



OSTIS-2014

(Open Semantic Technologies for Intelligent Systems)

УДК 004.81:159.942.52

ИССЛЕДОВАНИЕ НЕЙРОСЕТЕВЫХ АЛГОРИТМОВ ОБУЧЕНИЯ В ИНТЕЛЛЕКТУАЛЬНЫХ ЭВОЛЮЦИОННЫХ СИСТЕМАХ

Комарцова Л.Г., Лавренков Ю.Н., Антипова О.В.

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

lkomartsova@yandex .ru

polikarp1@rambler.ru

В статье рассматриваются проблемы разработки и исследования нейросетевых и гибридных алгоритмов обучения для повышения эффективности функционирования интеллектуальных систем с целью поддержки принятия решений в сложных средах.

Ключевые слова: нейронная сеть (НС), алгоритм обучения, эволюционные и генетические алгоритмы обучения НС, обучение в реальном времени.

Введение

Развитие систем искусственного интеллекта (СИИ) в настоящее время связано с созданием новых методов и моделей, направленных на решение сложных проблем таких, как предсказание, планирование, распознавание образов и т. д. в различных прикладных областях [Ларичев и др., 1998]. Многие из публикаций по этим проблемам, несмотря на появление работ по созданию интеллектуальных систем реального времени, основываются на предположении неизменности во времени предъявляемых СИИ данных, статичности внешней среды. Хотя эти предположения в некоторых случаях являются допустимыми, используемые в СИИ статические методы не могут быть использованы при моделировании динамических процессов, а также при исследовании процессов, взаимодействующих с другими процессами, когда это взаимодействие априорно неизвестно. Другими словами, статические модели не могут быть применены к моделированию процессов, которые изменяются во времени, развиваются и эволюционируют. Для эволюционирующих процессов необходимым является отслеживание динамики их изменения во времени (т.е. функционирование в режиме on-line) и адаптации к внешней среде.

На основе анализа особенностей, которыми должна обладать эволюционная система, предложена многоуровневая и многомодульная открытая архитектура интеллектуальной эволюционной системы, основу которой составляет нейросетевая база знаний [Комарцова, 2003]. Эта

система может функционировать в двух режимах: on-line и off-line.

Обучение с учителем предназначено для организации пассивного («медленного») обучения в режиме off-line в отсутствие входной информации на входе системы. Накопленные в памяти примеры могут использоваться для обучения других нейросетевых модулей для поддержки «равновесия» с внешней средой. Основная нейросетевая модель в этом случае - многослойная нейронная сеть (МНС) с прямым распространением сигналов. Процедура обучения МНС может быть улучшена с помощью генетических алгоритмов (ГА) оптимизации, исследованных авторами [Комарцова, 2003, Комарцова, 2002]. Дальнейшее повышение эффективности использования ГА для обучения и адаптации нейросетевых модулей в составе эволюционной системы связывается с разработкой комбинированных алгоритмов. С этой целью предлагается алгоритм оптимизации, основанный на комбинации генетического алгоритма и алгоритма имитации отжига [Metropolis N. and al., 1998].

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.

На основе анализа особенностей, которыми должна обладать эволюционная система, предложена многоуровневая и многомодульная открытая архитектура интеллектуальной эволюционной системы, основу которой составляет нейросетевая база знаний [Комарцова, 2003]. Эта система может функционировать в двух режимах: on-line и off-line.

Обучение с учителем предназначено для организации пассивного («медленного») обучения в режиме off-line в отсутствие входной информации на входе системы. Накопленные в памяти примеры могут использоваться для обучения других нейросетевых модулей для поддержки «равновесия» с внешней средой. Основная нейросетевая модель в этом случае - многослойная нейронная сеть (МНС) с прямым распространением сигналов. Процедура обучения МНС может быть улучшена с помощью генетических алгоритмов (ГА) оптимизации. Дальнейшее повышение эффективности использования ГА для обучения и адаптации нейросетевых модулей в составе эволюционной системы связывается с разработкой комбинированных алгоритмов. С этой целью предлагается алгоритм оптимизации, основанный на комбинации генетического алгоритма и алгоритма имитации отжига [Metropolis N. and al., 1998].

Этот алгоритм позволяет использовать алгоритм имитации отжига в ГА для целенаправленного отбора хромосом в новую популяцию в соответствии с приращением функции фитнеса в каждом поколении. Модификация комбинированного алгоритма заключается в изменении операторов генной мутации, операторов отбора и селекции, введенных авторами в [Комарцова, 2002]. Применение операторов случайной мутации в ГА фактически означает формирование новых генов, что, в конечном итоге, приводит к расширению области поиска и повышению вероятности нахождения оптимального решения. Однако случайные мутации с равной вероятностью могут привести как к увеличению значений функции фитнеса, так и к ее уменьшению. Таким образом, целесообразно динамически управлять вероятностью случайной мутации в процессе работы ГА: на начальном этапе поиска значение вероятности должно быть достаточно высоким (0,05..0,1), а на конечном – стремиться к нулю. Аналогичные рассуждения можно провести и в отношении операторов селекции и отбора.

Многие реально существующие информационные системы работают в реальном времени и используют для обучения данные только из входного потока (поток данных, передаваемый по сети Internet, телеметрическая информация о состоянии объектов и т.д.), которые не снабжены

метками класса, к которым их можно отнести. Поэтому в нейросетевых моделях, производящих обработку динамических данных, используют обучение без учителя в режиме on-line. В качестве основной нейросетевой модели, которую предполагается использовать в эволюционной системе для быстрого обучения в режиме on-line, является нейронная сеть адаптивного резонанса ART (*Adaptive Resonance Theory network*).

В классическом алгоритме построения сети адаптивного резонанса параметр сходства ρ фиксируется перед началом функционирования сети и в дальнейшем остается неизменным. При этом начальное значение ρ задается пользователем сети. Поскольку от параметра сходства в конечном итоге зависит качество функционирования всей сети, выбор правильного значения ρ имеет решающее значение для работы сети ART. Когда сеть ART работает в динамичной среде, на ее входы может подаваться множество различных векторов, значения которых трудно прогнозировать заранее. В этом случае ρ выбирает эксперт на основе своего опыта, поскольку из-за недостатка знаний о входных векторах невозможно прогнозировать величину параметра сходства, которая бы обеспечивала адекватное функционирование сети ART. В подобной ситуации желательно на первом этапе работы сети установить параметр ρ достаточно близким к 1, чтобы сеть могла создать достаточное число классов, а в дальнейшем уменьшить ρ , чтобы предотвратить чрезмерный рост сети.

При работе в динамичной среде невозможно проводить предварительное обучение НС, т.е. обучение отдельно от среды, в которой сеть будет функционировать. Поэтому ART-сеть должна работать в режиме on-line с момента запуска.

С этой целью в работе реализована возможность автоматического выбора параметра ρ на основе механизма нечеткого вывода с учетом специфики внешней среды. В рассматриваемом алгоритме fuzzy ART-1 [Комарцова, Максимов, 2004] методы нечеткой логики используются для управления параметром сходства ρ , при этом нечеткость вводится на уровне задания приращений параметра сходства, в зависимости от ситуации, возникающей в ART-1 при кластеризации.

Проведенное экспериментальное исследование алгоритма ART-1 с нечетким управлением параметром сходства подтвердили целесообразность его применения в тех случаях, когда желательно максимально автоматизировать процедуру обучения НС. Кроме того, подбирая соответствующие значения параметра сходства, можно существенно повысить помехоустойчивость сети, что является особенно важным для интеллектуальных систем, работающих в режиме on-line.

Выполненные эксперименты показали высокую эффективность нейросетевого классификатора на

основе модифицированного комбинированного алгоритма:

В связи с этим в работе предлагается реализовать возможность автоматического выбора параметра ρ на основе механизма нечеткого вывода с учетом специфики внешней среды. В рассматриваемом алгоритме fuzzy ART-1 [Комарцова, Максимов, 2004] методы нечеткой логики используются для управления параметром сходства ρ , при этом нечеткость вводится на уровне задания приращений этого параметра в зависимости от ситуации, возникающей в ART-1 при кластеризации.

Проведенное экспериментальное исследование алгоритма ART-1 с нечетким управлением параметром сходства подтвердили целесообразность его применения в тех случаях, когда желательно максимально автоматизировать процедуру обучения НС. Кроме того, подбирая соответствующие значения параметра сходства, можно существенно повысить помехоустойчивость сети, что является особенно важным для интеллектуальных систем, работающих в режиме on-line.

Выполненные эксперименты показали высокую эффективность нейросетевого классификатора на основе модифицированного комбинированного алгоритма:

1) этот классификатор быстрее обучается даже по сравнению с комбинированным алгоритмом на основе ГА и имитации отжига, при этом для обучения требует меньшей обучающей выборки (ошибка классификации уменьшается на 0,1 % при увеличении размера обучающей выборки с 200 до 500), что является особенно важным для построения эволюционных систем;

2) число ошибок классификации при той же обучающей выборке ниже, чем в других классификаторах.

1. решаемой задаче.
2. Выходной слой обеспечивает выдачу информации в заданном формате из слоя принятия решений во внешнюю среду.
3. 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).
4. 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».

Функционирование ИС

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 свойствам, 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 перцептронного 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.

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. 1. 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.

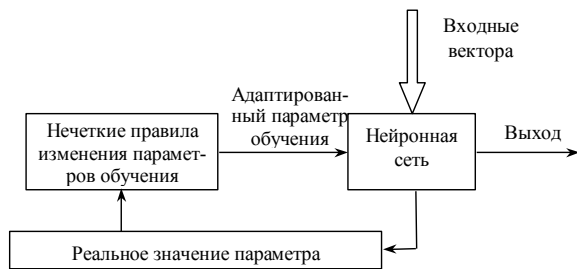


Рисунок 1 - Схема подстройки параметров обучения НС на основе методов нечеткой логики

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.

Таблица 1 - Фрагменты нечетких правил

$IE \backslash E$	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	–




Рисунок 2 - 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.

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.

Таблица 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).

Таблица 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.

Заключение

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 ИС.

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 точность – 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 перцептрона // Нейрокомпьютеры. Разработка и применение. – М.: Радиотехника. 2002.-№12. [Kirkpatrick S. and al.] Kirkpatrick S, Gellat C.D. Vecchi M. Optimization by Simulated Annealing. Science. -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., BaidykT.N., LukowichV.V., Rachkovskij D.A. Adapt. NN-classifier with multfloat 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.

RESEARCHING OF NEURAL LEARNING ALGORITHMS IN INTELLIGENT EVOLUTION SYSTEMS

Komartsova L.G., Lavrenkov Ju.N., Antipova O.V.

*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 (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.