

УДК 519.71

О.Г. Руденко, М.С. Сныткин, А.Е. Кувшинов

## РЕШЕНИЕ ЗАДАЧИ КЛАССИФИКАЦИИ С ПОМОЩЬЮ ИСКУССТВЕННОЙ НЕЙРОННОЙ СЕТИ НА ОСНОВЕ ТЕОРИИ АДАПТИВНОГО РЕЗОНАНСА

### 1. Введение

Классификация является мощным инструментом, используемым для категоризации больших объемов данных. Необходимость в определении категорий возникает, например, тогда, когда требуется установить коды опознавания классов состояний сложных систем или выделить по характерным сходствам различные подмножества из группы данных («data mining»).

Обычно искусственные нейронные сети (ИНС) используют тогда, когда стандартные статистические методы кластеризации не позволяют получить приемлемые результаты при интерпретации заданного набора данных по причине низкой их производительности или завышенных требований к системным ресурсам. В то же время ИНС, следуя своим собственным правилам, могут быть с успехом применены для решения поставленной задачи.

ИНС на основе теории адаптивного резонанса (ART) относит входное изображение к одному из известных классов, если оно в достаточной степени подобно или резонирует с прототипом этого класса. Если найденный прототип с определенной точностью, задаваемой специальным параметром сходства, соответствует входному изображению, то он модифицируется, чтобы стать более похожим на предъявленное изображение. Когда входное изображение недостаточно подобно ни одному из имеющихся прототипов, на его основе создается новый класс. Это возможно благодаря тому, что сеть имеет большое количество избыточных или нераспределенных элементов, которые не используются до тех пор, пока в этом нет необходимости (если нет нераспределенных нейронов, то входное изображение не вызывает реакции сети). Таким образом, новые образы могут создавать новые классы, но не могут искажать запомненную информацию.

Серьезная проблема для ИНС — правильное соотношение стабильности и пластичности при запоминании образов [1].

Существуют наборы эталонов (даже состоящие всего из 4-х векторов), которые при циклическом предъявлении в обучении дают никогда не сходящиеся наборы параметров сети. Предъявление всего одного нового образа в обучающем множестве часто приводит к долгому переобучению. Если сеть работает в реальном времени, например, обрабатывает сенсорную информацию, то обучающее множество может все время меняться. Для большин-

ства моделей ИНС это приводит к отсутствию обучения вообще.

Человеческая память, напротив, эффективно хранит и корректирует запоминаемые образы. Ни предъявление нового образа, ни изменение старых не приводит к уничтожению памяти или невозможности запоминания. Даже удаление части нервной ткани чаще всего не прерывает работу сети и не стирает запомненные образы, а лишь делает их менее четкими.

Сеть ART — попытка приблизить механизм запоминания образов в ИНС к биологическому. Результатом работы ART является устойчивый набор запомненных образов и возможность выборки «похожего» вектора по произвольному предъявленному на входе вектору. Важное качество ART — динамическое запоминание новых образов без полного переобучения и отсутствие потерь уже запомненных образов при предъявлении новых.

Основные свойства сетей ART отражены в ряде теорем [2], наиболее важными из которых являются следующие:

После стабилизации процесса обучения предъявление одного из обучающих векторов (или вектора с существенными характеристиками образа) будет активировать требуемый нейрон слоя распознавания без поиска. Эта характеристика «прямого доступа» определяет быстрый доступ к предварительно изученным образам.

Процесс поиска является устойчивым. После определения нейрона-победителя в сети не будет возбуждения других нейронов в результате изменения векторов выхода слоя сравнения; только сигнал сброса может вызвать такие изменения.

Процесс обучения является устойчивым. Обучение не будет вызывать переключения с одного активированного нейрона слоя распознавания на другой.

Процесс обучения конечен. Любая последовательность произвольных входных векторов будет формировать стабильный набор весов после конечного количества обучающих серий; повторяющиеся последовательности обучающих векторов не будут приводить к циклическому изменению весов.

### 2. Структура и обучение сетей ART

В зависимости от вида входных переменных и способа их обработки различают следующие модели сетей ART:

- 1) ART 1, использующая двоичные входные векторы;
- 2) ART 2, использующая как двоичные, так и непрерывные векторы входов;
- 3) ART 3, используемая для моделирования биологических процессов;
- 4) ART MAP, представляющая собой комбинацию двух ART-сетей;
- 5) Fuzzy ART, использующая нечеткую логику.

Структура любой сети ART включает слой сравнения  $F1$ , слой распознавания  $F2$ , приемник, модули весовых матриц и модуль сброса. Отличительной особенностью сети является то, что непрерывно изменяющийся вектор входных образов  $I = (i_1, i_2, \dots, i_m)$  передается в прямом и обратном направлениях (резонирует) между слоями сети.

ART 2 является обобщением сети ART 1, способным обрабатывать как двоичные, так и непрерывные сигналы. Архитектура сети ART 2 аналогична архитектуре сети ART 1, однако нейроны слоя сравнения сети ART 2 имеют более сложную структуру и представляют собой небольшую сеть, состоящую из шести нейронов и служащую буферным устройством.

Начальная обработка в любой сети ART 2 выполняется в модуле, представляющим собой обучаемую конкурентную сеть, как показано на рис. 1 [1]. Входные  $m$  нейронов слоя  $F1$  хранят входной образ  $I = (i_1, i_2, \dots, i_m)$ . На каждый нейрон выходного слоя  $F2$  поступает восходящая сетевая активность  $t_j$ , формируемая из всех выходов  $S = I$  слоя  $F1$ . Элементы вектора  $T = (t_1, t_2, \dots, t_n)$  можно рассматривать как результат сравнений между входным образцом  $I$  и прототипами  $W_1 = (w_{11}, \dots, w_{1m}), \dots, W_n = (w_{n1}, \dots, w_{nm})$ . Эти прототипы являются весами синаптических связей между слоями  $F1$  и  $F2$ . На выходе только одного нейрона  $J$  слоя  $F2$ , получившего наибольшую восходящую сетевую активность  $t_j$ , устанавливается единица, на выходах остальных нейронов остаются нули

$$u_j = \begin{cases} 1, & \text{если } t_j > \max(t_k : k \neq j) \\ 0, & \text{иначе.} \end{cases} \quad (1)$$

Одним из возможных путей вычислить сетевую активность  $t_j$  и таким образом определить степень сходства между векторами  $I$  и  $W_j$ , является взвешенная сумма

$$t_j = \sum_{i=1}^m w_{ji} \cdot i_i. \quad (2)$$

Большое влияние величины  $t_j$  на результаты классификации привело к возникновению множества вариантов ее определения. После того как определен нейрон  $J$  слоя  $F2$ , победивший в соревнованиях, соответствующий прототип  $W_J = (w_{1J}, \dots, w_{mJ})$  адаптируется к входному образу  $I$ . Одним из методов подобной адаптации является изменение вектора  $W_J$  в соответствии с входным образом  $I$  по правилу

$$W_J^{(new)} = \eta \cdot I + (1 - \eta) \cdot W_J^{(old)}, \quad (3)$$

где  $\eta \in [0, 1]$  — константа, называемая показателем обучения (предотвращает слишком быстрое изменение прототипа  $W_J$  и, как следствие, дестабилизацию процесса обучения).

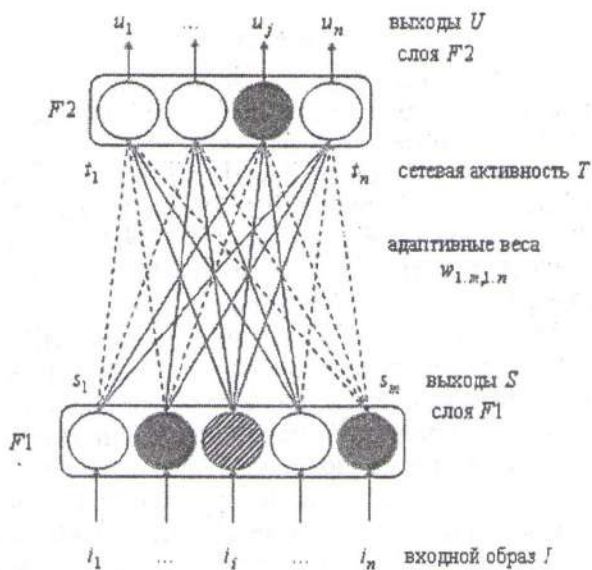


Рис. 1. Обучаемая конкурентная сеть

Прототипы для данной конкурентной сети могут быть инициализированы как случайными величинами, так и значениями из произвольно выбранных входных образов обучающей последовательности.

Обучаемая конкурентная сеть такого типа имеет тенденцию к неустойчивой классификации, когда сходство между входными образами изменяется в слишком широких пределах [3]. К тому же, нет возможности управлять количеством классов создаваемых сетью, или минимальным сходством образов в одном классе. В сетях ART эта проблема решается путем расширения обучаемой конкурирующей сети как это показано на рис. 2. Как видно из рисунка, добавлена обратная связь, объединяющая выход  $U$  слоя  $F2$  со слоем  $F1$ . Синаптические нисходящие веса  $W_{ji}$  этих связей, кроме возможного коэффициента масштабирования, идентичны восходящим весам  $W_{ji}$ . Нисходящая сетевая активность  $V$  обычно определяется как

$$v_i = \sum_{j=1}^n u_j \cdot w_{ji} \quad (4)$$

или

$$V = U \cdot W_{ji} = W_J. \quad (5)$$

Поскольку все выходы слоя  $F2$ , кроме  $u_j$ , равны нулю (рис. 2), то входной слой  $F1$  получает прототип  $W_J$ , который представляет текущий класс  $J$ , победивший в соревнованиях. Далее выполняется са-

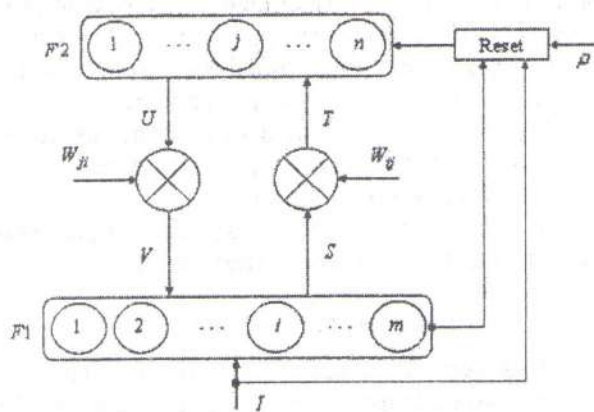


Рис. 2. Упрощенная архитектура сети ART 2

мая сложная в сетях ART 2 часть обработки данных — сравнение прототипа  $W_j$  с входным образом  $I$ . Минимальное сходство между входным образом и прототипом соответствующего класса задается величиной чувствительности  $\rho$ . Если степень совпадения меньше, чем  $\rho$ , текущий нейрон-победитель из слоя  $F2$  исключается из соревнований сигналом сброса. Сигнал сброса устанавливает активный нейрон  $j$  слоя  $F2$  в нуль и таким образом дает возможность другому нейрону победить в соревнованиях, тем самым на выходе слоя  $F2$  получаем восходящую сетевую активность  $t_j$  еще не сброшенных выходных нейронов. Как только будет обнаружен прототип, у которого степень сходства с входным образом  $I$ , по крайней мере, такая же как чувствительность  $\rho$ , сигнал сброса не возникнет и сеть достигнет резонанса. Позиция последнего нейрона-победителя слоя  $F2$  указывает класс входного образа  $I$ , после чего происходит адаптация соответствующего прототипа.

Начальная инициализация величин прототипов, с которыми не был связан ни один входной образ, должна удовлетворять двум условиям:

1) прототипы, в которых хранятся прежде сформированные классы, должны участвовать в сравнении с входным образом раньше, чем неиспользованные прототипы.

2) если ни один из сформированных классов не подходит к входному образу достаточно хорошо, поиск заканчивается выбором нефиксированного прототипа.

Алгоритм, используемый для классификации в любом типе сети ART тесно связан с известным алго-

ритмом  $k$ -средних [4]. Оба используют по одному прототипу, для представления каждого динамически изменяющегося класса. Алгоритм  $k$ -средних разбивает заданный набор входных образов на  $k$  групп. Параметр  $k$ , таким образом, определяет грубость раздела. В отличие от алгоритма  $k$ -средних, ART использует в качестве критерия минимальное требуемое сходство между образами, называемое чувствительность  $\rho$ , которые будут классифицированы в пределах одной группы. Результирующее число  $k$  групп, в этом случае, зависит от расстояния (с точки зрения определяющего показателя) между всеми входными образами, представленными в сеть в течение обучающих циклов. Рис. 3 иллюстрирует основные этапы упрощенного алгоритма работы сети ART.

На этапе предварительной обработки создается входной образ как массив с постоянным числом  $m$  элементов. ART работает с входным образом фиксированного размера, определяемого размерностью входного пространства, в котором должны быть установлены все кластерные области. Любой из уже сформированных прототипов имеет один и тот же размер  $m$ .

Кроме того, элементы входного образа должны удовлетворять различным ограничениям относительно, например, границ входных величин или геометрической длины массива как вектора. Эти огра-

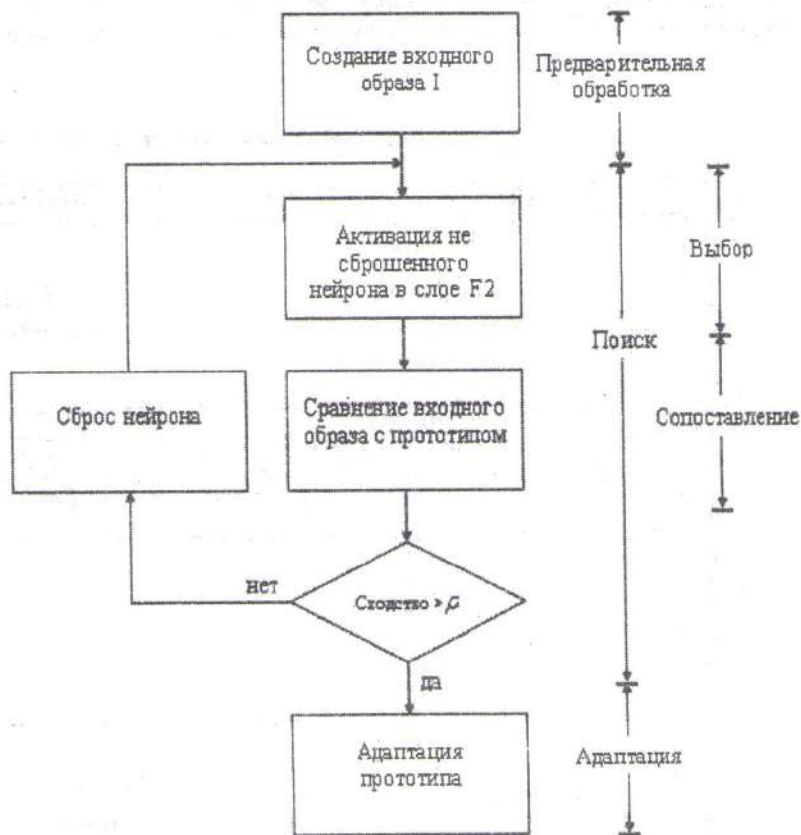


Рис. 3. Обработка входных образов сетью ART

ничения являются характеристиками различных типов сетей ART 2 и позволяют сравнивать входные данные с кластерными прототипами. Как только входной образ будет сформирован, он подается на вход нейронной сети для обработки.

В настоящее время существуют следующие разновидности нейросетей ART 2: ART 2A, ART 2A-C и ART 2A-E. В ряде работ отмечается, что ИНС Fuzzy ART также относится к сетям ART 2, т. к. она обрабатывает как двоичные, так и непрерывные входные вектора.

Сеть ART 2A является базовым и самым простым вариантом реализации сети, но имеет ряд недостатков.

Основной недостаток ART 2A для многих реализаций — потеря всей информации, хранящейся в длине вектора входного образа, поскольку все образы приведены к единичной евклидовой длине. Другими словами, ART 2A не может найти отличия между двумя входными образами  $A_1$  и  $A_2$ , если  $A_1 = c \cdot A_2$ , где  $c > 0$ . Используя комплементарное кодирование, вся информация, находящаяся в длине некодированного вектора  $A$ , помещается в направление результирующего вектора  $I = (A, A^c)$ . Данный метод реализован в сети ART 2A-C и используется для расширения возможности распознавания сетями ART 2A сенсорных аналоговых сигналов [5].

Другой вариант сохранить информацию, находящуюся в длине вектора при обработке входных образов в сети ART 2A, состоит в замене показателя

расстояния ART 2A, евклидовой мерой сходства и исключения нормализации длины входных образов на этапе предварительной обработки и адаптации. Это вариант реализован в сети ART 2A-E.

В сети Fuzzy ART для повышения помехоустойчивости на всех этапах обработки используются операторы нечеткой логики.

В табл. 1 представлены основные этапы обработки для описанных выше нейронных сетей.

### 3. Моделирование

В качестве данных для исследования использовалась база образов животных, состоящая из 100 животных, каждое из которых, обладая 16 свойствами, относится к одному из 7 классов (млекопитающие, птицы, пресмыкающиеся, рыбы, земноводные, насекомые, ракообразные). Эта база создана Richard Forsyth и доступна всем желающим [6].

Таблица базы данных (БД) содержит 16 полей, описывающих различные признаки, и одно поле, определяющее класс, к которому принадлежит образ. Поля признаков следующие:

- 1) hair. Имеет ли животное шерсть. Возможные значения: {0, 1};
- 2) feathers. Имеет ли животное перья. Возможные значения: {0, 1};
- 3) eggs. Откладывает ли животное яйца. Возможные значения: {0, 1};
- 4) milk. Кормит ли животное детей молоком. Возможные значения: {0, 1};

Таблица 1

Основные этапы обработки образов в сетях ART

	Fuzzy ART	ART 2A-C	ART 2A-E	ART 2A
Предобработка	$I = (A, A^c)$ $a_i \in [0, 1] \forall i$		$I = A$ $a_i \in [0, 1] \forall i$	$I = \frac{A}{\ A\ } = \mathcal{N}(A)$ $a_i \geq 0 \forall i$ $\ A\  > 0$
Выбор	$\rho \leq \frac{ I \wedge W_j }{ W_j }$	$t_j = \frac{I \cdot W_j}{\ I\  \cdot \ W_j\ }$	$t_j = 1 - \sqrt{\frac{1}{m} \sum_{i=1}^m (i_i - w_{ji})^2}$	$t_j = I \cdot W_j$
Сопоставление	$\rho \leq \frac{ I \wedge W_j }{ I }$		$\rho \leq t_j$	
Адаптация	$W_j^{(new)} = \eta \cdot (I \wedge W_j^{(old)}) + (1 - \eta) \cdot W_j^{(old)}$		$W_j^{(new)} = \eta \cdot I + (1 - \eta) \cdot W_j^{(old)}$	$W_j^{(new)} = \mathcal{N}(\eta \cdot I + (1 - \eta) \cdot W_j^{(old)})$

Таблица 2

## Результаты классификации на основе сети ART 2A

5) airborne. Способно ли животное летать. Возможные значения: {0, 1};

6) aquatic. Обитает ли животное в воде. Возможные значения: {0, 1};

7) predator. Хищное ли животное. Возможные значения: {0, 1};

8) toothed. Имеет ли животное зубы. Возможные значения: {0, 1};

9) backbone. Имеет ли животное позвоночник. Возможные значения: {0, 1};

10) breathes. Дышит ли животное. Возможные значения: {0, 1};

11) venomous. Ядовито ли животное. Возможные значения: {0, 1};

12) fins. Имеет ли животное плавники. Возможные значения: {0, 1};

13) legs. Количество конечностей у животного. Возможные значения: {0, 2, 4, 6, 8};

14) tail. Имеет ли животное хвост. Возможные значения: {0, 1};

15) domestic. Домашнее ли животное. Возможные значения: {0, 1};

16) catsize. Сравнимо ли животное по размеру с кошкой. Возможные значения: {0, 1}.

Некоторые из полей базы данных позволяют почти однозначно идентифицировать класс (например, наличие свойства milk говорит о том, что это животное — млекопитающее). Другие — дают лишь косвенные данные (например, catsize).

В базу данных занесены следующие классы:

- 1) млекопитающие (наиболее многочисленный класс, содержит 41 представителя);
- 2) птицы (21 представитель);
- 3) пресмыкающиеся (5 представителей);
- 4) рыбы (13 представителей);
- 5) земноводные (3 представителя);
- 6) насекомые (8 представителей);
- 7) ракообразные (10 представителей).

Особенностью этой БД является то, что некоторые животные трудно дифференцируемы: например, дельфин должен быть отнесен к млекопитающим, несмотря на сходство с рыбами. Класс ракообразных состоит из очень сильно различающихся между собой животных, которые зачастую не имеют между собой ничего общего (червяк и краб). База использовалась в исходном виде, но более корректно с точки зрения биологии было бы разделить класс ракообразных, не являющихся таковыми, на несколько других классов.

Для исследования особенностей работы сетей ART была разработана программа, способная обучаться на тестовом наборе данных, и классифицировать эти данные, используя различные значения параметров. При обучении образы многократно подавались на вход нейронной сети в случайном порядке. Результаты классификации на основе различных сетей ART 2 приведены в табл. 2–5.

Параметры		n	Распознаны неверно
$\rho$	$\eta$		
0.67	0.253	7	Дельфин и морская свинья были оторваны от млекопитающих и примкнули к рыбам. Черепаха отнесена к птицам. Ракообразные разделены на 3 группы: — червяк, личинка; — скорпион; — моллюск, краб, лангуст, омар, осьминог. Земноводные и пресмыкающиеся объединены
0,693	0,182	8	Дельфин и морская свинья были оторваны от млекопитающих и примкнули к рыбам. Черепаха отнесена к птицам. Ракообразные разделены на 3 группы: — червяк, личинка; — скорпион; — моллюск, краб, лангуст, омар, осьминог
0,717	0,308	11	Черепаха отнесена к птицам. Ракообразные разделены на 3 группы: — червяк, личинка; — скорпион; — моллюск, краб, лангуст, омар, осьминог. Млекопитающие разделены на 2 группы

Таблица 3

## Результаты классификации на основе сети ART 2A-C

Параметры		n	Распознаны неверно
$\rho$	$\eta$		
0.67	0.253	8	Утконос отделен от млекопитающих и выделен в отдельный класс. Черепаха отнесена к птицам. Ракообразные разделены на 3 группы: — червяк, личинка; — скорпион; — моллюск, краб, лангуст, омар, осьминог
0,693	0,182	7	Черепаха отнесена к птицам. Ракообразные разделены на 3 группы: — червяк, личинка; — скорпион; — моллюск, краб, лангуст, омар, осьминог. Земноводные и пресмыкающиеся объединены
0,717	0,308	12	Черепаха отнесена к птицам

Таблица 4  
 Результаты классификации на основе сети ART 2A-E

Параметры		n	Распознаны неверно
$\rho$	$\eta$		
0,78	0,331	8	Морская змея была оторвана от млекопитающих и примкнула к рыбам. Черепаха отнесена к птицам. Ракообразные разделены на 3 группы: – червяк, личинка; – скорпион; – моллюск, краб, лангуст, омар, осьминог
0,722	0,331	7	Морская змея была оторвана от млекопитающих и примкнула к рыбам. Черепаха отнесена к птицам. Ракообразные разделены на 3 группы: – червяк, личинка; – скорпион; – моллюск, краб, лангуст, омар, осьминог. Земноводные и пресмыкающиеся объединены
0,811	0,394	9	Черепаха отнесена к птицам

Таблица 5  
 Результаты классификации на основе сети Fuzzy ART

Параметры		n	Распознаны неверно
$\rho$	$\eta$		
0,289	0,253	8	Червяк и личинка отнесены к насекомым
0,324	0,292	7	Осьминог и пингвин выделены в отдельный класс. Скот и гремучая змея выделены отдельный класс
0,717	0,284	13	Черепаха отнесена к птицам. Скот и гремучая змея выделены в отдельный класс

#### 4. Выводы

Как показали исследования, сети ART2 вполне пригодны для задач классификации, эффектив-

ность решения которых зависит от расстояния между классами. Из приведенных таблиц видно, что основные проблемы возникли с классификацией класса членистоногих, т. к. его некоторые его члены различаются между собой очень сильно, и с биологической точки зрения членистоногими не являются. При увеличении числа классов до 9, сеть ART 2A-E классифицировала остальные классы корректно, а членистоногих разбила на 3 класса. Другие сети ART 2A показали сходные, хотя и не так ярко выраженные результаты – разделению подвергались и другие классы животных. Кроме того, ошибки возникали в случаях с водоплавающими млекопитающими (дельфин, морская свинья, морская змея) и черепахой (все сети относили ее к птицам). Следует отметить, что при использовании сети Fuzzy ART количество ошибок классификации значительно уменьшилось. В целом, кардинальных различий между результатами для различных сетей не наблюдается.

Большое влияние на результат имеют значения параметров сходства  $\rho$  и адаптации  $\eta$ , используемые при обучении сети. Очевидно, разработка формальных методов определения оптимальных значений этих параметров представляет собой важную проблему, на решение которой должны быть направлены основные усилия исследователей.

Список литературы: 1. Горбань А.Н. и др. Нейроинформатика. – Электронная публикация. 2. G. A. Carpenter and S. Grossberg. ART 2: Self-organization of stable category recognition codes for analog input patterns // Appl. Opt. – 1987. vol. 26, 23, P. 4919–4930. 3. G. A. Carpenter. The art of adaptive pattern recognition by a self-organizing neural network // IEEE Computer. – Mar. 1987. P. 88. 4. Carpenter G., Grossberg S. ART 3: Hierarchical Search Using Chemical Transmitters in Self-Organizing Pattern Recognition Architecture // Neural Networks. – 1990. – 3. – P. 129–152. 5. J. R. Whitely, J. F. Davis, A. Mehrotra, and S. C. Ahalt. Observations and problems applying ART2 for dynamic sensor pattern interpretation // IEEE Trans. Syst. Man, Cybern. – 1996. vol. 26. P. 423–437. 6. <http://www.aialab.si/orange/doc/datasets/zoo.htm>.

Поступила в редколлегию 28.09.2005