а именно: каждая матрица над полем вещественных чисел имеет вещественные сингулярные числа и векторы. Кроме того, сингулярное разложение матриц устойчиво к малым возмущениям матриц, т.е. сингулярное разложение каждой матрицы является хорошо обусловленной процедурой.

Относительно практических аспектов, сингулярное разложение матрицы в общем случае может быть получено по достаточно простой и надежной схеме:

$$V_{(k+1)}^T = U_{(k)}^T A, V_{(k+1)} = V_{(k+1)} / |V_{(k+1)}|,$$

$$U_{(k+1)} = A V_{(k+1)},$$

$$U_{(k+1)} = U_{(k+1)} / |U_{(k+1)}|, \quad (3)$$

$$s_k = U_k^T A V_k, |s_{k+1} - s_k| \leq \varepsilon,$$

где $k = 0, 1, 2, \dots$ – номер итерации, $|U_{(k+1)}|$ – любая векторная норма, ε – заданная точность вычисления.

Можно показать, что для произвольных начальных векторов $U_{(0)}, V_{(0)}$ итерации по схеме (3) сходятся в общем случае к сингулярным векторам U, V , соответствующим максимальному сингулярному числу $s_{\max} = U^T A V$.

Следует отметить, что такие свойства не свойственны спектральному разложению, которое в действительности формирует основу для многомерного статистического анализа. В отличие от сингулярного разложения матриц, собственные числа и собственные векторы спектрального разложения являются вещественными только для вещественных симметрических матриц, в общем случае не симметрические вещественные матрицы обладают комплексным спектром, который определить не просто.

С использованием приведенного выше итеративного алгоритма (3) сингулярное разложение матрицы A , представленное в форме (1), (2), может быть получено с использованием метода исчерпывания.

Сущность этого метода заключается в следующем:

- максимальное сингулярное число и соответствующие ему правый и левый сингулярные векторы матрицы A вычисляются с помощью итеративного алгоритма (3). Формируется матричная компонента $A_1 = s_1 U_1 V_1^T$;

- формируется матрица невязки

$$A_2 = A - A_1 = A - s_1 U_1 V_1^T,$$

для которой максимальное сингулярное число и соответствующие ему правый и левый сингулярный векторы матрицы A_2 вычисляются с помощью итеративного алгоритма (3) и т.д.

Данный алгоритм иммунокомпьютинга может быть рассмотрен как «иммунный» алгоритм, так как любой образ может быть представлен как частный случай формального протеина и его распознавание основывается на энергии связи с антителом формального протеина.

8. Заключение

Таким образом, гибридный алгоритм обучения для оптимизации решения задач мониторинга позволяет с большой эффективностью решать следующие задачи: обучение с экспертом, самообучение (обучение без эксперта), группировка и классификация, представление результатов вычислений в пространстве образов.

Литература

- [1] Барсегян А.А., Куприянов М.С., Степаненко В.В., Холод И.И. Технология анализа данных: Data Mining, Visual Mining, Text Mining, OLAP : Уч. Пособие. – 2-е изд. – СПб.: БХВ – Петербург, 2007. – 384 с.: ил. + CD-ROM.
- [2] Zadeh L.A. What is Soft Computing? Soft Computing 1 (1997).
- [3] Wang X. Hybrid nature-inspired computation method for optimization / Doctoral Dissertation. Helsinki University of Technology, TKK Dissertations, Espoo 2009. - 161 p.
- [4] Raidl G.R. A Unified View on Hybrid Metaheuristics // Lecture Notes in Computer Science.– Springer-Verlag, 2006, Vol. 4030. – Pp. 1-12.
- [5] El-Abd, Kamel M. A taxonomy of cooperative search algorithms / Hybrid Metaheuristics: Second International Workshop. - Springer, 2005. - Vol. 3636. - Pp. 32-41.
- [6] Krasnogor N. Studies on the Theory and Design Space of Memetic Algorithms, Ph.D. Thesis, Faculty of Computing, Mathematics and Engineering, University of the West of England, Bristol, U.K., 2002. - 289 p.
- [7] Eiben A.E., Michalewicz Z., Schoenauer M., Smith J.E. Parameter Control in Evolutionary Algorithms / Parameter Setting in Evolutionary Algorithms. - Springer Verlag, 2007. - Pp. 19-46.
- [8] Smith J.E., Fogarty T.C. Operator and parameter adaptation in genetic algorithms // Soft Computing, 1997. - № 1. - Pp. 81-87.
- [9] Карпенко А.П., Селиверстов Е.Ю. (2008) Обзор методов роя частиц (PSO) для задачи глобальной оптимизации // Наука и образование: электронное научно-техническое издание, www.technomag.edu.ru, март, 2009.
- [10] Chen M.-R., Lu Y.-Z., Luo Q. A novel hybrid algorithm with marriage of particle-swarm optimization and extremely optimization // Optimization Online, May 2007 (http://www.optimization-online.org/ARCHIVE_DIGEST/2007-05.html).
- [11] Мухамедиева Д.Т. Алгоритм кластеризации правил систем нечеткого вывода // Естественные и технические науки. – Москва, 2013. - № 2. - С.248-252.
- [12] Бекмуратов Т.Ф., Мухамедиева Д.Т. Подходы к решению задачи многокритериальной оптимизации с нечеткой целью // Научный журнал «Проблемы информатики». – Новосибирск, 2014. - Вып.1. - С.3-9.
- [13] Мухамедиева Д.Т. Анализ особенностей генетических алгоритмов // Проблемы вычислительной и прикладной математики. – Ташкент, 2015. - № 1 (1). - С. 87-93.
- [14] Мухамедиева Д.Т., Примова Х.А., Ниезматова Н.А. Подходы к использованию Z-оценивания неопределенности в системах нечёткого вывода // Проблемы вычислительной и прикладной математики. – Ташкент, 2015. - № 2 (2). - С. 85-90.
- [15] Bekmuratov T.F., Mukhamedieva D.T. Neuro - fuzzy logic synthesis of fuzzy inference systems / Proceedings of Tenth International Conference on Application of Fuzzy Systems and Soft Computing ICAFS, Lisbon, Portugal, 2012. - Pp. 321-328.
- [16] Wang N., Qiu C., Niu X., Xue Z. A novel Online Self-organizing Fuzzy Neural Network for function approximation. Proceedings of the 9th IEEE International Conference on Cognitive Informatics, ICCI – 2010, art. no. 5599680, 2010. - Pp. 550-555.
- [17] Cheu E.Y., Quek C., Ng S.K. Time series forecasting with appetitive reward-based pseudo-outer-product fuzzy neural network. Proceedings of the International Joint Conference on Neural Networks , art. no. 5596738, 2010.
- [18] Liu K., Wei B., Liu B. Analysis model of slope deformation time series based on the genetic-adaptive neuron-fuzzy inference system. Journal of Beijing Jiaotong University, 36 (1), 2012. - Pp. 56-62.
- [19] Zadeh L., Neshat N., Kazemi A., Saberi M. Predictive control of drying process using an adaptive neuro-fuzzy and partial least squares approach. International Journal of Advanced Manufacturing Technology, 58 (5-8), 2012. -Pp. 585-596.
- [20] Malek H., Ebadzadeh M.M., Rahmati M. Three new fuzzy neural networks learning algorithms based on clustering, training error and genetic algorithm. Applied Intelligence, 2011. - Pp. 1-10.
- [21] Jin C., Chang G., Cheng W., Jiang H. Improved particle swarm optimization for fuzzy neural network training. Proceedings of the 5th International Conference on Genetic and Evolutionary Computing, ICGEC – 2011. art. no. 6042785, 2011. - Pp. 299-302.
- [22] Ye Y.-L. Structure and parameters optimization of fuzzy rough neural network. Systems Engineering and Electronics, 31 (12), 2009. - Pp. 2988-2993.
- [23] Lovassy R., Kóczy L.T., Gál L., Rudas I.J. Fuzzy neural networks stability in terms of the number of hidden layers. Proceedings of the 12th IEEE International Symposium on Computational Intelligence and Informatics, CINTI - 2011, art. no. 6108523, 2011. - Pp. 323-328.
- [24] Dasgupta D. Artificial Immune Systems and Their Applications, Springer-Verlag, 1998.
- [25] Дасгупта Д. Искусственные иммунные системы и их применение. – М.: Физматлит, 2006. - 344 с.