



OSTIS-2012

(Open Semantic Technologies for Intelligent Systems)

УДК 004.81:159.942.52

ДИНАМИЧЕСКИЕ МОДЕЛИ ИНТЕЛЛЕКТУАЛЬНЫХ СИСТЕМ НА ОСНОВЕ НЕЙРОННЫХ СЕТЕЙ АДАПТИВНОГО РЕЗОНАНСА

Комарцова Л.Г., Лавренков Ю.Н., Антипова О.В., Кадников Д.С.

*Московский государственный технический университет им. Н.Э.Баумана
(Калужский филиал), г. Калуга, Россия*

lkomartsova@yandex .ru

polikarp1@rambler.ru

В статье рассматриваются проблемы создания динамических систем искусственного интеллекта. Исследуются вопросы отображения изменения параметров динамических процессов во времени, выделены особенности и признаки их характеризующие. Решается задача создания динамических моделей, обеспечивающих возможность функционирование подобных систем на основе модифицированной нейронной сети адаптивного резонанса.

Ключевые слова: эволюционные процессы, динамические системы искусственного интеллекта, нейросетевые модели, нейросетевая база знаний, нейронная сеть адаптивного резонанса.

ВВЕДЕНИЕ

Развитие систем искусственного интеллекта (СИИ) в настоящее время связано с созданием новых методов и технологий, направленных на решение сложных проблем, таких, как предсказание, планирование, распознавание образов и т.д. в различных прикладных областях [Ларичев О.И. и др., 1998]. Многие из публикаций по этим проблемам, несмотря на появление работ по созданию систем реального времени [Еремеев А.П., 2004], основываются на предположении неизменности во времени предъявляемых СИИ данных, статичности внешней среды. Однако статические модели не могут быть применены к моделированию процессов, которые изменяются во времени, развиваются и эволюционируют.

Для эволюционирующих процессов необходимым является отслеживание в динамике их изменения во времени (т.е. функционирование в режиме on-line) и адаптации к внешней среде (например, движение робота в незнакомой среде). В работе исследуются некоторые вопросы, которые необходимо решать для создания эволюционных систем, моделирующих процедуру принятия решений человеком в сложных трудно формализуемых задачах в реальном времени.

В соответствии с определением, данным в [Grossberg S., 1987], эволюция (evolutio) означает необратимый процесс исторического изменения живого, формирование таких комбинаций признаков и свойств организма, которые ведут к возникновению у них адаптации к условиям внешней среды. Поскольку эволюционный процесс

развивается во времени его трудно моделировать, так как характеризующие его параметры либо являются неизвестными априорно, либо изменяются случайно. При построении моделей эволюции и создании интеллектуальных эволюционных коннекционистских систем (ИЭКОС) необходимо уметь отображать изменения параметров динамических процессов во времени и выделять особенности и признаки их характеризующие [Chin-Teng Lin, 1996]. Главной проблемой при этом является хорошо известная дилемма «стабильности-пластичности», наиболее известный принцип жизни, реализуемый в коннекционистских - нейросетевых вычислительных моделях [Люгер, 2005], примером таких моделей являются нейронные сети типа ART (Adaptive Resonance Theory). В этой связи объединение эволюции и коннекционистских систем в рамках одной вычислительной модели представляется наиболее перспективным направлением развития СИИ.

1. Архитектура ИЭКОС

Целенаправленное, устойчивое к флуктуациям поведение ИЭКОС определяется двумя основными факторами [Комарцова Л.Г., 2004]:

- цельный интеллект имеет распределенную структуру и возникает из взаимодействия множества простых, отдельных, агентских (модульных) интеллектов;

- развитие эволюционных моделей опирается на дарвиновский принцип естественного отбора как на основной механизм, формирующий поведение

отдельных агентов и обеспечивающий их адаптацию к внешней среде.

Перечислим основные особенности, которые должны быть реализованы в подобных ИЭКОС: 1) модульность; 2) открытость; 3) взаимодействие отдельных модулей при функционировании системы; 4) обучаемость и дообучаемость в процессе всего жизненного цикла существования системы; 5) адаптивность к решаемой задаче; 6) необходимость работы в режиме on-line.

На основе анализа особенностей, которыми должна обладать эволюционная система, предложена архитектура ИЭКОС, представляющая собой многомодульную и многоуровневую открытую конструкцию, содержащую следующие основные части:

1. Входной слой, обеспечивающий предварительную обработку информации (фильтрацию, нормирование, центрирование и т.д.). Число входов может меняться в зависимости от числа выделенных признаков, характеризующих поступающую в систему информацию.
2. Запоминающая часть (нейросетевые модули), представляющая собой нейросетевую базу знаний (НСБЗ) и формирующаяся на основе информации, поступающей из различных источников в процессе функционирования системы. Это многомодульная структура с эволюционными связями между модулями, объединенными в распределенные группы.
3. Слой принятия решений, состоящий из нескольких модулей, каждый из которых принимает решение по определенной проблеме. Модули имеют обратную связь с внешней средой и системой, осуществляющей адаптацию НСБЗ к решаемой задаче.
4. Выходной слой обеспечивает выдачу информации в заданном формате из слоя принятия решений во внешнюю среду.
5. Система адаптации, осуществляющая подстройку одного или нескольких модулей НС к решаемой задаче за счет их дообучения или включения новых нейронов в выходной слой (например, подобно тому, как это делается в сетях ART).
6. Знаниеориентированная подсистема, извлекающая информацию из НС и представляющая ее в виде правил IF-THEN. Наличие нечеткой базы правил обеспечивает объяснение результатов работы нейросетевых модулей.

Такую архитектуру можно рассматривать как теоретическую модель для построения реальных динамических систем. Несмотря на значительные достижения в области развития теории искусственного интеллекта, все еще не достигнут тот уровень «интеллектуальности», который свойственен человеку. Поэтому большое значение для практики имеет исследование методов построения эволюционных систем, которые могли бы эволюционировать и адаптироваться к

решаемым задачам, повышая тем самым уровень своего «интеллекта».

2. Функционирование ИЭКОС

Рассмотрим основные моменты функционирования эволюционной системы. Вначале эта система содержит небольшое число модулей, определяемых априорными знаниями специалистов в некоторой проблемно-предметной области, при этом некоторое множество правил может быть заранее встроено в систему. На основе процедуры самоорганизации и адаптации к внешней среде происходит постепенное накопление знаний системы подобно тому, как это делается в мозге человека, т.е. система становится все более интеллектуальной.

В ответ на входное воздействие активизируется определенный нейросетевой модуль на основе введенной меры сходства входного вектора с вектором весовых коэффициентов входных связей этого модуля. Если ни один из модулей не активизируется или эта активность находится ниже заданного порога, создается новый модуль (в простейшем случае нейронный узел или даже нейрон). Связи между модулями и нейронами определяются «возрастом» и средней активностью модулей на протяжении всего жизненного цикла существования эволюционной системы. Одни и те же нейроны могут быть объединены в классы, на основе их реакцией на входные образы. Если, допустим, создается новый нейронный узел в ответ на некоторый входной вектор X , то этот узел на основе принципов самоорганизации начинает «сближаться» с нейронами, имеющими высокую активность на вектор X даже при недостаточном уровне сходства этого вектора с векторами входных связей нейронов. Таким образом, система эволюционирует во времени.

Реализация такого поведения системы осуществляется с использованием двух основных форм обучения: с учителем и без учителя (на основе самоорганизации). Основные требования, которые предъявляются к нейросетевым модулям в составе эволюционной системы, связаны с необходимостью обеспечения пластичности – способности воспринимать новые образы, и в то же время сохранению стабильности, гарантирующей не разрушение старых образов без потери ранее накопленной информации. К нейронным сетям, обладающим таким свойством, относятся сети адаптивного резонанса (Adaptive Resonance Theory - ART-сети). Для повышения эффективности функционирования нейросетевых модулей на основе обучения с учителем необходимо модифицировать существующие алгоритмы обучения с тем, чтобы адекватно реагировать на изменения во внешней среде. Такие алгоритмы реализованы в [Комарцова Л.Г., 2002].

Наиболее важные достоинства нейронных сетей с адаптивным резонансом (ART-сетей) сводятся к следующему:

- при подаче на вход НС некоторого образа принимается «пластичное» решение о появлении нового образа и «стабильное» решение о совпадении со старым образом; это позволяет решить проблему стабильности-пластичности, которую очень трудно реализовать в сетях персептронного типа.

- НС типа ART (ART-1, ART-2, ART-3) обладают свойством самоорганизации, т.е. обучаются по алгоритму обучения без учителя, который основывается на использовании методов on-line кластеризации, квантизации и прототипного обучения [Metropolis N. and al.];

- в ART-сетях реализована возможность создания оптимальной топологии НС (с минимальным числом нейронов в выходном слое).

Однако эти достоинства влекут за собой необходимость управлять ростом сети, что в оригинальном алгоритме обучения ART осуществляется путем выбора пользователем желаемой величины параметра сходства $\rho \in [0,1]$. Чем выше значение этого параметра, тем большее число классов прототипов, и, соответственно, нейронов выходного слоя будет создано сетью. В предельном случае ($\rho=1$) происходит образование отдельного класса для каждого экземпляра обучающей выборки. Очевидно, что в этом случае существенно снижается способность нейронной сети к обобщению.

Чрезмерный рост числа распознаваемых классов приводит к неэффективному использованию компьютерных ресурсов и замедлению кластеризации. Слишком малое количество образованных классов прототипов, в свою очередь, может обусловить низкую точность распознавания.

Задача выбора числа необходимых классов, которые может распознать сеть, перекладывается на пользователя, который должен выбрать значение параметра ρ . Оптимальный выбор этого параметра трудоемок и требует проведения большого числа экспериментов. Поэтому первостепенное значение приобретает автоматизация процесса роста нейронной сети без задания пользователем конкретного значения параметра сходства. Один из подходов к решению этой проблемы для сети ART-1, работающей с двоичными входными образами и обучающейся без учителя, рассмотрен ниже.

3. Алгоритм обучения сети ART-1

Образы, соответствующие некоторому узлу j НС ART-1 (рис.1), представляются весовым вектором этого узла – T_j . Реакция узла j на особенности входного образа определяется другим весовым вектором V_j . Реализация ключевого элемента ART «стабильность-пластичность» осуществляется на основе использования параметра сходства ρ , который контролирует степень различия между новыми образами и запомненными старыми: $\rho \in [0,1]$.

Будем рассматривать алгоритм обучения ART-1 на основе on-line кластеризации с использованием

стратегии конкурентного обучения. On-line кластеризация – процесс группирования входных данных $X(t)$, $t=1, 2, \dots$, поступающих из непрерывного потока данных. При этом предполагается, что каждый входной вектор появляется однажды в системе и не может быть доступен снова.




Рис. 1 Схема обучения сети ART-1

Многие реально существующие информационные системы оперируют такими данными, как: данные из сети Интернет, индекс акций (товаров), биологическая информация, информация о климате и т. д. Если данные являются динамичными (изменяемыми во времени), то это требует использования адекватных вычислительных моделей, которые должны приспосабливаться к ситуации. Поскольку для таких данных трудно определить их принадлежность классу, используются алгоритмы обучения без учителя. Таким образом, использование on-line кластеризации при обучении ART-1 позволяет использовать этот тип сети для построения интеллектуальных эволюционных систем, могущих работать в реальном масштабе времени, что создает для предпосылки для реализации ИЭКОС. Сеть ART является единственным типом сетей, в которой реализована возможность создания оптимальной топологии сети (минимальное число нейронов в выходном слое). Важное достоинство сетей этого типа проявляется в способности решить проблему стабильности-пластичности

В ART-1 (рис. 1) имеются следующие типы связей между нейронами: b_{ij} – от каждого i -го входного нейрона к каждому j -му выходному ($i=1, \dots, n$, $j=1, \dots, m$); t_{ij} – от каждого выходного нейрона к входным; все выходные нейроны имеют рефлексивную положительную связь и тормозящую связь с другими выходными нейронами (на рис. 1 в выходном слое для простоты изложения алгоритма обучения представлены только 2 нейрона).

Алгоритм обучения ART-1 состоит из двух главных фаз. Первая фаза связана с определением нейрона - победителя путем вычисления степени активности выходных нейронов сети в ответ на подачу некоторого входного вектора: нейрон - победитель имеет наибольшую степень активности. Во второй фазе вычисляется рассогласование между входным образом и прототипом, связанным с нейроном - победителем. Если это рассогласование ниже необходимого, этот прототип обновляется в соответствии с новым вектором, если превышает, то

процедура продолжается для других нейронов или создается новый нейрон.

Запишем алгоритм обучения ART-1.

Шаг 1. Инициализация весовых коэффициентов:

$$t_{ij} := 1; \quad b_{ij} := 1/(1+n) \quad \forall i=1,2,\dots,n; j=1,2,\dots,m$$

Шаг 2. Установка параметра сходства ρ из условия: $0 \leq \rho \leq 1$.

Шаг 3. WHILE (имеются входные вектора) DO

(a) подача на вход сети нового входного вектора:

$$\mathbf{X} = (x_1, x_2, \dots, x_n);$$

(b) вычисление значений выходов сети:

$$y_j = \sum_{i=1}^n b_{ij} x_i, \quad \forall j=1,2,\dots,m$$

(c) определение номера нейрона - победителя j^* с наибольшей величиной выхода;

(d) определение сходства входного вектора \mathbf{X} (образа) с прототипом \mathbf{T}_{j^*} , который соответствует нейрону- победителю j^* : IF (число единиц в двоичном представлении пересечения векторов \mathbf{X} и \mathbf{T}_{j^*} , деленное на число единиц в \mathbf{X} больше, чем ρ , THEN GOTO (f)

ELSE

(e) выход нейрона j^* сбрасывается, затем продолжается процедура поиска нового нейрона-победителя; GOTO (b);

(f) входной вектор \mathbf{X} ассоциируется с прототипом \mathbf{T}_{j^*} , поэтому производится изменение весовых коэффициентов прототипа:

$$t_{ij} := t_{ij} * x_{ij}^*, \quad \forall i=1,2,\dots,n;$$

(g) весовые коэффициенты b_{ij} также изменяются:

$$b_{ij} := b_{ij}^* + t_{ij}^* x_{ij} / (0.5 + \sum_{i=1}^n t_{ij}^* x_i).$$

Шаг 4. Конец.

В сети ART-1 число формируемых кластеров зависит от величины ρ . Чем выше значение ρ , тем большее число кластеров требуется для представления входных данных. Для автоматического формирования кластеров будем использовать возможности нечеткого управления.

4. Управление ростом сети ART-1 на основе методов нечеткой логики

В настоящее время известны два, наиболее часто применяемые на практике типа алгоритмов обучения нечеткой ART: 1) быстрого обучения и 2) использующие нормализацию входных векторов с помощью комплементарного (дополнительного) кодирования [Kussul E.M. and al.]. Нечеткость рассматриваемой модели ART-1 определяется видом используемого логического оператора AND (вместо оператора пересечения \cap в ART-1 оператора \wedge (min) в fuzzy ART-1). Оператор min сводится к оператору пересечения в случае двоичных аргументов.

В алгоритмах быстрого обучения в формуле обновления векторов:

$$\mathbf{T}_j(t+1) = \beta(\mathbf{X} \wedge \mathbf{T}_j(t) + (1-\beta)\mathbf{T}_j(t),$$

где β - коэффициент обучения, устанавливается $\beta=1$, посредством этого входной вектор \mathbf{X} быстро сходится к некоторому кластеру или создается новый нейрон, после чего β устанавливается <1 , когда определен кластер для входного вектора.

Для более сложного алгоритма в случае нормирования входных векторов в качестве меры нечеткости вводится функция выбора нейрона - победителя:

$$A_j(\mathbf{X}) = \frac{|\mathbf{X} \wedge \mathbf{T}_j|}{\varepsilon + |\mathbf{T}_j|},$$

где $\varepsilon > 0$, является константой, а нечеткий AND оператор \wedge определяется как оператор min, $|\bullet|$ - норма вектора. Функция выбора показывает степень, с которой весовой вектор \mathbf{T}_j является нечетким подмножеством входного вектора \mathbf{X} .

В предлагаемом алгоритме нечеткость вводится на уровне задания приращений параметра сходства ρ , в зависимости от ситуации, возникающей в ART-1 при кластеризации.

Общая схема подстройки различных параметров обучения нейронной сети (НС) с помощью нечеткой логики представлена на рис. 2. Нечеткая база правил, содержащая экспертные знания, используется для адаптивного изменения значений параметров обучения, в зависимости от состояния сети и реального значения параметров обучения.

Определим в качестве параметра управления величину ρ . Предположим, что априорно известно число кластеров N_a . Проведем первоначальную кластеризацию по приведенному выше алгоритму: пусть количество реальных кластеров равно N_r . Если $N_r < N_a$, то требуется подстройка параметра ρ с последующим новым предъявлением входных данных. Если $N_r > N_a$, ρ можно увеличивать, так как имеется число дополнительных кластеров $N_a - N_r$ (что приведет к более точной классификации); в противном случае, при $N_r < N_a$ - ρ должно уменьшаться, чтобы все входные векторы могли быть отнесены к одному из существующих кластеров.




Рис. 2. Схема подстройки параметров обучения НС на основе методов нечеткой логики

Таким образом, в алгоритме обучения нечеткой ART-1 после проведения очередной кластеризации по алгоритму ART-1 необходимо определять

величину изменения ρ , т.е. $\Delta\rho$ которое позволит N_r приблизиться к N_a . Схема вычисления искомого значения приращения параметра обучения $\Delta\rho$ (рис. 3) соответствует базовой схеме нечеткого контроллера [Kussul E.M. and al.].

Нечеткие правила, построенные на основе проведенного эмпирического анализа результатов работы нечеткой ART, позволили определить процедуру изменения ρ в соответствии с табл.2. Здесь $E = N_a - N_r$ и IE - изменение E. Определены следующие нечеткие множества: NB – отрицательное большое; NS – отрицательное малое; ZE – нуль; PS – положительное малое; PB – положительное большое.

Из табл.1, например, можно извлечь следующее правило: IF E есть положительное малое (PS) AND IE есть положительное большое (PB), THEN $\Delta\rho$ есть положительное малое (PS).

Далее по правилам нечеткой логики, зная вид функции принадлежности нечеткой переменной $\Delta\rho$ и используя дефазификацию, извлекается числовое значение приращения.

Табл. 1 Фрагменты нечетких правил

IE \ E	NB	NS	ZE	PS	PB
NB	–	NS	ZE	PS	–
NS	NB	NS	ZE	PS	PB
ZE	NB	NS	ZE	PS	PB
PS	NB	NS	ZE	PS	PB
PB	–	NS	ZE	PS	–




Рис. 3 Функции принадлежности для $\Delta\rho$

Определив значение $\Delta\rho$, сеть ART-1 выполняет повторную классификацию при новом значении $\Delta\rho$. Алгоритм заканчивает свою работу (устанавливает соответствующее значение ρ), когда N_r сравняется с N_a .

Следует отметить, что на этапе распознавания в нечеткой ART-1 используется стандартная процедура поиска нейрона – победителя с $\rho = 0$, поскольку в общем случае образования новых классов не происходит.

Для оценки эффективности предложенного алгоритма были использованы стандартный тестовый набор по распознаванию ирисов и генератор тестов. Характеристики используемых в

экспериментах тестовых наборов представлены в табл. 2.

При проведении экспериментов параметр сходства ρ в одном случае был выбран равным нулю для обеспечения минимального размера сети, а в другом – равным $\rho = 0.9$ для достижения более высокой точности. В табл. 3 представлены результаты классификации на выбранных наборах данных. В качестве результатов использовались ошибки классификации (даваемые в процентах от общего числа имеющихся примеров) и число образованных в результате функционирования ART-1 кластеров.

Табл. 2. Характеристики тестовых наборов

Тесты	Кол-во классов	Размерность векторов	Кол-во векторов
Распознавание сортов ирисов	3	4	150 (75, 5)
Генератор тестов	5	4	100-500

Результаты классификации для генератора тестов усреднены по 10 независимым компьютерным экспериментам, для распознавания сортов ирисов – по 100 экспериментам и представлены в табл.3. (ошибки распознавания образов даются в % от общего числа предъявляемых образов).

Табл. 3. Результаты классификации

Тесты	ART-1 $\rho=0$		ART-1 $\rho=0.9$		ART-1 с неч. управлением ρ	
	Ошибки (%)	Кластер	Ошибки (%)	Кластер	Ошибки (%)	Кластер
Распознавание сортов ирисов	6,2	5	5,4	18	4,2	11
Генерат. тестов (200)	17,2	8	14,2	26	13,1	17
Генерат. тестов (500)	16,2	7	13,7	19	10,8	15

Анализ полученных результатов показывает, что ошибка распознавания при использовании сети ART-1 с нечетким управлением ρ значительно меньше по сравнению с другими алгоритмами.

ВЫВОДЫ

Проведенное экспериментальное исследование показало, что использование методов нечеткой логики для управления параметрами обучения нейронной сети адаптивного резонанса ART-1 позволяют автоматизировать процедуру настройки параметров сети в процессе ее

функционирования, что позволяет сделать вывод о целесообразности использования этого типа сетей для построения ИЭКОС.

Точность распознавания (табл.3.) рассмотренного алгоритма практически не уступает точности стандартного алгоритма ART –1 при больших значениях параметра сходства, а число образуемых кластеров оказывается меньше. Кроме того, на основе предложенного алгоритма по желанию пользователя можно регулировать соотношение точности – размер нейронной сети.

Рассмотренные гибридные нечеткие нейросетевые модели на основе ART-1, в отличие от других подобных моделей, позволяют повысить качество работы динамических интеллектуальных систем за счет использования лучших свойств каждой из объединяемых технологий.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

- [Ларичев О.И. и др.], Ларичев О.И., Финн В.К. Теория и методы создания интеллектуальных компьютерных систем // Информационные технологии и вычислительные системы. - 1998.-№1.
- [Еремеев А.П.] Еремеев А.П. Концепции времени и их применение в интеллектуальных системах // Сб. научн. тр. «Интеллектуальные системы и технологии». –М.:МИФИ.-2004.
- [Grossberg S.] Grossberg S. Studies of Mind and Brain. –Reidel. – Boston.-1982.
- [Люгер Дж.] Люгер Дж. Искусственный интеллект. Стратегии и методы решения сложных проблем.- Пер. с англ. –М.: Изд дом «Вильямс».-2003.
- [Комарцова Л.Г.] Комарцова Л.Г. Исследование алгоритмов обучения многослойного персептрона // Нейрокомпьютеры. Разработка и применение. – М.:Радиотехника. 2002.-№12.
- [Kirkpatrick S. and al.] Kirkpatrick S, Gellat C.D. Vecchi M. Optimization by Simulated Annealing. Sciece. -1983.-vol. 220.
- [Metropolis N. and al.] Equation of calculation by fast computing machines. -J. of Chem. Phys. -21(6). – 1998.
- [Комарцова Л.Г. и др.] Комарцова Л.Г. Максимов А.В. Нейрокомпьютеры.-М.: МГТУ им. Н.Э. Баумана.-2004.
- [Kussul E.M. and al.], Kussul E.M., Baidyk T.N., Lukowich V.V., Rachkovskij D.A. Adapt. NN-classifier with multifloat input coding // Proc. of 6-th Int. Conf. "NeuroNimes-2008". -Nimes, France. -2008.
- [Chin-Teng Lin] Chin-Teng Lin. Neural Fuzzy Systems to Intelligent Systems//A.Simon and Schuster Company. Upper Saddle River, NJ 07458.-1996 by Prentice Hall.

DYNAMIC MODELS OF INTELLIGENT SYSTEMS ON THE BASE OF ADAPTIVE RESONANCE THEORY NEURAL NETWORK

Komartsova L.G., Lavrenkov Ju.N.,
Antipova O.V., Kadnikov D.S.

*Moscow Bauman State Technical University,
Kaluga filial, Russia*

lkomartsova@yandex.ru, polikarp1@rambler.ru

The article is devoted to the problems for solving difficult problems, such as prediction, planning, pattern recognition and knowledge discovery in a number of application areas: bioinformatics, speech and language, image and video analysis, other engineering disciplines.

Most of these publications deal with static process, assuming that the process is represented adequately by the data available at present and that it does not change over time.

When the process is evolving, the modelling system needs to be trace the dynamics of the process and to be adapt to changes in the process. Many real-world problems from engineering, economics, social sciences require continuously adapting models. The modelling system needs to be evolving.

INTRODUCTION

For the evolutionary process is necessary to monitor the dynamics of their changes over time (ie, the operation mode of on-line) and adaptation to the environment (for example, the robot in an unfamiliar environment). In this paper we investigate some issues that need to be addressed for the creation of evolutionary systems that simulate human decision-making process in the complex is difficult to formalize problems in real time.

MAIN PART

Based on the analysis of the features that should have an evolutionary system architecture proposed by intellectual evolving system, which is a multi-module and multi-tier open architecture that can adapt to a particular domain based on the additional training of neural network modules in the operation of this system.

Solved the problem of automating the process of growth of the neural network ART-1, without specifying the user-specific values for similarity based on the use of fuzzy logic methods, which significantly reduce training time.

The fuzzy rule base that contains expertise has been used for adaptive changes in the values of learning parameters, depending on network conditions and real values of the parameters of learning.

At the stage of recognition in fuzzy ART-1 uses a standard search procedure of the neuron - the winner with $\rho = 0$, since in general the formation of new classes is not happening. To evaluate the effectiveness of the proposed algorithm was used a standard test set for recognizing irises and test generator.

CONCLUSION

Experimental tests showed that the use of fuzzy logic methods to control the parameters of neural network learning adaptive resonance ART-1 allow us to automate network configuration during its operation, which suggests the usefulness of this type of networks for dynamic intelligent systems.

The above hybrid fuzzy neural network model based on the ART-1, in contrast to other similar models can improve the dynamic performance of intelligent systems by using the best features of each of the merged technologies.