

УДК 519.71

ГИБРИДНЫЕ ИСКУССТВЕННЫЕ ИММУННЫЕ СИСТЕМЫ И МЯГКИЕ ВЫЧИСЛЕНИЯ (Обзор)

В.И.Литвиненко

*Херсонский национальный технический университет,
johndoe2004@mail.ru*

Розглядається проблема розроблення гібридних штучних імунних систем. Проаналізовано існуючі тенденції, намічено основні напрямки створення нових гібридних імунних систем.

Ключові слова: штучна імунна система, м'які обчислення, гібридна система.

Problem of development of hybrid artificial immune systems is considered. Existing tendencies are analyzed, directions are scheduled for creation of new hybrid immune systems.

Key words: artificial immune system, soft computing, hybrid system.

Рассматривается проблема разработки гибридных искусственных иммунных систем. Проанализированы существующие тенденции, намечены основные направления создания новых гибридных иммунных систем.

Ключевые слова: искусственная иммунная система, мягкие вычисления, гибридная система.

Введение

Опыт последних лет показал, что применение в информатике однородных методов, т.е. методов, соответствующих одной научной парадигме, для решения сложных проблем далеко не всегда приводит к успеху. В гибридной архитектуре, объединяющей несколько парадигм, эффективность одного подхода может компенсировать слабость другого. Комбинируя различные подходы, можно обойти недостатки, присущие каждому в отдельности.

Гибридные системы состоят из различных компонентов, объединенных в интересах достижения поставленных целей. Интеграция и гибридизация различных методов и информационных технологий позволяет решать сложные задачи, которые невозможно решить на основе каких-либо отдельных методов или технологий. При этом в случае интеграции разнородных информационных технологий следует ожидать синергетических эффектов более высокого порядка, чем при объединении различных моделей в рамках одной технологии.

Постановка проблемы. Как показывают исследования ни один из алгоритмов, используемых в искусственных иммунных системах для решения прикладных задач, не лишен недостатков. Как правило, в зависимости от применяемой модели иммунной системы, получается выигрыш по одним параметрам и проигрыш по другим. Поэтому весьма актуально построение гибридных моделей на основе различных парадигм мягких вычислений.

Проведенные нами исследования показали достаточное количество аналитических работ в области создания гибридных систем на основе эволюционных алгоритмов, нечетких систем, нейронных сетей и мультиагентов. Аналогичные аналитические работы по гибридным иммунным

системам и методология их создания отсутствуют. Работы по гибридным иммунным системам ограничиваются описанием удачных гибридизаций при решении определенных задач, их анализ и обобщение не проводились.

В связи с этим в данной работе ставится **задача**: провести анализ существующих гибридных иммунных систем и определить основные направления и тенденции разработки и создания гибридных иммунных систем.

1. Искусственные иммунные системы

Под искусственными иммунными системами (ИИС) понимаются адаптивные структуры, построенные на метафорах теоретической иммунологии, наблюдаемыми иммунными функциями, принципами и моделями, которые применяются для решения прикладных задач. Несмотря на то, что естественные иммунные системы изучены далеко не полностью, на сегодняшний день существует, по крайней мере, три теории, которые объясняют работу иммунной системы и описывают взаимодействие ее элементов, а именно теория отрицательного отбора [1, 2], теория клональной селекции [3, 4] и теория иммунной сети [5, 6]. Они легли в основу создания трех основных алгоритмов функционирования ИИС.

Сфера применения ИИС на сегодняшний день включает следующие области (но не ограничивается ими): методы вычислений, когнитивные модели, обнаружение аномалий и неисправностей, мультиагентные системы, модели самоорганизации, модели коллективного интеллекта, системы поиска и оптимизации, модели автономных распределенных систем, модели искусственной жизни, системы компьютерной безопасности, методы извлечения информации, обработка сигналов и изображений и др.

2. Гибридизация искусственных иммунных систем

Термин “*мягкие вычисления*” был введен в 1994 г. основоположником теории нечетких множеств, профессором Лотфи Заде [7]. По сути, он означает новый метод вычислительной математики, который в ряде областей оказался более эффективным, чем традиционные методы. Мягкие вычисления не являются отдельной методологией. Это, скорее, объединение, комбинирование различных направлений. Главными партнерами в этом объединении являются нечеткая логика, нейровычисления, генетические и вероятностные вычисления с более поздним включением хаотических систем, сетей доверия, искусственных иммунных систем и теории обучения. Основные технические принципы для проектирования гибридных систем могут быть найдены в [8].

Вычислительные методы, основанные на функциональной аппроксимации, случайном поиске и оптимизации, входящие в мягкие вычисления, в основном делятся на механизмы локального поиска (нейронные сети) и глобального поиска (эволюционные вычисления). Многие подходы, входящие в направление мягких вычислений, являются универсальными, однако они хорошо дополняют друг друга и используются в различных

комбинациях для создания гибридных интеллектуальных систем. Поэтому при создании систем, работающих с неопределенностью, надо понимать, какая из составляющих частей мягких вычислений или какая их комбинация наилучшим образом подходит для решения задачи.

Гибридные интеллектуальные системы условно можно разделить на следующие классы [9]: (а) гибридные системы с функциональным замещением; (б) гибридные системы с взаимодействием; (в) полиморфные гибридные системы. В [10] было введено понятие искусственных иммунных систем (ИИС) как новой парадигмы мягких вычислений.

2.1. Искусственные иммунные системы и искусственные нейронные сети

Взаимосвязь между иммунной и нервной системами исследовалась еще с первых дней создания теоретической иммунологии. Однако предложенная Н. Ерне теория иммунной сети стимулировала сравнительные исследования обеих систем для поиска новых параллелей между ними. Как результат этого исследования, модели иммунной сети стали использоваться в качестве новых подходов для разработки и усовершенствования моделей нейронных сетей и наоборот. В дальнейшем была предпринята попытка Де Кастро и Вон Зубеном [11], сравнения модели искусственной иммунной сети (aiNet) с искусственными нейронными сетями.

В работах [12-13] автор использовал аналогию между теорией иммунной сети и центральной нервной системой для разработки модели нейронной сети. Иммунная система рассматривалась как L-мерная система, содержащая большое количество сингулярных точек, рассматриваемых как аттракторы. Обучение в этой системе осуществлялось изменением сил стимулов, представляемых сети и сил связи между клетками, которые фиксировались. Данный подход отличался от традиционных представлений об искусственных нейронных сетях, в которых векторы весов адаптируются к входным данным.

В работах [13-14] [20,21] предложено альтернативный вариант использования иммунной системы для поиска адекватной архитектуры нейронной сети. Основываясь на теории параллельной распределенной обработки PDP (Parallel Distributed Processing), в [15] авторы предложили PDP-иммунную сеть. При этом авторами не был явно представлен алгоритм обучения, хотя они утверждали, что поведение при обучении иммунной системы не контролируется.

В [16] авторы описали растущую булеву конкурентную сеть, основанную на клональном отборе и принципах созревания аффинности иммунной системы. Главными особенностями предложенного алгоритма являются конкурентное обучение, автоматическое порождение (генерация) архитектуры сети с ростом и сокращением фаз, а также, бинарное представление сил связи в Хемминговом пространстве. Процедура обновления веса является поиском, управляемым мутацией, который моделирует процесс созревания аффинности репертуара антител, такой, что веса (антитела) становятся более совершенным компонентом для распознаваемых антигенов.

Авторы работы [17] для инициализации многослойной нейронной сети с прямым распространением, обучаемой алгоритмом обратного распространения ошибки, применили подход, предложенный в [18] и использующий модели отжига, основанные на иммунной метафоре. Авторы утверждали, что корреляция между качеством начальных весов сети и качеством выхода сети может быть отождествлена с качеством начального репертуара антител и качеством иммунного ответа. В работе выделялись подходы к созданию разнообразия антител, используя Евклидово пространство форм. Они предложили алгоритм, способный генерировать множество начальных векторов весов, достаточно разнообразных, для уменьшения вероятности сходимости нейронной сети с прямым распространением к локальному оптимуму.

Ранее описанная модель иммунной сети, названной aiNet, применена в [19] для определения числа и положения радиально-базисных функций, которые используются в радиально-базисных нейронных сетях (RBF). Главной целью алгоритма являлась кластеризация и фильтрация множества данных. Для представления молекул авторы использовали Евклидово пространство форм. Здесь антитело, соответствовало кандидату в центры радиально-базисной нейронной сети, а антиген – входному образу.

2.2. Искусственные иммунные системы и эволюционные алгоритмы

Большое число разработанных в настоящее время ИИС, характеризуется наличием адаптации, подобной той, которая используется в эволюционных алгоритмах. В данном разделе описываются работы, которые явно принимают во внимание эволюционный алгоритм как часть обработки или те, которые комбинируют (объединяют) их с ИИС, для улучшения отдельных характеристик. Стефания Форрест [20] использовала бинарное пространство форм для модели иммунной системы, предназначенной для решения задач распознавания образов. В данной модели для обеспечения разнообразия детекторов и увеличения обобщающих способностей иммунного алгоритма использовался генетический алгоритм. В этом случае, под способностью обобщения понимается обнаружение общих шаблонов, которые используются множеством антигенов. Разнообразие популяции напротив, соответствует множеству индивидуумов, способных к широкому покрытию ландшафта аффинности. Авторы использовали Хемминговое пространство форм для представления и Хемминговое расстояние для вычисления аффинности между молекулами.

В работе [21] были исследованы эффекты эволюции генетического кодирования молекул антител и применения эволюционного алгоритма для создания начальных репертуаров клеток и молекул для ИИС. В работе [22] предложен подход концептуального обучения, в котором использовался коэволюционный генетический алгоритм, предназначенный для создания искусственной иммунной системы, чьи антитела могли отличать примеры из обучающего множества “свой” от примеров множества “чужой”. Авторы

исследовали способность ИИС к обобщению и управлению разнообразием популяции.

Авторы работы [23] применили способности ИИС к распознаванию образов, а также их адаптационные свойства для улучшения работы генетических алгоритмов при решении задач структурной оптимизации. Их работа касалась двух аспектов: применение способностей иммунных систем к ускорению сходимости ГА и обработка ограничений при оптимизации, основанной на ГА. В работе [24] авторы исследовали возможность обучения ИИС при помощи генетического алгоритма и ее последующее применение для решения задач календарного планирования (синтеза множества планов), которые бы вместе охватывали весь диапазон ситуаций, как предсказуемых так и непредсказуемых. Их модель включала эволюцию с использованием библиотек генов, созревание аффинности для иммунного ответа и принцип клонального отбора.

Николай Николаев [25] разработал иммунную версию генетического программирования (ГП). В предложенной им иммунной версии ГП (иГП), прогрессивный поиск управляется динамической функцией пригодности, на основании аналогии с моделью иммунной сети. Функция пригодности состоит из двух динамических моделей, которые оказывают влияние друг на друга: 1) модель, используемая для распространения генетических программ, которые соответствуют более важным примерам, и 2) модель, используемая для изменения важности примеров в соответствии с количеством генетических программ, которые распознают эти примеры.

2.3. Искусственные иммунные системы и нечеткие системы

В иммунной системе распознавание антигенов является приблизительным, т.е. иммунный ответ может выявиться, даже когда связывание между антигеном и антителом не происходит, следовательно, вполне может удовлетворить и приблизительное связывание. Вместе с кросс-реактивностью эти характеристики подчеркивают присутствие "нечеткости" в пределах иммунных систем, предполагая, что нечеткая логика могла бы соответствующим образом моделировать несколько аспектов и механизмов иммунной системы. Следовательно, нечеткие системы и искусственные иммунные системы могут обеспечить плодотворные взаимодействия, данные вопросы рассмотрим на следующих примерах.

В работе [26] была предложена вычислительная система, использующая иммунные метафоры и другие методы мягких вычислений. Предложенная им гибридная система состояла из комбинаций искусственных иммунных систем с искусственными нейронными сетями, нечетких систем и эволюционными алгоритмами, в соответствии с решаемой задачей. Этот подход был применен в приложениях, связанных с задачами управления. В каждом специфическом случае несколько элементов иммунной системы использовались на различных уровнях стратегий управления. Иммунные процессы и механизмы, такие как созревание аффинности были выделены как важный элемент управления, но в

целом подход был сосредоточен на аналогиях между иммунной системой и задачей управления. Предложенная система использовалась для решения задачи автономного управления летательных аппаратов.

Джеймс Болдуин в работе [27] предположил, что приобретенные в течение жизни индивидуума характеристики могут стать частью состава генома последующих поколений без Ламарковского наследования. Суть “Эффекта Болдуина” состоит в улучшении фенотипа хромосомы и запоминании полученного значения без изменения генотипа хромосомы. В работах [28-29] авторы использовали различные типы антител, каждый для определенной задачи. В этих работах, уровнем возбуждения данного антитела была функция принадлежности, зависящая от процента успешного решения определенной задачи. Эта функция типична для нечетких систем, где универсум рассуждений (в данном случае процент от успеха) делится на несколько интервалов, что приводит к приближительному представлению переменной при обучении. В работе [30] авторы предложили искусственную иммунную модель сети для анализа данных и для решения задач нечеткой кластеризации.

3. Структуры и процессы для разработки гибридных моделей

Практическое применение большинства обсужденных парадигм мягких вычислений требует наличия таких свойств алгоритмов как *модели отбора* и *параметров адаптации*.

Модель отбора соответствует определению подходящей структуры для системы. В нейронных сетях это включает в основном определение числа связей, нейронов и слоев, которые используются в сети. Эволюционные алгоритмы обычно имеют установленное число индивидуумов (хромосом) в популяции, которые должны быть определены априорно. В нечетких системах это соответствует числу делений для каждой лингвистической переменной и нечетким правилам, которые должны быть априорно настроены.

Параметры адаптации. Другим важным аспектом, затрагивающим большинство подходов мягких вычислений, является потребность априорного определения некоторых параметров адаптации. В нейронных сетях осуществляется адаптация таких параметров, как коэффициент скорости обучения, функция активации и коэффициент затухания окрестности которые должны соответствовать типу сети и/или алгоритму обучения. В случае эволюционных алгоритмов вероятность генетической изменчивости, отбор и стратегия репродукции – часть определенных пользователем параметров. В нечетких системах, различные типы функций принадлежности (Гауссовский, треугольный, трапециевидный, и т.д.) ведут к различным действиям алгоритма.

В Таблице 1 показано основные сходства и различия структур, функций, свойств, компонент и характеристик ИИС, ИНС и ЭА.

Можно выполнить сравнительный анализ “мягких” информационных технологий (нейронных сетей, нечеткой логики, генетических алгоритмов и искусственных иммунных систем), хорошо зарекомендовавших себя при

решении трудно формализуемых задач. Результаты исследования достоинств и недостатков этих технологий представлены в Таблице 2.

ИНС, ЭА и НС обладают большим потенциалом для взаимодействия с искусственными иммунными системами. Большинство работ, которые описаны в литературе, пытаются объединить один или большее количество этих мягких вычислительных парадигм с ИИС, совместно используя искусственные нейронные и иммунные модели сети или иммунные и эволюционные алгоритмы. В данном разделе описаны существующие примеры тенденций интегрированного использования искусственных иммунных систем совместно с ИНС, ЭА и НС.

Классические методы исследования операций и системы искусственного интеллекта (СИИ), построенные на основе классической логики, не обладают такими возможностями. Методы исследования операций целесообразно использовать для обработки достоверных данных, интегрированные методы на основе НС, НЛ ГА и ИИС обеспечивают возможность обработки информации и формирования знаний в условиях неопределенности, что объясняет широкие возможности интеллектуальных систем, использующих эти технологии.

Выбор технологии для обработки исходной информации зависит от особенностей решаемых задач, от числа количественных и качественных параметров, описывающих проблему, от уровня ее проработанности. Поэтому необходимо определить условия применимости каждой из рассматриваемых технологий, а также разработать методы и алгоритмы, позволяющие адаптировать их к решению конкретных задач проблемной области. Так во многих случаях наилучшее решение систем обработки данных (на всех этапах поиска рациональных решений) может быть получено путем использования эволюционных методов и искусственных иммунных систем.

Основные задачи, которые чаще всего должны решать гибридные модели: оптимизация; многокритериальный выбор; классификация и распознавание; прогнозирование; логический вывод и т.д. Как показано в таблице 1, для каждой из отдельных компонент гибридных моделей необходимо решать ряд внутренних проблем, связанных с их недостатками, но их совместное использование при решении общей задачи позволяет компенсировать эти недостатки и усилить достоинства (получить синергетический эффект).

Таблица 1

Сравнение подходов ИИС, ИНС и ЭА

Характеристика	Искусственные иммунные системы	Искусственные нейронные сети	Эволюционные алгоритмы
Компоненты	Атрибуты строк	Искусственные нейроны	Строки, представляющие хромосомы
Локализация компонентов	Динамическая локализация	Предопределенные /динамические (детерминированные) локализации	Динамические локализации
Структура	Множество дискретных или сетевых элементов	Сетевые нейроны	Дискретные элементы
Сохранение знаний	Сетевая связь атрибут/строки	Сила связей	Строки хромосом
Динамизм	Обучение/развитие	Обучение	Эволюция
Метадинамизм	Устранение / пополнение компонентов	Конструктивные / сокращенные алгоритмы	Устранение / пополнение особей
Взаимодействие с другими компонентами	Через распознавание атрибутов строк или сети	Через сетевые связи	Через операторы рекомбинации и/или функцию пригодности
Взаимодействие с окружением	Распознавание входных образов или оценка целевой функции	Распознавание входных образов или оценка целевой функции	Оценка целевой функции
Порог	Влияет на аффинность элементов	Влияет на активность нейрона	Влияет на генетическую изменчивость
Устойчивость	Популяция (сеть) индивидуумов	Сеть индивидуумов	Популяция индивидуумов
Состояние	Концентрация и аффинность	Активация уровня выходных нейронов	Генетическая информация в хромосомах
Управление	Иммунные принципы, теория или процессы	Алгоритм обучения	Эволюционный алгоритм
Способность обобщения	Перекрестная реакция	Сетевая экстраполяция	Обнаружение общих шаблонов
Нелинейность	Связывающая функция активации	Нейронная функция активации	Не явное
Характеристика	Эволюция и коннективизм	Согласно алгоритму обучения	Эволюционный

Сравнительная таблица информационных технологий

Технология	Достоинства	Недостатки
Методы исследования операций	<ol style="list-style-type: none"> 1. Высокая эффективность решения задач математического моделирования. 2. Возможность работы в реальном режиме времени. 3. Возможность решения задач оптимизации. 	<ol style="list-style-type: none"> 1. Отсутствие способности к обучению. 2. Нельзя работать с неопределенными, неточными данными, нелинейными. 3. Сложность представления знаний и применения экспертных знаний. 4. Необходимость вычисления градиента функции, зависимость от начального приближения
Нейронные сети	<ol style="list-style-type: none"> 1. Способность к обучению 2. Универсальность при решении нестандартных задач. 3. Возможность прогнозирования и быстрой корректировки прогноза для новых данных. 4. Возможность работы с неточностью, неопределенностью, нелинейностью. 5. Высокая эффективность программного обеспечения на параллельных ЭВМ. 6. Возможность работы обученной НС в реальном масштабе времени 	<ol style="list-style-type: none"> 1. Отсутствие возможности объяснения полученных результатов. 2. Большое время обучения сети. 3. Трудность формирования топологии нейронной сети, адекватной решаемой задаче. 4. Необходимость достаточной представительности обучающей выборки. 5. Эвристичность параметров алгоритмов обучения различных типов сетей. 6. Ресурсоемкий характер обучения сети. 7. Сложность дообучения и переобучения нейронной сети.
Эволюционное моделирование и генетические алгоритмы	<ol style="list-style-type: none"> 1. Быстрая сходимость в задачах оптимизации. 2. Возможность исследования неопределенной и неточной экспериментальной информации. 3. Возможность работы с нелинейностью. 4. Возможность быстрой корректировки получаемых решений. 5. Высокие адаптационные свойства при решении сложных проблем. 	<ol style="list-style-type: none"> 1. Не гарантируют получения оптимального решения за приемлемое время вследствие использования механизмов случайности при генерации новых решений. 2. Высокая зависимость качества решения от способа реализации генетических операторов и стратегии поиска экстремума. 3. Невысокая точность получаемых результатов оптимизации. 4. Недостаточная развитость механизма поддержания разнообразия векторов решений в популяции.
Системы на основе нечеткой логики	<ol style="list-style-type: none"> 1. Простота представления знаний. 2. Возможность использования экспертных знаний 3. Возможность объяснения результатов вывода. 	<ol style="list-style-type: none"> 1. Трудность формирования правил и функций принадлежности. 2. Трудность проверки на непротиворечивость базы знаний при получении новых знаний. 3. Отсутствие возможности обучения. 4. Отсутствие возможности оптимизации получаемых результатов.

		5. Необходимость априорного определения компонентов моделей: нечетких высказываний, функций принадлежности каждого значения лингвистических переменных, структуры базы нечетких правил и др. 6. Отсутствие стандартной методики конструирования нечетких систем.
Искусственные иммунные системы		
Системы отрицательного отбора	1. Отсутствие необходимости в априорной информации об условиях возникновения аномалий и как следствие отсутствие необходимости наличия комплементарной компоненты обучающей выборки при обучении системы. 2. Возможность с большой вероятностью обнаруживать изменения в исходном наборе данных с помощью небольшого набора детекторов. 3. Возможность получения робастных решений за короткое время.	1. Трудность фиксирования семантики получаемых решений и отсутствие возможности объяснения полученных результатов. 2. Часто необходимо большое количество детекторов для обеспечения лучшего охвата (уровень детекции). 3. Трудность объединения алгоритма с другими иммунными алгоритмами. 4. Трудность определения четкой границы между “своими” и “чужими” паттернами.
Системы на основе клонального отбора	1. Наличие развитых механизмов поддержки разнообразия векторов решений в популяции. 2. Наличие механизмов одновременного локального и глобального поиска. 3. Быстрая сходимость алгоритма в задачах оптимизации. 4. Возможность исследования неопределенной и неточной экспертной информации. 5. Возможность работы с нелинейностью. 6. Быстрая корректировка получаемых решений	1. Большое количество параметров управления. 2. Отсутствие гарантии получения оптимального решения за приемлемое время, вследствие использования механизмов случайности при генерации новых решений. 3. Высокая зависимость производительности от вида иммунных операторов и стратегий поиска решений. 4. Трудность фиксирования семантики получаемых решений и отсутствие возможности объяснения полученных результатов.
Системы на основе иммунной сети	1. Возможность распознавания структуры данных за счет адаптации топологии сети, формирования и исследования внутреннего образа. 2. Независимость результата от начальной топологии сети. 3. Возможность очистки и сжатия данных. 4. Возможность построения множества альтернативных моделей данных с минимальной корреляцией и получения множества качественных коллективных решений 5. Возможность быстрой адаптации при поступлении новых данных за счет динамической топологии.	1. Большое количество параметров управления. 2. Необходимость соблюдать баланс роста и сжатия сети. 3. Отсутствие гарантии получения оптимального решения за приемлемое время, вследствие использования механизмов случайности при генерации новых решений. 4. Высокая зависимость производительности от способов реализации иммунных операторов и стратегий поиска решений.

При создании гибридных моделей необходимо учитывать следующие факторы [31,32]: назначение системы; методы поиска и анализа альтернативных вариантов решений; особенности реализации. Основные методы поиска и анализа решений во многом определяются типом задаваемой исходной информации. Гибридные интеллектуальные системы условно можно разделить на следующие классы [3].

1. Гибридные системы с функциональным замещением. В них используется одна модель, один из элементов которой замещается другой моделью, например: а) перерасчет весов в процедуре обратного распространения с помощью генетического алгоритма. Уменьшается число итераций для получения решений; б) подбор функций принадлежности в нечетком контроллере с помощью генетического алгоритма. Функции получаются гораздо лучше, чем при ручном подборе.

2. Гибридные системы с взаимодействием. Используются независимые модули, которые обмениваются информацией и выполняют различные функции с целью получения общего решения. Если задача разбивается на распознавание образов, вывод и оптимизацию, то эти функции берут на себя нейронные сети, экспертные системы и генетические алгоритмы. Например: а) нахождение центров радиально-базисных функций РБФ-нейронной сети при помощи алгоритма нечеткой кластеризации. Повышается скорость обучения нейронной сети; б) разбиение лингвистической переменной на термы при помощи алгоритма иерархической кластеризации в нечетких нейронных сетях. В итоге также приводит к повышению скорости обучения нечеткой нейронной сети.

3. Полиморфные гибридные системы. Одна модель используется для имитации функционирования других моделей. Так рассуждения с помощью цепочки правил можно моделировать с помощью нейронной сети (также и генетический поиск). Например: а) синтез структуры нейронной сети при помощи генетического алгоритма. Улучшение обобщающих способностей нейронной сети; б) синтез структуры байесовской сети для решения задач классификации при помощи генетического алгоритма. Оптимизируется процесс адаптации структуры байесовской сети под решаемую задачу.

Для создания гибридных моделей первого типа необходимо исследовать недостатки каждой из технологий и определить пути интеграции для устранения этих недостатков, причем внутренняя структура моделей остается неизменной. Создание второго типа моделей требует более глубокого исследования алгоритмов функционирования каждой из моделей для определения способа реализации отдельных функций на основе более прогрессивных технологий. В настоящее время более исследованным классом являются модели второго типа. Гибридизация нейросетевых и нечетких систем рассмотрена в [31,32], где приведены примеры нейросетевых нечетких систем, реализующих вывод в нечеткой базе знаний с помощью архитектуры ANFIS (Adaptive Neuro-Fuzzy Inference System), и нечетких нейронных сетей, в которых отдельные элементы НС являются нечеткими (например, нейроны).

Таблица 3

Типология гибридных моделей на основе искусственных нейронных сетей (ИС), эволюционных алгоритмов (ЭА), нечеткой логики (НЛ), алгоритма искусственной иммунной сети (АИИС), алгоритма клонального отбора (АКО) и алгоритма отрицательного отбора (АОО)

Исходная технология	Интегрируемая технология	Способ интеграции	Ожидаемый эффект
ИС	АКО	1. Подбор эвристических параметров ИНС при обучении (параметрическая оптимизация) 2. Формирование оптимальной топологии ИНС (структурная оптимизация) 3. Синтез топологии и подбор эвристических параметров (структ.-параметрическая оптимизация)	1. Повышение скорости обучения ИНС. 2. Снижение трудоемкости создания ИНС, отбор информативных признаков. 3. Повышение качества обучения и дообучения ИНС.
ИС	АИИС	1. Подбор эвристических параметров ИНС при обучении (параметрическая оптимизация) 2. Формирование оптимальной топологии ИНС 3. Синтез топологии и подбор эвристических параметров ИНС	1. Повышение скорости обучения ИНС. 2. Снижение трудоемкости создания ИНС, отбор информативных признаков. 3. Повышение качества обучения и дообучения ИНС. 4. Повышение качества получаемых решений.
ИС	НЛ	1. Подбор эвристических параметров ИНС при обучении и распознавании 2. Построение нейросетевых нечетких моделей.	1. Повышение скорости обучения и качества распознавания ИНС. 2. Приобретение объяснительного качества для ИНС.
ИС	ЭА	1. Формирование оптимальной топологии ИНС 2. Обучение ИНС как альтернатива Back Propagation	1. Снижение трудоемкости, отбор параметров 2. Повышение скорости обучения и качества распознавания ИНС
АКО	ИС	1. Подбор параметров АКО	1. Адаптация параметров АКО под решаемую задачу.
АКО	ЭА	1. Использование генетических операторов для управления популяцией АКО 2. Использование представления решений в виде логико-математических зависимостей 3. Создание репертуара индивидуумов для АКО	1. Увеличение разнообразия пространства решений 2. Решение задач аппроксимации и прогнозирования 3. Ускорение сходимости алгоритма к глобальному оптимуму.
АКО	НЛ	1. Моделирование нечеткого взаимодействия между антигенами и антителами.	1. Улучшение разделяющей способности при решении задач кластеризации и классификации.
АОО	АКО	1. Применение операторов клонального отбора для оптимизации размещения детекторов	1. Повышение разделяющей способности.

АОО	АИИС	1. Применение АИИС для оптимизации размещения детекторов (геометрический подход)	1. Повышение разделяющей способности
АОО	НЛ	1. Использование нечетких детекторов	1.Повышение разделяющей способности, отсутствие возможности объяснения полученных решений.
АОО	ЭА(АКО)+НЛ	1.Генерация нечетких правил	1.Оптимизация нечеткой базы правил
АИИС	ИНС	1. Подбор параметров АИИС	1. Адаптация параметров АИИС под решаемую задачу в ходе развития популяции.
АИИС	ЭА	1. Использование генетических операторов 2. Использование представления решений в виде логико-математических зависимостей 3.Создание репертуара индивидуумов для АИИС.	1.Увеличение разнообразия пространства решений 2. Решение задач аппроксимации и прогнозирования с получением множества альтернативных моделей. 3. Ускорение сходимости алгоритма.
АИИС	НЛ	1. Моделирование нечеткого взаимодействия антиген-антитело и антитело-антитело	1. Улучшение разделяющей способности
ЭА	АКО	1. Использование операторов клонального отбора в эволюционных алгоритмах.	1. Возможность осуществления локального и глобального поиска
ЭА	АИИС	1. Использование операторов АИИС в эволюционных алгоритмах.	1. Очистка и сжатие данных при выявлении зависимостей и оптимизации.
ЭА	ИНС	1.Формирование целевой функции.	1. Новый способ задания целевой функции в генетическом алгоритме.
ЭА	НЛ	1.Подбор параметров в ГА 2.Определение критерия останова. 3.Реализация новых генетических операторов	1.Адаптация параметров ГА под решаемую задачу в ходе развития популяции 2.Снижение вычислительной сложности
НЛ	АКО	1.Моделирование селекции нечетких правил	1. Оптимизация нечетких баз правил.
НЛ	ИНС+АКО	1.Синтез правил и подбор параметров функций принадлежности в нечетких нейронных сетях	1. Повышение скорости и качества обучения и дообучения; снижение трудоемкости создания сетей, отбор информативных признаков
НЛ	АИИС	1. Разделение входных признаков на термы при помощи кластеризации.	1. Получение оптимального количества правил.
НЛ	ИНС	1. Автоматическое формирование функции принадлежности 2. Реализация нечетких отношений.	1. Ниже трудоемкость формирования баз знаний. 2.Снижение вычислительной сложности нечеткого вывода.
НЛ	ЭА	1. Настройка компонент системы на базе НЛ. 2.Проверка баз знаний	1. Уменьшение противоречивости БЗ.

Гибридизация нейронных сетей и генетических алгоритмов рассматривалась в [33] для выбора оптимальной топологии НС, а в [34] - для оптимизации обучающей выборки. В работах [35-37] представлены модели первого типа в которых осуществлена гибридизация алгоритмов клонального отбора и искусственной иммунной сети с одной стороны с алгоритмом экспрессии генов относящегося к эволюционным алгоритмам, а также частично МГУА. В [38] осуществлена гибридизация алгоритмов отрицательного и клонального отбора для оптимизации размещения детекторов (аналитический подход по результатам), что позволило повысить разделяющую способность алгоритма при решении задач бинарной классификации.

В работе [39] осуществлена гибридизация алгоритма отрицательного отбора и искусственной иммунной сети для задач бинарной классификации и выявления аномалий. В [40-41] описан алгоритм структурно-параметрической оптимизации вейвлет- и радиально-базисных нейронных сетей с помощью алгоритма клонального отбора (полиморфная гибридная система). В работах [42-43] описана гибридизация алгоритма клонального отбора и ИНС для решения задачи синтеза коллектива нейронных сетей. В работах [44-45] описана методология гибридизации алгоритмов клонального отбора, иммунной сети для решения задачи синтеза нечеткой нейронной сети, предназначенной для решения задач прогнозирования и аппроксимации. В работе [46] описана гибридизация алгоритмов нечеткой оптимизации и клонального отбора.

Выводы

В работе рассмотрены основные тенденции развития гибридных искусственных иммунных систем. Рассмотрены возможные подходы их гибридизации с эволюционными алгоритмами, искусственными нейронными сетями и системами на основе нечеткой логики. За рамками статьи остались вопросы гибридизации ИИС с ДНК-вычислениями, рассуждениями на основе прецедентов, индуктивными методами (МГУА), классифицирующими системами, системами на основе муравьиных колоний, системами роевого интеллекта, а также подходы с точки зрения метаэвристик. Основное внимание уделялось системам с функциональным замещением и частично гибридным системам с взаимодействием.

Общий вывод состоит в том, что построение гибридных моделей на основе ИИС позволяет повысить их эффективность за счет адаптации к решаемой задаче и уменьшения вычислительной сложности. В работе проанализированы основные достоинства и недостатки искусственных иммунных систем. Показано, что построение гибридных интеллектуальных систем стало ведущей тенденцией современной информатики. Предложены существующие и гипотетические схемы гибридизации ИИС, ИНС, ЭА и НЛ, позволяющие получить заметный синергетический эффект при решении задач.

Литература

1. Forrest S., Perelson A., Allen L., Cherukuri R. Self-nonsel discrimination in a computer / Proc. IEEE Symp. on Research in Security and Privacy, 1994.-P.202–212.
2. Forrest S, Perelson A Computation and the immune system, SIGBIO Newsletter, Association for Computing Machinery 12(2): 1992.– 52–57pp.
3. Ada G., Nossal G. The clonal selection theory // Scientific American. - 257(2). – 1987.– 50–57 p.
4. De Castro LN, Von Zuben FJ The clonal selection algorithm with engineering applications, Proc of GECCO'00, Workshop Proceedings, 2000.– P. 36–37.
5. Timmis J. Artificial Immune Systems: A Novel Data Analysis Technique Inspired by the Immune Network Theory / Ph.D. Dissertation, Department of Computer Science, University of Wales. – 2000.– 163 p.
6. De Castro L., Von Zuben F. An evolutionary immune network for data clustering. – Proc. IEEE Brazilian Symposium on Neural Networks, 2000.– P. 84–89.
7. Zadeh L. What is soft computing // Soft Computing. – 1. - 1997. – p. 1.
8. Khosla, J., Dillon T. Engeneering Intellegent Hybrid Multy-Agent Systems. – Kluwer Academic Publshers, 1997.
9. Аверкин А.Н., Прокопчина С.В. Мягкие вычисления и измерения // Интеллектуальные системы (МГУ)– 1997, - Т.2, вып. Л-4. — С. 93-114.
10. de Castro LN, Timmis J Artificial immune Systems: A New Computational Intelligence Paradigm. – Springer-Verlag , 2003.– 357 p.
11. De Castro L., Von Zuben F. Immune and Neural Network Models: Theoretical and Empirical Comparisons // Int. J. of Computational Intelligence and Applications (IJCIA), 2001.– P. 45-56.
12. Hoffmann G. A neural network model based on the analogy with the immune system // J. Theor. Biol., 122. – 1986.– P. 33–67.
13. Hoffmann GW, Benson MW, Bree GM, Kinahan PE A teachable neural network based on an unorthodox neuron // Physica 22D, 1986.– P. 233–246.
14. Vertosick F.T, Kelly R.H Immune network theory: A role for parallel distributed processing? // Immunology, 66: 1989.– P. 1–7.
21. Vertosick FT, Kelly RH The immune system as a neural network: A multi-epitope approach // J. Theor. Biol. 150: 1991.– P. 225–237.
15. Rumelhart D.E., McClelland J.L. Parallel Distributed Processing. – Cambridge MIT Press, 1986.– 595 p.
16. De Castro L., Von Zuben The construction of a boolean competitive network using ideas from immunology // Neurocomputing, 50C: 2003.– P. 51–85.
17. De Castro L., Von Zuben F. An immunological approach to initialize feedforward neural network weights // Proc of ICANNGA'01, 2001.– P. 126–129.
18. Kirkpatrick S, Gelatt Jr CD, Vecchi MP Optimization by simulated annealing, Science 220(4598): 1987.– P. 671–680.
19. De Castro L., Von Zuben F. Automatic determination of radial basis function: an immunity-based approach // Int. J. Neural Systems , 11(6): 2001.– P. 523–535.

20. Forrest S., Javornik B, Smith R., Perelson A. Using genetic algorithms to explore pattern recognition in the immune system // *Evolut Comput* 1(3): 1993.– P. 191–211.
21. Hightower R., Forrest S., Perelson A. The evolution of emergent organization in immune system gene libraries / *Proc. of the Sixth ICGA*, Eshelman LJ (ed), Morgan Kaufmann, San Francisco, CA, 1995.– P. 344–350.
22. Potter M., de Jong K. The coevolution of antibodies for concept learning / *Proc. of the 5th ICPPSN*, 1998.– P. 530–539.
23. Hajela P., Yoo J. Immune network modelling in design optimization / *New Ideas in Optimization*. - London: McGraw Hill, 1999.– P. 203–215.
24. Hart E., Ross P. The evolution and analysis of a potential antibody library for use in job-shop scheduling / *Ibidem*.– P. 185–202.
25. Nikolaev N., Iba H., Slavov V. Inductive genetic programming with immune network dynamics // *Adv. Genetic Programming 3*.- MIT Press, 1999.– P. 355–376.
26. Krishna-Kumar K., Satyadas A., Neidhoefer J. An immune system framework for integrating computational intelligence paradigms with applications to adaptive control // *Computational Intelligence: A Dynamic System Perspective*.– IEEE Press, 1995.– P. 32–45.
27. Baldwin, Mark J. A New Factor in Evolution // *The American Naturalist*, Vol. **30**, No. 354 (Jun., 1896).– P. 441-445.
28. Lee D.-W., Jun H.-B., Sim K.-B. Artificial immune system for realization of cooperative strategies and group behavior in collective autonomous mobile robots / *Proc of AROB'99*, 2, 1999.– P. 232–235.
29. Jun J-H, Lee D-W, Sim K-B Realization of cooperative and swarm behavior in distributed autonomous robotic systems using artificial immune system / *Ibidem*.– P. 614–619.
30. De Castro L., Von Zuben F. aiNet: an artificial immune network for data analysis. – *Data Mining: A Heuristic Approach*. – Idea Group Publishing, USA, Chapter XII, 2001.– P. 231–259.
31. Lin C.-T., Lee G.C.S. *Neural Fuzzy Systems: A Neuro-Fuzzy Synergism to Intelligent Systems*. - Upper Saddle River, NY: Prentice Hall, 1997.
32. Голубин А.В. Гибридные генетические алгоритмы: истоки и перспективы // *Новости искусственного интеллекта*,—2006. — №1. – С.101-118.
33. Комарцова Л.Г. Исследование нейросетевых и гибридных методов и технологий в интеллектуальных системах поддержки принятия решений // *Дис. докт. техн. наук*, — Калуга: КФ МГТУ им. Н.Э.Баумана, 2003.
34. Шумский С.А. Байесова регуляризация обучения / *Сб. тр. 4й Всерос. гонф. «Нейроинформатика-2002»* - В 2 ч., вып. Л-1. - М.: Изд-во МИФИ, 2002.
35. Фефелов А.А., Бидюк П.И., Литвиненко В.И. Применение комбинированных искусственных иммунных систем при решении задач построения моделей динамических процессов // *Міжн. семінар з індуктивного моделювання. Збірник праць*. – Київ: МННЦІТС НАНУ, 2005.– С. 69-84.
36. Бардачев Ю.Н., Бидюк П.И., Фефелов А.А., Литвиненко В.И. Гибридный алгоритм клонального отбора // *Зб. наук. праць у 5 томах Міжн. наук. конф.*

„Інтелектуальні системи прийняття рішень та прикладні аспекти інформаційних технологій”, Євпаторія, 2005. – Том 3. – С.41-47.

37. Бідюк П.І., Баклан І.В., Баклан Я.І. та ін. Моделювання та прогнозування нелінійних динамічних процесів // Зб. наук. пр., Вид-во “ЕКМО”, 2004. – 120 с.

38. Баранов О.М., Литвиненко В.І., Носенко В.І. та ін. Застосування штучних імунних систем для рішення задач класифікації донних морських об’єктів // Зб. наук. праць Севаст. військ.-мор. ін-ту ім. Нахімова.- Вип. 2(8), 2005.- С.339-340.

39. Литвиненко В.И. Сравнительные экспериментальные исследования алгоритма модифицированного отрицательного отбора и клонального алгоритма отрицательного отбора для решения задач классификации // Вестник Херсонского национального технического университета, №4(33), 2008. - С.7-14.

40. Бідюк В.И., Фефелов А.А., Литвиненко В.И. Иммуносетевая модификация алгоритма отрицательного отбора для решения задачи обнаружения аномалии // Адаптивні системи автоматичного управління. Міжвідомчий науково-технічний збірник. – Дніпропетровськ: Системні технології.- 2007.- С.15–24.

41. Литвиненко В.И., Четырин С.П. Компенсация ошибок оператора в контуре управления следящей системы на основе синтезируемых вейвлет-нейронных сетей // Автоматика. Автоматизация. Электротехнические комплексы и системы, №2(20). – 2007. – С.112–123.

42. Литвиненко В.И. Синтез радиально-базисных сетей для решения задачи дистанционного определения концентрации хлорофилла // Там же. –№1(19). – 2007. – С.53–66.

43. Литвиненко В.І., Фефелов А.О., Дідик О.О. Методологія синтезу колективу радіально-базисних мереж для розв’язування задач класифікації за допомогою алгоритму клонального відбору // Наукові праці: науково-методичний журнал. – Т.109, Вип. 93. Комп’ютерні технології. – Миколаїв; Вид.-во ЧДУ ім. Петра Могили, 2009. – С.118-134.

44. Литвиненко В.И., Фефелов А.А., Дидык А.А. методология синтеза коллектива вейвлет-нейронных сетей для решения задач классификации с помощью алгоритма клонального отбора // Праці у двох томах міжнар. наук. конф. „Інтелектуальні системи прийняття рішень і проблеми обчислювального інтелекту”, Євпаторія 2009. - Том 2. - С.359-366.

45. Бардачев Ю.Н., Литвиненко В.И., Гринавцев О.В., Фефелов А.А. Синтез нечетких нейронных сетей с помощью иммунных алгоритмов для прогнозирования электрической нагрузки // Зб. наук. пр. “Моделювання та керування станом еколого-економічних систем регіону”. Вип. 3, 2006.– С.47-68.

46. Литвиненко В.И. Прогнозирование нестационарных временных рядов с помощью синтезируемых нечетких нейронных сетей // Автоматизация. Электротехнические комплексы и системы. - №1(21), 2008.- С.64–71.

47. Литвиненко В.І. Реалізація системи підтримки прийняття рішень на основі нечіткої оптимізації розподілу фінансів між альтернативними проектами за допомогою алгоритму клонального добору // Наукові праці: науково-методичний журнал.– Т.90, вип.77.– Миколаїв: вид-во МДГУ, 2007.- С.105-113.