

УДК 004.85

Е. В. Котляров

ОБУЧЕНИЕ НЕЙРОННОЙ СЕТИ НА ОСНОВЕ АЛГОРИТМА МУРАВЬИНОЙ КОЛОНИИ ДЛЯ ЗАДАЧИ КЛАССИФИКАЦИИ

Предложен оригинальный гибридный алгоритм обучения искусственной нейронной сети на основе алгоритма муравьиной колонии и алгоритма обратного распространения ошибки, имеющий существенные отличия от базовых классических алгоритмов. Тестирование алгоритма было проведено на общедоступной тестовой базе данных ресурса UCI Machine Learning Repository.

Ключевые слова: обучение искусственной нейронной сети, алгоритм муравьиной колонии.

E. V. Kotlyarov

NEURAL NETWORK LEARNING METHOD BASED ON ANT COLONY ALGORITHM FOR CLASSIFICATION PROBLEMS SOLUTION

The original hybrid algorithm of the artificial neural network training on the basis of the ant colony algorithm and the back propagation algorithm, having essential differences from base classical ones is suggested. The algorithm testing was carried out on a public test database of the UCI Machine Learning Repository resource.

Keywords: artificial neural network training, ant colony algorithm.

Є. В. Котляров

НАВЧАННЯ НЕЙРОННОЇ МЕРЕЖІ НА ОСНОВІ АЛГОРИТМУ МУРАШИНОЇ КОЛОНИЇ ДЛЯ ЗАДАЧІ КЛАСИФІКАЦІЇ

Запропоновано оригінальний гібридний алгоритм навчання штучної нейронної мережі, заснований на алгоритмі мурашиної колонії й алгоритмі зворотного поширення помилки, що має істотні відмінності від базових класичних алгоритмів. Тестування алгоритму було проведене на загальнодоступній тестовій базі даних ресурсу UCI Machine Learning Repository.

Ключові слова: навчання штучної нейронної мережі, алгоритм мурашиної колонії.

Введение. Классические методы решения задач, которые были созданы путем использования сложных математических моделей и применялись более 20 лет назад, как правило, на сегодняшний день работают долго и зачастую – неэффективно. Причиной этого является попытка применить сложный математический метод решения задачи на больших объемах данных. Ранее, когда были разработаны эти методы, объемы обрабатываемых данных были значительно меньше, чем сейчас. После появления стохастических методов для решения задач, взятых «у природы», появилась идея совмещать классические сложные математические методы со стохастическими алгоритмами, чтобы повысить скорость работы, снизить вероятность расходимости, повысить точность алгоритма и т.д.

Одним из классических методов обучения искусственной нейронной сети [3] является алгоритм обратного распространения ошибки, опубликованный в 1974 г. одновременно и независимо друг от друга в работах

А.И. Галушкина [1] и Пола Дж. Вербоса [9]. Данный метод преодолел некоторые теоретические трудности и дал дополнительный толчок в развитии теории искусственных нейронных сетей. Однако этот алгоритм имеет ряд серьезных недостатков, к ним относятся: паралич сети, наличие локальных минимумов, сложность корректного выбора размера шага, временная неустойчивость процесса, которые не всегда позволяют решить поставленную задачу.

Применение стохастических методов при решении различных задач позволяет снизить вычислительную сложность. Одним из стохастических алгоритмов является алгоритм оптимизации по принципу муравьиной колонии. Он основан на непрямом взаимодействии между автономными агентами-муравьями, причем для взаимодействия один с другим муравьи используют феромоны.

Применение гибридных алгоритмов для обучения искусственной нейронной сети началось в XXI в. В работах [5,7–8] рассматриваются применения различных гибридных

алгоритмов. В частности, одним из таких алгоритмов является алгоритм муравья [4].

В настоящей статье предложен гибридный алгоритм для обучения искусственной нейронной сети, основанный на алгоритме оптимизации по принципу муравьиной колонии [2]. Алгоритм протестирован на задаче установления диагнозов заболеваний мочеполовой системы.

Описание алгоритма. В качестве обучаемой искусственной нейронной сети рассматривается многослойный персептрон с одним скрытым слоем и количеством узлов равным n, m и p на входном, скрытом и выходном слоях соответственно. Структура сети изображена на рисунке




Рис. Структура нейронной сети

Вводятся следующие обозначения:

$u = (u_1, \dots, u_n)$ – вектор входных сигналов;

$v = (v_1, \dots, v_m)$ – вектор выходных сигналов скрытого слоя;

$e = (e_1, \dots, e_p)$ – вектор полученных выходных сигналов сети;

$c = (c_1, \dots, c_p)$ – вектор эталонных выходных сигналов сети.

Вектор ошибок $err = (err_1, \dots, err_p)$ находится по формуле $err_i = c_i - e_i, i = 1, 2, \dots, p$.

Для задания весов между входным и скрытым слоями используется матрица $W = \|w_{ij}\|, i = 1, 2, \dots, n, j = 1, 2, \dots, m$, между скрытым и выходным слоями – матрица $A = \|a_{ij}\|, i = 1, 2, \dots, m, j = 1, 2, \dots, p$. Каждый нейрон скрытого и выходного слоев имеет

смещение, вектор смещения для узлов скрытого слоя обозначается

$W_0 = \|w_{0j}\|, j = 1, 2, \dots, m$, для узлов выходного

слоя – $A_0 = \|a_{0j}\|, j = 1, 2, \dots, p$.

Для подсчета входного сигнала в каждом узле скрытого слоя используется классическая схема: находится взвешенная сумма всех входных сигналов, к найденной сумме прибавляется взвешенное смещение. Полученное значение передается в активационную функцию. В качестве активационных используются функции вида

$$f_1(x) = \frac{1}{1+e^{-x}}, f_2(x, a) = \frac{1}{1+e^{-ax}},$$

$$f_3(x, a) = \frac{1}{1+a^{-x}}, f_4(x) = 1+e^{-x^2},$$

$$f_5(x) = \frac{1}{1+|x|}.$$

Значение активационной функции и является выходным сигналом соответствующего узла скрытого слоя, т.е. координатой вектора v . Аналогично находится вектор выходных сигналов сети e .

Рассмотрим работу алгоритма. Перед запуском обучения сети элементы матриц W, A и компоненты векторов W_0, A_0 задаются произвольными вещественными числами из промежутка $[-1, 1]$. На вход сети подается вектор входных сигналов u , задается вектор эталонных выходных сигналов c , соответствующий данному входному вектору. Сигнал распространяется по сети от входа к выходу. Сначала формируется вектор v , затем вектор e , после просчитывается вектор ошибок err .

Для оптимизации обучения нейронной сети предлагается использовать следующий гибридный алгоритм. Суть алгоритма состоит в предварительном нахождении приоритетных путей движения по нейронной сети. Для этого наряду с измененным алгоритмом обратного распространения ошибки предлагается применить модифицированный алгоритм муравьиной колонии.

Модификация алгоритма муравьиной колонии для выбора приоритетных путей состоит в следующем: упрощено правило выбора следующего узла, изменен учет

пройденного муравьем расстояния, введена функция для учета феромонов, изменен вероятностный учет движения муравья.

Количество муравьев, которое используется для обучения, задается по формуле

$$l = B \cdot \text{ceil}\left(\frac{\max(m, p)}{n}\right)$$

где $B \in \mathbb{N}$ – параметр, которым может управлять пользователь, чтобы увеличить или уменьшить количество муравьев на один входной узел,

$$\text{ceil}(x) = \begin{cases} [x] + 1, & x \notin \mathbb{Z} \\ [x], & x \in \mathbb{Z} \end{cases}$$

где $[x]$ – целая часть числа x . Количество муравьев на каждый входной узел является достаточным для посещения муравьями всех узлов на скрытом и выходном слоях сети.

Перед началом путешествий муравьи равномерно распределяются по всем входным узлам.

При первом путешествии муравьев в сети еще нет феромонов. Для равномерного посещения муравьями узлов скрытого и выходного слоев при первом путешествии используется следующий прием: муравей равновероятно может выбрать любой из узлов. При посещении узла муравьем данный узел помещается в список недоступных к посещению узлов остальными муравьями, как на скрытом, так и на выходном слоях. Когда все узлы становятся недоступными, списки (на скрытом и/или выходном слоях) очищаются, и следующий муравей снова может равновероятно выбрать доступные к посещению узлы.

После окончания первого путешествия всеми муравьями происходит перераспределение феромонов в сети. Муравей оставляет феромоны на двух пройденных ребрах. Количество оставляемых феромонов на каждом пройденном ребре вычисляется по формуле

$$\text{pher}_i = \frac{Q}{|err_i|}, i = 1, 2, \dots, p,$$

где Q – задаваемая константа, равная количеству феромонов, которое может распространить один муравей за одно путешествие.

err_i – величина ошибки в i -м выходном узле, в который пришел муравей.

Для задания уровня феромонов на ребрах используются матрицы феромонов:

$\Phi = \|\varphi_{ij}\|, i = 1, 2, \dots, n, j = 1, 2, \dots, m$, (между входным и скрытым слоями) и

$\Psi = \|\psi_{ij}\|, i = 1, 2, \dots, m, j = 1, 2, \dots, p$, (между скрытым и выходным слоями). Начальный уровень феромонов в сети равен нулю на всех ребрах.

При втором и последующих путешествиях муравьи используют упрощенное правило выбора, которое основывается только на уровне феромона на ребре. Муравей выбирает следующий узел, к которому ведет ребро с наивысшей концентрацией феромонов. Если таких ребер несколько, муравей с равной вероятностью выбирает любое из них.

После распространения муравьями феромонов происходит испарение феромонов, чтобы «притупить» внимание муравьев к мало посещаемым ребрам. Остановка путешествий муравьев происходит тогда, когда при двух последовательных итерациях пути муравьев не изменились. Полученные уровни феромонов на каждом ребре используются для корректировки весов сети.

Для учета влияния феромонов при корректировке весов сети введена функция $\eta(x, k)$ для учета феромонов, где k – параметр. Для каждого фиксированного допустимого значения параметра k функция $\eta(x, k)$ обладает следующими свойствами: она является непрерывной по переменной x на сегменте $[0; 1]$, строго монотонно убывающей по переменной x , и на концах сегмента принимает значения $\eta(1, k) = 1, \eta(0, k) = \eta_0(k), \eta_0(k) > 1$. При проведении экспериментов использовались следующие функции для учета феромонов:

$$\eta_1(x, k) = \frac{k}{x+1} + 1 - \frac{k}{2}, \eta_2(x, k) = \frac{k}{x^2+1} + 1 - \frac{k}{2},$$

$$\eta_3(x, k) = k^{1-x}, \eta_4(x, k) = k * \arccos(x) + 1.$$

Корректировочные коэффициенты весов сети предлагается находить по формулам

$$\delta_{ij} = (c_i - e_i)e_i(1 - e_i)\eta\left(\frac{\psi_{ij}}{\Psi_{\max}}, k\right),$$

$$i = 1, 2, \dots, m, j = 1, 2, \dots, p,$$

$$\delta'_{ij} = \sum_{k=1}^p a_{jk} \delta_{jk} \cdot v_i (1 - v_i) \eta\left(\frac{\varphi_{ij}}{\Phi_{\max}}, k\right),$$

$$i = 1, 2, \dots, n, j = 1, 2, \dots, m,$$

где $\Psi_{\max} = \max_{\substack{i=1,2,\dots,m, \\ j=1,2,\dots,p}} \psi_{ij}$ и $\Phi_{\max} = \max_{\substack{i=1,2,\dots,n, \\ j=1,2,\dots,m}} \varphi_{ij}$, k –

задаваемый параметр. Обновление весов сети и смещений сети проводятся по формулам

$$a_{ij}^* = a_{ij} + \theta \delta_{ij} e_j, i = 1, 2, \dots, m, j = 1, 2, \dots, p,$$

$$w_{ij}^* = w_{ij} + \theta \delta'_{ij} u_i, i = 1, 2, \dots, n, j = 1, 2, \dots, m,$$

$$a_{0i}^* = a_{0i} + \theta a_{0i} \max_{j=1,2,\dots,m} \delta_{ji}, i = 1, 2, \dots, p,$$

$$w_{0i}^* = w_{0i} + \theta w_{0i} \frac{1}{n} \sum_{j=1}^n \delta'_{ji}, i = 1, 2, \dots, m,$$

где θ – задаваемый коэффициент обучения сети.

Применение алгоритма для установления диагноза заболеваний мочеполовой системы.

Для тестирования алгоритма используется общедоступный ресурс UCI Machine Learning Repository, предоставляемый для проверки качества обучения нейронной сети различными алгоритмами. Ресурс содержит набор общепризнанных специально подготовленных данных в виде коллекции баз данных и генераторов тестовых данных. Эти наборы используются сообществом Machine Learning для изучения и эмпирического анализа алгоритмов обучения. В данной работе описаны результаты экспериментальных тестовых испытаний на примере базы симптомов заболеваний мочеполовой системы.

Цель тестирования – показать практическую применимость предложенного алгоритма для решения задач классификации и провести сравнительную оценку разных вариантов настройки параметров алгоритма и его элементов. Рассматриваются различные наборы пар функций (активационная функция и функция учета феромонов) и влияние их вида на эффективность и качество обучения.

Предложенный алгоритм применим к различным задачам классификации. В настоящей работе он протестирован на задаче определения диагноза заболеваний мочеполовой сис-

темы по данным базы данных [6], которая создана польским доктором философии Джасиком Цернаком (Jacek Czerniak) в институте исследовательских систем Польской академии наук. База представляет собой набор данных для тестирования предполагаемого диагноза двух болезней мочеполовой системы. Она составлена 11 февраля 2009 года, содержит 120 примеров. Задача определения диагноза относится к задачам классификации.

Характеристика базы: база состоит из 6 входных атрибутов, характеризующих состояние больного и двух выходных атрибутов для установления диагноза заболевания.

Входными атрибутами являются:

- температура пациента (от 35°C до 42°C);
- приступы тошноты (есть, нет);
- поясничные боли (есть, нет);
- недержание мочи (есть, нет);
- боли при мочеиспускании (есть, нет);
- жжение уретры, зуд, опухоли выхода уретры (есть, нет).

Все входные атрибуты, кроме первого, принимают целочисленные значения (1 или 0), а первый – вещественные вида $35 + 0,1n$, где $n = 0, 1, \dots, 70$.

Выходными атрибутами являются диагнозы заболеваний:

- воспаление мочевого пузыря (есть, нет);
- воспаление почки (есть, нет).

Все выходные атрибуты принимают целочисленные значения (1 или 0).

База случайным образом разбивается на 102 обучающих и 18 тестовых примеров. Алгоритм тестируется при помощи 5 различных активационных функций $f_k(x)$, $k = 1, 4, 5$, $f_k(x, a)$, $k = 2, 3$ и 4 различных функций для учета феромонов $\eta_i(x, k)$, $i = 1, 2, 3, 4$. При этом, если у выбранной функции есть параметр, то эксперименты проводятся для различных значений параметров. Величина максимальной ошибки сети во всех экспериментах положена равной 0,01.

При проведении экспериментов были заданы следующие параметры:

$n = 6, m = 4, p = 2, \theta = 0,2, Q = 1.$

В табл.1 приведены сравнительные результаты двух экспериментов: обучения нейронной сети классическим алгоритмом обратного распространения ошибки и обучения нейронной сети при помощи предложенного гибридного алгоритма, где в качестве активационной функции выбрана функция $f_2(x,4)$, а в качестве функции учета феромонов – функция $\eta_3(x,5)$.

В первых двух столбцах приведены правильные ответы, которые должна дать сеть (компоненты вектора эталонного выходного сигнала c записаны в одной строке первых двух столбцов).

В 3- и 4-м столбцах показаны ответы при обучении сети классическим алгоритмом обратного распространения ошибки (в одной строке столбцов записаны компоненты вектора выходного сигнала, который, не огра-

ничивая общности, тоже будем обозначать через e).

В 6- и 7-м столбцах указаны правильные ответы сети, которая обучалась предложенным гибридным алгоритмом (в одной строке 6- и 7-го столбцов записаны компоненты вектора выходного сигнала e).

Формула оценивания правильного ответа имеет вид: $|e_1 - c_1| < 0,1$ и $|e_2 - c_2| < 0,1$, где $e_i, i = 1,2$ – i -я компонента вектора выходного сигнала; $c_i, i = 1,2$ – i -я компонента вектора эталонного выходного сигнала. Если неравенства выполняются, то получен правильный ответ, записывают (1), в противном случае – правильный ответ не получен (0). В 5- и 8-м столбцах приведены результаты правильности ответов на соответствующие примеры. Метод обратного распространения ошибки показал 78 % правильных ответов, а гибридный метод – 100 %.

1. Сравнительная характеристика одного эксперимента

Исходные данные		Классический алгоритм			Гибридный алгоритм		
Воспаление МП	Воспаление почки	Воспаление МП	Воспаление почки	Правильные ответы	Воспаление МП	Воспаление почки	Правильные ответы
1	1	0,996433	0,973468	1	0,949135	0,970348	1
1	1	1,010835	0,966738	1	0,949559	0,970078	1
1	1	0,902378	1,077965	1	0,941608	0,969365	1
1	0	1,100665	-0,07727	0	0,998376	0,045349	1
1	0	0,957106	0,06966	1	0,998584	0,072254	1
1	0	1,101753	-0,0781	0	0,998377	0,045697	1
1	0	1,101753	-0,0781	0	0,998377	0,045697	1
1	0	1,09956	-0,07654	1	0,998376	0,044997	1
1	0	0,934433	0,054723	1	0,99734	0,010665	1
0	1	0,066425	0,970014	1	0,029716	0,962446	1
0	1	0,042195	1,014323	1	0,046371	0,986826	1
0	1	0,032558	1,000972	1	0,046523	0,986805	1
0	1	0,063246	0,954598	1	0,039631	0,962291	1
0	1	0,049078	0,885318	0	0,048577	0,986602	1
0	0	-0,00082	-0,01534	1	0,001257	0,055145	1
0	0	-0,04893	0,025587	1	0,001263	0,059214	1
0	0	-0,09856	0,067057	1	0,001272	0,063726	1
0	0	0,015453	0,027975	1	0,001985	0,016544	1

Далее проводились сравнительные эксперименты: один – методом обратного распространения ошибки, остальные 32 – с различными активационными функциями и различными функциями для учета феромонов. Если указанные функции имели параметр, то рассматривались конкретные значения параметров. Результаты экспериментов отражены в табл. 2. Под точностью алгоритма понимается отношение правильно решенных примеров при помощи данного алгоритма к об-

щему количеству решаемых примеров. Точность алгоритма выражена в процентах.

В первой строке табл. 2 приведен результат, полученный при помощи алгоритма обратного распространения ошибки. Во всех остальных строках табл. 2 указано, какие активационная функция и функция для учета феромонов использовались в эксперименте, кроме того, указано количество затраченных итераций.

2. Таблица результатов экспериментов

Активационная функция	Функция учета феромонов	Количество итераций	Точность, %
Алгоритм обратного распространения ошибки		–	78
$f_1(x)$	$\eta_1(x,5)$	16	89
$f_1(x)$	$\eta_2(x,5)$	18	83
$f_1(x)$	$\eta_3(x,5)$	72	94
$f_1(x)$	$\eta_4(x,5)$	9	83
$f_1(x)$	$\eta_1(x,10)$	9	83
$f_1(x)$	$\eta_2(x,10)$	12	83
$f_1(x)$	$\eta_3(x,10)$	70	78
$f_1(x)$	$\eta_4(x,10)$	18	56
$f_2(x,2)$	$\eta_1(x,5)$	9	89
$f_2(x,2)$	$\eta_2(x,5)$	7	89
$f_2(x,2)$	$\eta_3(x,5)$	17	89
$f_2(x,2)$	$\eta_4(x,5)$	Сеть не обучилась	
$f_2(x,4)$	$\eta_1(x,5)$	Сеть не обучилась	
$f_2(x,4)$	$\eta_2(x,5)$	12	100
$f_2(x,4)$	$\eta_3(x,5)$	12	89
$f_2(x,4)$	$\eta_4(x,5)$	Сеть не обучилась	
$f_3(x,3)$	$\eta_1(x,5)$	13	83
$f_3(x,3)$	$\eta_2(x,5)$	14	89
$f_3(x,3)$	$\eta_3(x,5)$	57	94
$f_3(x,3)$	$\eta_4(x,5)$	7	89
$f_3(x,5)$	$\eta_1(x,5)$	10	83
$f_3(x,5)$	$\eta_2(x,5)$	8	83
$f_3(x,5)$	$\eta_3(x,5)$	22	89
$f_3(x,5)$	$\eta_4(x,5)$	10	78

Результаты экспериментов показали, что наилучшая точность (100 %) достигается при помощи гибридного алгоритма, если в качестве активационной функции выбрать $f_2(x,4)$, а в качестве функции для учета феромонов – функцию $\eta_2(x,5)$. Хорошие результаты (от 85 до 99 %) достигаются при помощи следующих пар функций: $f_1(x)$ и $\eta_1(x,5)$; $f_1(x)$ и $\eta_3(x,5)$; $f_2(x,2)$ и $\eta_1(x,5)$; $f_2(x,2)$ и $\eta_2(x,5)$; $f_2(x,2)$ и $\eta_3(x,5)$; $f_2(x,4)$ и $\eta_3(x,5)$; $f_3(x,3)$ и $\eta_2(x,5)$; $f_3(x,3)$ и $\eta_3(x,5)$; $f_3(x,3)$ и $\eta_4(x,5)$; $f_3(x,5)$ и $\eta_3(x,5)$.

Заключение

Предложен оригинальный гибридный алгоритм обучения искусственной нейронной сети на основе алгоритма муравьиной колонии и алгоритма обратного распространения ошибки, имеющий существенные отличия от базовых классических алгоритмов.

Алгоритм муравьиной колонии используется для организации более эффективного поиска и вычисления весов нейронной сети посредством выбора более коротких путей движения по нейронной сети и индивидуального подбора весов сети при помощи феромонов. По сравнению с базовым, алгоритм муравьиной колонии существенно изменен. В базовом алгоритме за основу взят учет расстояния между каждой парой соединенных узлов. В предложенном алгоритме за основу берется учет величины ошибки в конце путешествия муравья. Кроме того, изменение элементов матриц феромонов с учетом величины ошибки на каждом выходном узле (вместо учета общей ошибки сети) позволило ускорить процесс обучения.

Корректировка всех весов сети и всех смещений происходит тогда, когда приоритетные пути движения по сети муравьями выбраны. При этом веса сети изменяются с учетом значений элементов матрицы феромонов, ошибки на каждом узле выходного слоя и предложенной функции для учета феромонов.

Тестирование было проведено на тестовой базе данных задачи установления диагнозов заболеваний мочеполовой системы. Сеть обучалась двумя алгоритмами: классическим алгоритмом обратного распростране-

ния ошибки и предложенным в настоящей работе гибридным алгоритмом с различными активационными функциями и различными функциями для учета феромонов. Тест показал работоспособность предложенного алгоритма. При тестировании варьировались параметры для достижения наилучшего результата. Выделены наборы пар функций, при которых достигается наилучший возможный результат – 100 % правильных ответов при приемлемом времени вычислений.

Полученные результаты позволяют ожидать, что такой подход может дать хорошие результаты при решении реальных задач классификации на реальных данных.

Список использованной литературы

1. Галушкин, А. И. Синтез многослойных систем распознавания образов / А. И. Галушкин. – М. : Энергия, 1974.
2. Котляров Е.В. Гибридный метод обучения искусственной нейронной сети на основе модифицированного алгоритма муравья / Е. В. Котляров, Т. И. Петрушина // Восточно-европейский журнал передовых технологий. – 2012.– №5/4 (59). – С. 16–21.
3. Simon Haykin, Neural Networks: A Comprehensive Foundation (2nd Edition) / Simon Haykin – Prentice Hall, Upper Saddle River, New Jersey, 1999 [in English].
4. Тим Джонс. Программирование искусственного интеллекта в приложениях / Тим Джонс. Пер. с англ.: Осипов А. И. – М. : ДМК. – Пресс, 2006 – 312 с.: ил.
5. Evolving Neural Networks Using the Hybrid of Ant Colony Optimization and BP Algorithms, Advances in Neural Networks – ISNN 2006 / Lecture Notes in Computer Science, 2006, Volume 3971/2006, 714-722, DOI: 10.1007/11759966_105.
6. Machine Learning Repository, база данных [Электронный ресурс] / Режим доступа к базе: <http://archive.ics.uci.edu/ml/datasets/Acute+Inflamations>.
7. Neural Network Based on Ant Colony Clustering Algorithm Applied to Predict the Stability of the Roof in Coal Mining, ISDA '06 Proceedings of the Sixth International Confer-

ence on Intelligent Systems Design and Applications – Vol. 01, 2006.

8. Study on the Feed forward Neural Network Based on Ant Colony Optimization / Journal of Wuhan University of Technology [Transportation Science & Engineering], 2009-03.

9. Werbos, P. J. Beyond regression: New tools for prediction and analysis in the behavioral sciences. Ph.D. thesis, Harvard University, Cambridge, MA, 1974.

nal of Wuhan University of Technology [Transportation Science & Engineering], 2009-03 [in English].

9. Werbos, P. J. Beyond regression: New tools for prediction and analysis in the behavioral sciences. Ph.D. thesis, Harvard University, Cambridge, MA, 1974 [in English]

Получено 10.09.2012

References

1. Galushkin, A. I. Multilayered systems synthesis of images recognition / A. I. Galushkin. – Moscow : Energy, 1974 [in Russian].

2. Kotlyarov E. V. Hybrid training method of artificial neural network on the basis of the modified ant algorithm / E. V. Kotlyarov, T. I. Petrushina // Eastern-European Journal of Enterprise Technologies. – 2012. –№ 5/4 (59). – P. 16–21 [in Russian].

3. Simon Haykin, Neural Networks: A Comprehensive Foundation (2nd Edition) / Simon Haykin – Prentice Hall, Upper Saddle River, New Jersey, 1999 [in English].

4. M.Tim Jones *AI Application Programming* – Charles River Media, inc, Hingham, Massachusetts, 2003 [in English].

5. Evolving Neural Networks Using the Hybrid of Ant Colony Optimization and BP Algorithms, Advances in Neural Networks – ISSN 2006 / Lecture Notes in Computer Science, 2006, Volume 3971/2006, 714-722, DOI: 10.1007/11759966_105 [in English].

6. Machine Learning Repository, база данных [Электронный ресурс] / Режим доступа к базе: <http://archive.ics.uci.edu/ml/datasets/Acute+Inflammations> [in English].

7. Neural Network Based on Ant Colony Clustering Algorithm Applied to Predict the Stability of the Roof in Coal Mining, ISDA '06 Proceedings of the Sixth International Conference on Intelligent Systems Design and Applications – Vol. 01, 2006 [in English].

8. Study on the Feed forward Neural Network Based on Ant Colony Optimization / Jour-



Котляров
Евгений Владимирович,
ассистент Одесского нац.
ун-та
им. И.И. Мечникова,
м/б тел. 050-392-75-36
E-mail jimis@ua.fm