



УДК 004:615.838.036.8

© 2012 г. **И.А. Ходашинский**, д-р техн. наук,
И.В. Горбунов,
П.А. Дудин,
Д.С. Синьков

(Томский государственный университет систем управления и радиоэлектроники),
А.А. Зайцев, канд. мед. наук
(Томский НИИ курортологии и физиотерапии ФМБА России)

ПОСТРОЕНИЕ НЕЧЕТКИХ СИСТЕМ ПРОГНОЗИРОВАНИЯ ЭФФЕКТИВНОСТИ НЕМЕДИКАМЕНТОЗНОГО ЛЕЧЕНИЯ

Излагается метод подбора оздоровительных программ на основе нечетких классификаторов и аппроксиматоров. Идентификация нечетких систем ведется методами роевого интеллекта и методами, основанными на производных. Приведены результаты работы построенных систем на реальных данных.

Ключевые слова: прогноз эффективности лечения, нечеткий классификатор, нечеткий аппроксиматор, роевой интеллект.

Введение

Методы статистики и вычислительного интеллекта давно и успешно применяются для решения задач медицинской диагностики, мониторинга и прогнозирования. К наиболее часто применяемым в настоящее время методам относятся анализ выживания, логистическая регрессия, кластерный анализ, байесовские сети, искусственные нейронные сети, генетические алгоритмы, деревья решений. Методы вычислительного интеллекта с позиций обнаружения новых закономерностей в медицинских данных являются более сильными, чем традиционные статистические методы [1].

Подавляющее большинство работ по созданию моделей и программных средств в области медицины направлено на диагностику болезней. Меньшая часть проводимых математических и компьютерных исследований направлена на разработку методов и средств лечения и совсем незначительная часть — на выбор комплексов реабилитации. В обзорной статье [2] авторы отмечают, что работ по применению машинных методов обучения для решения задач диагностики рака на порядок больше, чем работ по прогнозу этого заболевания. Для предсказания рака авторы указанной работы анализируют такие методы машинного обучения как деревья решений, нейронные сети, метод опорных векторов, генетические алгоритмы и делают оптимистический вывод, что использование машинных клас-

сификаторов в медицинской практике станет намного более широким и доступным.

Необходимость поиска средств, способствующих оптимальной коррекции индивидуальных резервов организма, определяет важность выбора наиболее эффективных средств и методов профилактики, лечения и реабилитации. Одним из путей решения этой задачи является прогнозирование лечебного эффекта немедикаментозной терапии. Прогнозирование ведется на основе анализа ретроспективных данных до лечения и после ранее прошедших реабилитацию пациентов. Указанный анализ позволяет в полной мере учесть индивидуальные особенности вновь поступивших пациентов при назначении им реабилитационных комплексов лечения [3].

Решение задач медицинской классификации и прогнозирования, как правило, ведется в условиях дефицита экспериментальных данных, поэтому не всегда удается построить алгоритм, восстанавливающий искомую зависимость. В связи с тем, что число признаков в таблице наблюдений превышает число наблюдений (пациентов), применение таких статистических методов как логистическая регрессия и дискриминантный анализ затруднительно и даже невозможно [4].

Цель статьи – описание решения проблемы медицинской классификации и прогнозирования эффективности немедикаментозного лечения с помощью нечетких систем.

Прогнозируемые величины

На основании совокупности данных вычисляется индекс функционального напряжения организма $FNO = \text{Индекс_АГ} / \text{Индекс_РЛПО}$, где *индекс_АГ* – индекс адаптивных гормонов: отношение концентрации глюкокортикоидов (*KZ*) к инсулину (*IS*) в сыворотке крови; *индекс_РЛПО* – индекс резерва липидов для перекисного окисления.

После прохождения пациентом курса лечения у него также берутся анализы и вычисляется индекс FNO . При этом увеличение величины индекса FNO в динамике свидетельствует об усилении степени функционального напряжения организма, а уменьшение – о нормализации нарушенных функций.

Прогностической величиной служит $FNO_koef = FNO_{до} / FNO_{после}$. Значение данного индекса свидетельствует об эффективности лечения. Если $FNO_koef > 1$, значит, у пациента наступило улучшение после прохождения курса лечения, в противном случае – заметных улучшений не наблюдается [4].

После обучения на имеющихся прецедентах (обучающей выборке) нечеткая система позволит давать прогнозы о результативности лечения тем или иным комплексом для вновь поступивших пациентов.

Нечеткие системы

Обработка лингвистической информации в нечеткой системе происходит при помощи базы правил. Каждое правило состоит из двух частей: условной и заключительной. Антецедент, или условная часть (IF-часть) содержит утверждение

относительно значений входных переменных, в консеквенте, или заключительной части (THEN-части) указывается значение, которое принимает выходная переменная.

Для аппроксиматора i -е правило имеет следующий вид:

IF $x_1=A_{1i}$ AND $x_2=A_{2i}$ AND ... AND $x_n=A_{ni}$ THEN $y = r_i$,

где A_{ij} – лингвистический терм, которым оценивается переменная x_i ; r_j – действительное число, которым оценивается выход y (например, FNO_koef).

Нечеткий аппроксиматор осуществляет отображение $f : \mathfrak{R}^n \rightarrow \mathfrak{R}$:

$$f(\mathbf{x}) = \frac{\sum_{i=1}^R \mu_{A_{1i}}(x_1) \cdot \mu_{A_{2i}}(x_2) \cdot \dots \cdot \mu_{A_{ni}}(x_n) \cdot r_i}{\sum_{i=1}^R \mu_{A_{1i}}(x_1) \cdot \mu_{A_{2i}}(x_2) \cdot \dots \cdot \mu_{A_{ni}}(x_n)},$$

где \mathbf{x} – входной вектор; R – число правил; n – количество входных переменных; $\mu_{A_{ij}}$ – функция принадлежности.

Нечеткий аппроксиматор может быть представлен как

$$y = f(\mathbf{x}, \boldsymbol{\theta}, \mathbf{r}),$$

где $\boldsymbol{\theta} = \|\theta_1, \dots, \theta_N\|$ – вектор параметров антецедентов; $N = n \cdot$ (число параметров, описывающих одну функцию принадлежности) \cdot (число термов, описывающих одну входную переменную); y – скалярный выход системы, $\mathbf{r} = \|\ r_1, \dots, r_R \ \|$ – вектор параметров консеквентов.

Пусть дано множество обучающих данных (таблица наблюдений) $\{(\mathbf{x}_p, t_p), p = 1, \dots, m\}$, тогда среднеквадратическая функция ошибки, являющаяся численным критерием адекватности модели, вычисляется по следующей формуле:

$$E(\mathbf{x}_p, \boldsymbol{\theta}, \mathbf{r}) = \frac{\sqrt{\sum_{p=1}^m (t_p - f(\mathbf{x}_p, \boldsymbol{\theta}, \mathbf{r}))^2}}{m}.$$

Проблема идентификации нечеткого аппроксиматора сводится к проблеме поиска минимума заданной функции в многомерном пространстве, координаты которого соответствуют параметрам нечеткой системы. В силу того, что поверхность поиска в указанном пространстве имеет сложный рельеф, методы поиска, основанные только на производных, здесь не всегда эффективны. Для решения проблемы оптимизации параметров антецедентов предлагается использовать алгоритм роящихся частиц, алгоритмы муравьиной и пчелиной колонии, а для настройки консеквентов – метод наименьших квадратов [5].

Для нечеткого классификатора i -е правило представлено следующим образом:

IF $x_1=A_{1i}$ AND $x_2=A_{2i}$ AND ... AND $x_n=A_{ni}$ THEN class= c_j , $w=CF_i$,

где c_j – идентификатор j -го класса (в нашем случае $j \in [1, 3]$); CF_i – вес правила или уровень доверия i -му правилу, $CF_i \in [0, 1]$.

Нечеткая классификация описывается функцией $f : \mathfrak{R}^n \rightarrow [0,1]^m$, которая относит классифицируемый объект к каждому классу с определенной степенью принадлежности, вычисленной следующим образом:

$$\beta_j(\mathbf{x}) = \sum_{R_{ij}} \prod_{k=1}^n A_{ki}(x_k) \cdot CF_i, j = 1, 2, \dots, m.$$

Выходом классификатора является класс, определяемый следующим образом:

$$\text{class} = c_{j^*}, j^* = \arg \max_{1 \leq j \leq m} \beta_j.$$

Нечеткий классификатор может быть представлена как функция

$$c = f(\mathbf{x}, \Xi, \mathbf{CF}),$$

где Ξ – база правил.

Пусть дано множество обучающих данных (таблица наблюдений) $\{(\mathbf{x}_p, c_p), p = 1, \dots, z\}$, определим следующую единичную функцию

$$\text{delta}(p, \Xi, \mathbf{CF}) = \begin{cases} 1, & \text{если } c_p = f(\mathbf{x}_p, \Xi, \mathbf{CF}) \\ 0, & \text{иначе} \end{cases}, p = 1, 2, \dots, z,$$

тогда численный критерий адекватности системы классификации может быть выражен следующим образом:

$$E(\Xi, \mathbf{CF}) = \frac{\sum_{p=1}^z \text{delta}(p, \Xi, \mathbf{CF})}{z}.$$

Проблема оптимизации параметров нечеткого классификатора сводится к проблеме поиска максимума заданной функции в многомерном пространстве, координаты которого соответствуют параметрам нечеткой системы. Для оптимизации Ξ предлагается использовать алгоритм пчелиной колонии, который призван генерировать и изменять базу правил. Для настройки \mathbf{CF} предлагается использовать модифицированный алгоритм пчелиной колонии, учитывающий специфику реализации операции танца пчел [6].

Алгоритм роящихся частиц

Алгоритм роящихся частиц – это стохастический метод поиска, основанный на итеративном взаимодействии частиц, образующих рой [7]. Перемещение частицы в пространстве поиска определяют три фактора: инерция, память, сотрудничество. Инерция подразумевает, что частица не может мгновенно изменить направление своего движения. Каждая частица имеет память и хранит свою лучшую позицию в пространстве поиска. Известна частице и лучшая позиция роя. Зная эти две позиции, частица динамически изменяет скорость согласно ее собственному опыту и опыту полета других частиц. Таким образом, движение каждой частицы задается ее лучшей позицией, ее текущей скоростью, ускорением, заданным предыдущей позицией, и ускорением, заданным лучшей частицей в рое. Рой прекращает движение при выполнении хотя бы одного из следующих условий: рой достиг состояния равновесия, найдено оптимальное решение (ошибка меньше заданной), выполнено заданное количество итераций.

В нашем случае пространство поиска $\theta \subset \mathbb{R}^N$, рой состоит из M частиц [8, 9]. Позиция i -й частицы определяется вектором

$$\mathbf{x}_i = (\theta_{i1}, \theta_{i2}, \dots, \theta_{iN}) \in \Theta.$$

Лучшая позиция, которую занимала i -я частица, определяется вектором

$$\mathbf{p}_i = (p_{i1}, p_{i2}, \dots, p_{iN}) \in \Theta.$$

Скорость частицы определяется также N -местным вектором

$$\mathbf{v}_i = (v_{i1}, v_{i2}, \dots, v_{iN}) \in \Theta.$$

Скорость и положение i -й частиц на $k+1$ шаге определяют следующие уравнения:

$$\mathbf{v}_i(k+1) = w \cdot \mathbf{v}_i(k) + c_1 \cdot rand \cdot (\mathbf{p}_i(k) - \mathbf{x}_i(k)) + c_2 \cdot Rand \cdot (\mathbf{p}_g(k) - \mathbf{x}_i(k)),$$

$$\mathbf{x}_i(k+1) = \mathbf{x}_i(k) + \mathbf{v}_i(k+1),$$

где $i = 1, 2, \dots, M$; $\mathbf{v}_i(k)$ – вектор скорости частицы i на итерации k ; $\mathbf{x}_i(k)$ – координаты частицы i на итерации k ; c_1, c_2 – положительные коэффициенты ускорения; $\mathbf{p}_i(k)$ – лучшая позиция частицы i на первых k итерациях; $\mathbf{p}_g(k)$ – глобально лучшая позиция частицы в рою на первых k итерациях (задается индексом g); w – эмпирический коэффициент инерции; $rand, Rand$ – случайные числа из интервала $[0, 1]$.

Коэффициент c_1 является когнитивным (познавательным) параметром, отражающим доверие частицы к ее собственному прошлому опыту, этот коэффициент ответственен за обнаружение новых областей в пространстве поиска. Коэффициент c_2 является социальным параметром, показывающим, насколько частица доверяет рою, этот коэффициент ответственен за исследование окрестностей ранее найденной перспективной области. Коэффициент w инерции ответственен за изменение скорости, управляет обнаружением новых областей и поиском в окрестностях перспективной области.

Непрерывный алгоритм муравьиной колонии

В классическом алгоритме муравьиной колонии при выборе дуги муравей «руководствуется» дискретным распределением вероятности [10, 11]. В случае непрерывного алгоритма выбор, который делает муравей, не ограничен конечным множеством, здесь дискретное распределение заменяется непрерывным, заданным своей функцией плотности [12]. В непрерывном алгоритме используется функция плотности вероятности с гауссовым ядром (Gaussian kernel probability density function). Гауссово ядро $G^i(x)$ в работе основано на взвешенной сумме нескольких одномерных гауссовых функций g_l^i :

$$G^i(x) = \sum_{l=1}^k \omega_l g_l^i(x) = \sum_{l=1}^k \omega_l \frac{1}{\sigma_l^i \sqrt{2\pi}} e^{-\frac{(x-\theta_l^i)^2}{2\sigma_l^{i2}}}.$$

Каждому параметру нечеткой системы соответствует свое гауссово ядро, $i = 1, \dots, N$; N – число идентифицируемых параметров. Каждая функция $G^i(x)$ описывается тремя векторами: $\boldsymbol{\theta}^i = \{\theta_1^i, \theta_2^i, \dots, \theta_k^i\}$; $\boldsymbol{\omega}$ – вектор весов, связанных с индивидуальными гауссовыми функциями; $\boldsymbol{\sigma}^i$ – вектор среднеквадратичных отклонений. Последний вычисляется следующим образом:

$$\sigma_l^i = \xi \sum_{j=1}^k \frac{|\theta_j^i - \theta_l^i|}{k-1}.$$

Параметр $\xi > 0$ одинаков для всех размерностей и имеет эффект подобный норме испарения феромона в дискретном алгоритме муравьиной колонии. Чем больше значение ξ , тем ниже скорость сходимости алгоритма [12].

В непрерывном алгоритме вводится понятие архива решений. Архив решений представлен таблицей, в которой k строк. Каждая строка состоит из трех частей:

- 1) найденное муравьем решение $\theta_l = \{\theta_l^1, \theta_l^2, \dots, \theta_l^N\}$;
- 2) ошибка, вычисленная нечеткой системой;
- 3) вес решения ω_l .

Решения упорядочены в архиве по возрастанию ошибки. Вес ω_l решения θ_l вычисляется согласно формуле:

$$\omega_l = \frac{1}{qk\sqrt{2\pi}} e^{-\frac{(l-1)^2}{2q^2k^2}},$$

где q – задаваемый параметр алгоритма.

При добавлении нового решения в архив худшее из них удаляется. Этот процесс аналогичен процессу испарения феромона в классическом алгоритме.

Муравьи в алгоритме делятся на колонии, каждая из которых отвечает за нахождение параметров своей функции принадлежности. У каждой колонии свой независимый архив решений [13].

Прямой алгоритм муравьиной колонии

В прямом алгоритме [14] муравей отвечает за вычисление значений закрепленного за ним параметра, поэтому муравьев в алгоритме столько, сколько параметров нечеткой модели. Каждый i -й муравей создает свое решение, генерируя нормально распределенное действительное число $N(\mu_i, \sigma_i)$. В алгоритме используются два вида феромонов: первый связан с центрами нормальных распределений $\mu = \|\mu_1, \dots, \mu_M\|$, второй – с разбросом $\sigma = \|\sigma_1, \dots, \sigma_M\|$. Количество феромона определяет значения параметров μ и σ . Для каждого параметра θ_j задан интервал изменения $[a_j, b_j]$, где b_j и a_j — верхняя и нижняя граница параметра θ_j .

В качестве начальных значений для параметров μ используются заданные случайным или иным способом значения параметров θ . Начальные значения параметров σ вычисляются по следующей формуле:

$$\sigma_i = \frac{b_i - a_i}{2}.$$

После того как муравьи нашли решения, определяется испарение феромона. Для текущей t -й итерации испарение определяется следующим образом:

$$\mu(t) = (1-\rho) \mu(t-1), \quad \sigma(t) = (1-\rho) \sigma(t-1),$$

где ρ – эмпирический коэффициент испарения феромона, заданный на интервале $[0, 1]$.

Далее происходит нанесение феромона:

$$\mu(t) = \mu(t) + \rho\theta(t), \quad \sigma(t) = \sigma(t) + \rho|\theta(t) - \mu(t)|,$$

где $\theta(t)$ – решение найденное муравьиной колонией на текущей итерации, оно совпадает с глобальным лучшим решением.

Особенностью прямого алгоритма является включение в него простейшего локального поиска, состоящего из двух этапов: на первом значение параметра θ_j увеличивается с определенным шагом до значения $\theta_j + d_j$, на втором этапе значение параметра уменьшается с определенным шагом до значения $\theta_j - d_j$. Значение d_j определяется по формуле:

$$d_j = \sigma_j \text{ rand},$$

где rand – случайное равномерно распределенное число в интервале $[0,1]$. Шаг вычисляется по следующей формуле:

$$st_j = d_j / K,$$

где K – целое число, отвечающее за вычисление значения шага.

В результате локального поиска определяется новый вектор параметров θ . Значения этих параметров передаются в нечеткую систему в качестве новых значений параметров. Вычисляются ошибка и лучшее решение текущего шага. Глобальное лучшее решение запоминается.

Для решения задачи оценки параметров необходима проверка изменения параметра θ_j на ограничения, накладываемые нечеткой системой. К таким ограничениям относится покрытие всей области определения термов, описывающих входную переменную, и упорядоченность пиков функций принадлежности [15].

Для преодоления локальных минимумов в алгоритме используется обновление параметров σ . С этой целью введен параметр конвергенции, вычисляемый по следующей формуле:

$$cf = \frac{\sum_{j=1}^N \frac{2\sigma_j}{b_j - a_j}}{N}.$$

Когда алгоритм приближается к локальному минимуму, коэффициент конвергенции cf приближается к 0. Как только коэффициент конвергенции становится меньше критического значения cf_r , вектор σ возвращается в начальное состояние.

Алгоритм пчелиной колонии

В построении нечеткого классификатора участвуют следующие алгоритмы: алгоритм инициализации базы правил на основе обучающей выборки, базовый алгоритм генерации правил (включает алгоритм работы пчелы-разведчика), модифицированный алгоритм настройки весов правил. Пошаговое представление указанных алгоритмов дано в работе [6].

Алгоритм инициализации базы правил на основе обучающей выборки предназначен для формирования начальной базы правил, содержащей по одному правилу на каждый класс. Кроме того, алгоритм устраняет ненакрытые термами области изменения входных переменных.

В алгоритме работы пчелы-разведчика для выбранного класса создается

еще одно нечеткое правило. Генерируемое алгоритмом правило содержит нечеткие термы с заранее определенным видом функции принадлежности.

Алгоритм генерации правил служит для формирования базы правил нечеткого классификатора с целью получить начальную базу правил гарантированно лучше случайного заполнения. Алгоритм соединяет в себе две концепции поиска решения: пчелы-разведчики, используя методологию случайного поиска, реализуют алгоритм работы пчелы-разведчика, генерируя новые решения, а рабочие пчелы реализуют идею локального поиска, настраивают антецеденты и консеквенты правила. Для уменьшения трудоемкости алгоритма было принято решение сократить число улучшаемых правил на основе их полезности, определяемой путем относительного прироста числа правильно классифицированных объектов обучающей выборки. Данное решение является аналогом «танца» пчел в живой природе. После чего из множества лучших на каждом этапе решений в пределах данной итерации выбирается наилучшее, которое и будет добавлено в базу правил.

Модифицированный алгоритм настройки весов правил используется для оптимизации вектора весов правил. Алгоритм подвергся модификации в силу того, что не существует единого толкования, каким образом происходит привлечение пчел к источнику нектара, однако известно, что эта зависимость имеет вероятностную природу и связана с качеством источника нектара. В модифицированном алгоритме вербовка производится в соответствии с методами селекции генетического алгоритма, для выбора решения используется метод имитации отжига [16].

Эксперимент и результаты

Эмпирической базой для эксперимента являются клинические данные о пациентах, прошедших реабилитацию в ФГУ Томского НИИ курортологии и физиотерапии ФМБА России.

В качестве входных переменных были выбраны в первом эксперименте KZ – глюкокортикоид, IS – инсулин; во втором: KZ – глюкокортикоид, TTG – гормон щитовидной железы, TST – тестостерон.

Если для обучения использовать всю имеющуюся выборку, то может возникнуть проблема так называемого "переобучения". То есть классификатор или аппроксиматор будет настроен именно на эту выборку и не обязательно будет эффективен при работе с другими данными. Для разрешения этой проблемы и получения нечеткой системы высокой обобщающей способности в нашей работе применен метод кросс-валидации. Для каждого из пяти комплексов лечения каждая таблица наблюдений делилась на обучающую выборку и тестовую в соотношении 80:20.

Усредненные результаты по 20 экспериментам приведены в таблицах, в которых приведены результаты работы нечетких: классификатора (табл. 1), настроенного алгоритмом пчелиной колонии; аппроксиматора (табл. 2), настроенного алгоритмами муравьиной колонии; аппроксиматора (табл. 3), настроенного алгоритмами роящихся частиц.

Таблица 1

Входные данные	Комплекс	Обучающая выборка	Тестовая выборка
		Процент правильной классификации	
KZ, IS	1	78,02	70,71
	2	81,01	63,57
	3	84,56	65,83
	4	72,75	63,81
	5	72,43	59,96
KZ, TTG, TST	1	78,36	67,50
	2	75,71	68,28
	3	81,62	64,16
	4	77,29	62,14
	5	74,78	56,28
Итого		77,65	64,22

Таблица 2

Входные данные	Комплекс	Обучающая выборка	Тестовая выборка
		Процент правильной классификации	
KZ, IS	1	78,53	72,72
	2	79,57	74,61
	3	76,04	74,20
	4	67,68	65,31
	5	67,74	61,80
KZ, TTG, TST	1	75,32	65,95
	2	76,75	73,11
	3	78,17	65,51
	4	74,26	69,43
	5	71,38	61,48
Итого		74,54	68,41

Таблица 3

Входные данные	Комплекс	Обучающая выборка	Тестовая выборка
		Процент правильной классификации	
KZ, IS	1	72,24	71,43
	2	69,65	60,28
	3	68,89	66,43
	4	63,89	56,71
	5	59,50	56,11
KZ, TTG, TST	1	67,45	59,30
	2	71,34	67,75
	3	70,15	62,13
	4	61,43	61,14
	5	60,82	57,33
Итого		66,54	61,86

Результаты прогнозирования, показанные нечеткими системами, настроенными различными алгоритмами, отличаются незначительно. Несколько скромный результат, показанный алгоритмом роящихся частиц, компенсируется его простотой и более высоким быстродействием.

Заключение

В работе описаны эффективные алгоритмы оптимизации параметров нечетких систем прогнозирования эффективности немедикаментозного лечения. Алгоритмы обладают неплохими обучающими способностями. Из представленных результатов видно, что процент правильной классификации на тестовых наблюдениях сопоставим с процентом на обучающих наблюдениях. Этот факт свидетельствует об отсутствии переобучения.

Предлагаемый нами подход к прогнозированию эффективности немедикаментозного лечения может использоваться как инструмент для разработки стандартов санаторно-курортной помощи при различных нозологических формах заболеваний. При наличии собственной базы данных подход может быть применен для прогноза результата лечения у конкретного пациента при лечении конкретного заболевания конкретным лечебным комплексом.

ЛИТЕРАТУРА

1. *Ohno-Machado L.* Modeling medical prognosis: Survival analysis techniques // *Journal of Biomedical Informatics*. – 2001. – Vol. 34. – P. 428-439.
2. *Cruz J.A., Wishart D.S.* Applications of Machine Learning in Cancer Prediction and Prognosis // *Cancer Informatics*. – 2006. – Vol. 2. – P. 59-78.
3. Метод прогнозирования эффективности восстановительного лечения на основе дерева решений / А.А. Зайцев, Е.Ф. Левицкий, И.А. Ходашинский и др. // *Вопросы курортологии, физиотерапии и лечебной физической культуры*. – 2010. – №5. – С. 35-38.
4. *Зайцев А.А., Ходашинский И.А., Плотников О.О.* Прогнозирование эффективности немедикаментозного лечения на основе ансамблей классификаторов // *Вопросы курортологии, физиотерапии и лечебной физической культуры*. – 2011. – №4. – С. 46-49.
5. Нечеткий аппроксиматор атмосферных температурных полей / М.Ю. Катаев, А.В. Лавыгина, И.А. Ходашинский, Д.А. Эпштейн // *Автометрия*. – 2010. – Т. 46, № 2. – С. 39-48.
6. Fuzzy approximator of atmospheric temperature fields/ М.Ю. Катаев, А.В. Лавыгина, И. А. Khodashinskii, D.A. Epshtein // *Optoelectronics, Instrumentation and Data Processing*. – 2010. – Vol. 46, No. 2. – P. 134-141.
7. *Ходашинский И.А., Горбунов И.В.* Построения нечетких классификаторов на основе алгоритма пчелиной колонии // *Материалы Всероссийской конференции с международным участием “Знания – онтологии – теории” (ЗОНТ-2011)*. Новосибирск, 3-5 октября 2011 г. – М.: Институт математики им. С. Л. Соболева, 2011. – Т.2. – С. 117-125.
8. *Kennedy J., Ebenhart R.* Particle Swarm Optimization / *Proceedings of the 1995 IEEE International Conference on Neural Networks*. – Perth: IEEE Service Center, 1995. – P. 1942-1948.
9. Ходашинский И.А. Идентификация параметров нечетких моделей типа синглтон на основе алгоритма роящихся частиц // *Информационные технологии*. – 2009. – №6. – С. 8-11.
10. *Ходашинский И.А., Синьков Д.С.* Идентификация параметров нечетких систем на основе адаптивного алгоритма роящихся частиц // *Информационные технологии*. – 2011. – №8. – С. 2-5.
11. *Dorigo M., Maniezzo V., Colorni A.* Ant System: Optimization by Colony of Cooperating Agents // *IEEE Transaction Systems, Man and Cybernetics. Part B*. – 1996. – Vol. 26. – P. 29-41.
12. *Ходашинский И.А., Дудин П.А.* Параметрическая идентификация нечетких моделей на основе гибридного алгоритма муравьиной колонии // *Автометрия*. – 2008. – Т. 44, № 5. – С. 24-35.
13. *Khodashinsky I.A., Dudin P.A.* Parametric Fuzzy Model Identification Based on a Hybrid Ant Colony Algorithm // *Optoelectronics, Instrumentation and Data Processing*. – 2008. – Vol. 44, No. 5. – P. 402-411.



14. *Socha K., Dorigo M.* Ant colony optimization for continuous domains // *European Journal of Operational Research.* – 2008. – Vol. 185, No. 3. – P. 1155-1173.
15. *Ходашинский И.А., Дудин П.А.* Идентификация нечетких систем на основе непрерывного алгоритма муравьиной колонии // *Автометрия.* – 2012. – Т. 48, № 1. – С. 63-71.
16. *Khodashinskiy I. A., Dudin P. A.* Identification of fuzzy systems using a continuous ant colony algorithm // *Optoelectronics, Instrumentation and Data Processing.* – 2012. Vol. 48, N. 1. – P. 54-61.
17. *Kong M., Tian P.* Application of ACO in Continuous Domain // *Advances in Natural Computation, Second International Conference, ICNC 2006, Xian, China, September 24-28, 2006. Proceedings, Part II, LNCS 4222.* – Berlin: Springer-Verlag, 2006. – P. 126-135.
18. *Ходашинский И.А., Дудин П.А.* Идентификация нечетких систем на основе прямого алгоритма муравьиной колонии // *Искусственный интеллект и принятие решений.* – 2011. – №3. – С. 26-33.
19. *Ходашинский И.А.* Идентификация нечетких систем на базе алгоритма имитации отжига и методов, основанных на производных // *Информационные технологии.* – 2012. – №3. – С. 14-20.

Статья представлена к публикации членом редколлегии А.А. Шелупановым.

E-mail:

Ходашинский Илья Александрович – hodashn@rambler.ru;

Горбунов Иван Викторович – noby.Ardor@gmail.com;

Дудин Павел Анатольевич – dudinpa@yandex.ru;

Синьков Дмитрий Сергеевич – express@sibmail.com;

Зайцев Алексей Александрович – prim@niikf.tomsk.ru.

УДК 621.372.542

© 2012 г. **А.Г. Шоберг**, канд. техн. наук
(Тихоокеанский государственный университет, Хабаровск)

АНАЛИЗ ОДНОМЕРНОГО СИГНАЛА НА ОСНОВЕ НЕЧЕТНОГО И ЧЕТНОГО БАЗИСОВ ВЕЙВЛЕТОВ С КОМПАКТНЫМИ НОСИТЕЛЯМИ

Предложено обоснование выбора вейвлетов для сравнения результатов анализа одномерных сигналов. Рассмотрены результаты моделирования. Предложены оценки вычислительных затрат и сравнительного количества коэффициентов вейвлет-преобразования для нечетного и четного базисов.

Ключевые слова: вейвлеты, преобразования, одномерный сигнал, анализ, симметрия.

Введение

Обработка сигналов, в том числе и многомерная, требует эффективных реализуемых механизмов, которые найдут применение в практически используемых алгоритмах и их реализации в виде программного обеспечения и технических устройств. Для работы с такими сигналами часто используются средства вейвлет-