

УДК 004.89



АДАПТИВНЫЕ НЕЧЕТКИЕ МОДЕЛИ ИДЕНТИФИКАЦИИ НЕЛИНЕЙНЫХ ОБЪЕКТОВ НА ОСНОВЕ ИСКУССТВЕННЫХ ИММУННЫХ СИСТЕМ

Н.М. Кораблев¹, И.В. Сорокина²

¹ХНУРЭ, г.Харьков, Украина, korablev@kture.kharkov.ua

²ХНУРЭ, г.Харьков, Украина, i.sorokina@kture.kharkov.ua

В данной работе рассмотрены вопросы адаптации нечетких моделей идентификации нелинейных объектов, представленных в виде системы нечеткого вывода и нечеткой нейронной сети, с использованием искусственных иммунных систем. Процесс адаптации состоит в настройке формы и параметров функций принадлежности, а также параметров и структуры (в случае системы нечеткого вывода) базы нечетких правил. Показана эффективность предложенных иммунных алгоритмов адаптации моделей нечеткого вывода на тестовых функциях.

ИСКУССТВЕННЫЕ ИММУННЫЕ СИСТЕМЫ, АДАПТИВНАЯ МОДЕЛЬ НЕЧЕТКОГО ВЫВОДА, АДАПТИВНАЯ НЕЧЕТКАЯ НЕЙРОННАЯ СЕТЬ, ФУНКЦИИ ПРИНАДЛЕЖНОСТИ, БАЗА НЕЧЕТКИХ ПРАВИЛ

Введение

Активное использование современных информационных технологий для создания математических основ интеллектуальных систем в последние годы позволило по-новому взглянуть на проблему обработки многомерных данных в условиях неполной и неточной информации. Одной из наиболее актуальных в этой сфере является задача идентификации нелинейных объектов. Классические методы многомерной статистики, используемые для решения такой задачи, основаны на определенных предположениях о структуре исходных данных и, как следствие, попытки их применения приводят к большим ошибкам при условии несоответствия обучающих наборов этим предположениям. Основные трудности при использовании классических систем нечеткого вывода для решения задачи идентификации нелинейных объектов связаны с априорным определением компонентов этих моделей (нечетких высказываний, функций принадлежности (ФП) для каждого значения лингвистических переменных, структуры базы нечетких правил и другое). При наличии набора неструктурированных данных определение этих компонентов представляет собой сложную проблему, требующую привлечения знаний экспертов в предметной области. Поскольку эти компоненты зачастую выбираются субъективно, они могут быть не вполне адекватны моделируемой системе или процессу. Специфика задачи идентификации нелинейных объектов приводит к необходимости устранения вышеуказанных недостатков.

Наиболее перспективным направлением при решении данной задачи является использование универсальных аппроксиматоров широкого класса многомерных нелинейных функций — адаптивных моделей нечеткого логического вывода и адаптивных нечетких нейронных сетей [1]. Параметры адаптивных моделей обоих типов настраиваются

путем их оптимизации в смысле некоторого критерия, формируемого по данным из обучающей выборки.

Решение подобной задачи оптимизации представляет собой трудную задачу по ряду причин. Во-первых, это большая размерность вектора параметров нечеткой модели. Во-вторых, большая размерность пространства поиска тесно связана с проблемой многоэкстремальности целевой функции. Кроме того, характер функции полностью зависит от данных обучающей выборки, которые меняются с каждым новым моделируемым процессом или объектом. В настоящее время накоплен большой арсенал средств для решения задач оптимизации, но поиск новых, более эффективных методов продолжается. Стандартными и хорошо изученными являются градиентные методы оптимизации [2]. Данная группа методов использует для поиска экстремума значение градиента функции. Недостатком этих методов является необходимость вычисления градиента функции, зависимость от начального приближения.

Широко распространена оптимизация на основе случайного поиска, когда градиент функции заменяется случайным вектором. Генетические алгоритмы как часть парадигмы эволюционных вычислений позволяют решать многие проблемы классических методов оптимизации. В [3] рассмотрено использование генетических алгоритмов в задачах оптимизации систем нечеткого вывода. Однако классические ГА и их разновидности не всегда эффективны при решении задачи мультимодальной оптимизации.

Развитие эволюционных вычислений с целью повышения эффективности алгоритмов обучения нечетких моделей ведется по пути создания новых методов, использующих возможности динамического изменения параметров алгоритмов оптимизации и различные варианты распараллеливания

процессов обработки нечеткой информации. Таким требованиям удовлетворяют искусственные иммунные системы (ИИС), которым присущи такие свойства как распознавание, разнообразие, обучение, память, распределенное обнаружение, саморегулирование, метадинамика, сетевая организация и другое [4]. В работе [5] рассмотрено применение ИИС в нечетких системах классификации, в частности для генерации базы нечетких правил.

Рассматривается также настройка адаптивных моделей нечеткого вывода, реализованных в виде системы нечеткого вывода и нечеткой нейронной сети на основе ИИС. Для оценки эффективности предложенных иммунных алгоритмов их работа проверяется на тестовых примерах. Проведенные эксперименты показывают, что предлагаемые иммунные алгоритмы способны выполнять адаптацию нечетких моделей идентификации нелинейных объектов.

1. Постановка задачи

Для адаптации нечеткой модели строится целевая функция:

$$\Phi(P) = \frac{1}{n} \sum_{j=1}^n [F(X_j, P) - y_j]^2 \Rightarrow \min_P, \quad (1)$$

минимизирующая среднеквадратическое отклонение между фактическими значениями выходной переменной y_j и полученной на основе нечеткого прогноза точечной оценкой $F(X_j, P)$. Вектор P представляет собой вектор параметров нечеткой модели и его состав определяется исходя из выбранного алгоритма обучения.

В качестве базовой модели нечеткого вывода используется модель Такаги-Сугено первого порядка с правилами вида:

P_i : ЕСЛИ x_i есть A_{i1} И ... И x_j есть A_{ij} И ... И x_m есть A_{im}
 ТО $y = k_{i1}x_1 + \dots + k_{ij}x_j + \dots + k_{im}x_m + k_{i0}, i = 1, \dots, n,$

где A_j – это нечеткие множества и соответствующие им ФП, построенные в пространстве входных $x_i, 1, \dots, m$ значений переменных; $k_{ij} (j = 0, \dots, m)$ – коэффициенты аргументов функции.

Используемые гауссовы ФП описываются выражением:

$$\mu(x) = \exp \left[- \left(\frac{x - c}{\sigma} \right)^2 \right], \quad (2)$$

где c – центр нечеткого множества; σ отвечает за крутизну функции.

Для адаптации нечетких моделей (системы нечеткого вывода, нечеткой нейронной сети) ставится задача разработки алгоритмов на основе искусственных иммунных систем с использованием принципа клонального отбора [6-7] и теории им-

мунной сети [8]. Для настройки нечетких моделей необходимо оптимизировать параметры ФП и нечетких правил по данным из обучающей выборки.

2. Адаптивные системы нечеткого вывода

2.1. Модель системы нечеткого вывода

Основой адаптивной системы нечеткого вывода является база знаний, представляющая собой совокупность информации о множестве лингвистических переменных в виде соответствующих ФП и о множестве правил нечеткого вывода [1]. База знаний формируется на основе информации из обучающей выборки.

Представим адаптивную систему нечеткого вывода в виде кортежа:

$$AFIS = \langle \{X_i, y_i\}, RB, DB, I, G(RB), L(DB), F \rangle,$$

где $\{X_i, y_i\}, i = \overline{1, n}$ обучающая выборка; RB – база правил; DB – база данных; I – механизм нечеткого логического вывода; $G(RB)$ – генерация и оптимизация базы правил; $L(DB)$ – генерация и оптимизация базы данных (параметров ФП); F – функция, оценивающая эффективность нечеткой модели.

Основная трудность использования данной системы заключается в необходимости структурной и параметрической адаптации (оптимизации) – поиске оптимального набора параметров термов лингвистических переменных и коэффициентов нечетких правил, и структуры множества правил логического вывода [9].

2.2. Иммунный алгоритм адаптации правил нечеткого вывода (структурная адаптация)

Алгоритм формирования нечеткой базы знаний представляет собой итерационную процедуру последовательной идентификации наблюдений из обучающей выборки с помощью искусственных иммунных систем.

Антигены представляют собой примеры обучающей выборки. Каждое антитело кодирует одно правило базы знаний. Количество антител в популяции (правил в базе знаний) соответствует количеству примеров в обучающей выборке. Правила кодируются вещественными числами, представляющими собой индекс нечетких множеств входных переменных и коэффициенты нечетких правил:

$$Ab = \langle IFS_1, IFS_2, \dots, IFS_n, k_0, k_1, \dots, k_n \rangle,$$

где $IFS_1, IFS_2, \dots, IFS_n$ – индексы нечетких множеств для n входных переменных; k_0, k_1, \dots, k_n – коэффициенты нечетких правил.

Аффинность антител популяции вычисляется по результатам нечеткого вывода в соответствии с (1). В результате работы иммунного алгоритма клонального отбора лучшие по популяции антитела формируют популяцию клеток памяти, которая представляет множество нечетких правил вида:

$$R_1: \text{IF } x_1 \text{ is } IFS_{11} \text{ ...AND... } x_n \text{ is } IFS_{1n} \text{ THEN} \\ y = k_{10} + k_{11}x_1 + \dots + k_{1n}x_n;$$

$$R_2: \text{IF } x_1 \text{ is } IFS_{21} \text{ ...AND... } x_n \text{ is } IFS_{2n} \text{ THEN} \\ y = k_{20} + k_{21}x_1 + \dots + k_{2n}x_n;$$

...

$$Rq: \text{IF } x_1 \text{ is } IFS_{q1} \text{ ...AND... } x_n \text{ is } IFS_{qn} \text{ THEN} \\ y = k_{q0} + k_{q1}x_1 + \dots + k_{qn}x_n.$$

Полное множество правил в АСНВ для реальных задач может быть достаточно велико. Если для описания наблюдения используются n переменных, каждая из которых имеет m термов, то верхняя оценка числа правил составляет m^n .

Для сокращения мощности множества правил необходимо в этом множестве выделить некоторое минимальное подмножество наблюдений, исключив избыточные и противоречивые правила. Данную задачу в предлагаемом иммунном алгоритме выполняет оператор супрессии, который обеспечивает сжатие популяции путем связывания антител в зависимости от значения их аффинности относительно других антител популяции. Антитела с минимальной аффинностью удаляются из популяции в соответствии с установленным порогом сжатия сети, что приводит к уменьшению числа правил в базе знаний адаптивной системы нечеткого вывода.

Алгоритм структурной адаптации можно представить в виде следующей последовательности шагов:

1. Генерация начальной популяции антител Ab .
 2. Цикл для каждого антигена Ag_i :
 - 2.1. В систему нечеткого вывода подставляются параметры ФП и правило вывода с коэффициентами, взятыми из антитела, вычисляется аффинность антител Ab к антигену Ag_i .
 - 2.2. Выбор n лучших антител для клонирования N раз.
 - 2.3. Клонирование, формирование популяции клонов C .
 - 2.4. Мутация популяции C , формирование популяции C^* .
 - 2.5. Вычисления аффинности популяции C^* к антигену Ag_i .
 - 2.6. Редактирование популяции антител Ab и заполнение популяции клеток памяти M .
 - 2.7. Супрессия антител внутри популяции Ab .
 - 2.8. Замена d худших антител новыми антителами в популяции антител Ab .
 3. Проверка критерия останова. Если не достигнут — переход к шагу 2, в противном случае — переход к шагу 4.
 4. Конец.
- Результат — популяция клеток памяти M , которая представляет собой набор правил вывода с вычисленными коэффициентами нечетких правил.

2.3. Иммунный алгоритм адаптации ФП (параметрическая адаптация)

Параметрическая адаптация включает в себя процедуру оптимизации первичных значений параметров ФП. Принцип действия процедуры адаптации заключается в изменении параметров термов всех лингвистических переменных. Целью параметрической адаптации является поиск такой модели, с таким набором параметров, для которой качество идентификации будет наилучшим.

В задаче параметрической адаптации нечетких моделей в роли антигена выступает обучающая выборка; в роли антител — параметры ФП вида (2) для входных переменных. Антитело представляет собой строку фиксированной длины:

$$Ab = \langle c_{11}, \dots, c_{1m}, \dots, c_{n1}, \dots, c_{nm}, \\ \sigma_{11}, \dots, \sigma_{1m}, \dots, \sigma_{n1}, \dots, \sigma_{nm} \rangle,$$

где c_{ij}, σ_{ij} , $i = \overline{1, n}$; $j = \overline{1, m}$ — параметры гауссовых ФП вида (2) для n входных переменных, каждая из которых имеет m термов.

Каждая из ФП задана на универсуме $X = [x_{\min}, x_{\max}]$, в качестве которого выбран замкнутый интервал действительных чисел. Исходный вектор параметров ФП генерируется случайным образом. Предлагается вещественное кодирование антител, что позволяет повысить точность найденных решений.

На вход адаптивной системы нечеткого вывода подается множество значений входных переменных из обучающей выборки. На основании параметров ФП, взятых из антител, и сгенерированной на этапе структурной адаптации базы правил выполняется нечеткий вывод. По результатам нечеткого вывода вычисляется аффинность каждого антитела со всеми антигенами популяции в соответствии с (1). Поиск минимума функции (1) ведется в допустимом множестве изменения входных переменных x_i : $x_i^{\min} \leq x_i \leq x_i^{\max}$, $i = \overline{1, n}$. Антитела с лучшей аффинностью подвергаются клонированию и мутации. Антитела с худшим значением аффинности удаляются из популяции и заменяются новыми. Работа иммунного алгоритма прекращается при достижении критерия останова. База данных адаптивной нечеткой системы формируется по лучшему антителу популяции.

Алгоритм параметрической адаптации можно представить в виде следующей последовательности шагов:

1. Генерация начальной популяции антител Ab .
2. Цикл для каждого антитела Ab_i :
 - 2.1 В систему нечеткого вывода с базой нечетких правил, полученных на этапе структурной адаптации, подставляются параметры ФП из антитела Ab_i , вычисляется аффинность антитела к популяции антигенов Ag .

2.2. Выбор n лучших антител для клонирования N раз.

2.3. Клонирование, формирование популяции клонов C .

2.4. Мутация популяции C , формирование популяции C^* .

2.5. Вычисление аффинности популяции C^* к популяции антигенов Ag .

2.6. Редактирование популяции антител.

2.7. Замена d худших антител новыми антителами в популяции антител Ab .

3. Проверка критерия останова. Если не достигнут – переход к шагу 2, в противном случае – переход к шагу 4.

4. Конец.

Результат – антитело с лучшей аффинностью, содержащее параметры ФП.

2.4. Взаимодействие алгоритмов структурной и параметрической адаптации

Обобщенный алгоритм обучения адаптивной модели нечеткого вывода для n входных переменных x_1, x_2, \dots, x_n и одной выходной переменной y представляет собой итерационную процедуру, в которой организовано взаимодействие процедур параметрической и структурной адаптации.

На подготовительном этапе для каждого идентифицируемого объекта формируется обучающая выборка вида: $(x_1^{(k)}, x_2^{(k)}, \dots, x_n^{(k)}, y^{(k)})$, $k = \overline{1, K}$, где $x_1^{(k)}, x_2^{(k)}, \dots, x_n^{(k)}, y^{(k)}$ – значения входных переменных x_1, x_2, \dots, x_n и выходной переменной y в k -ом примере; K – общее количество примеров в обучающей выборке.

На основании известных минимальных и максимальных значений каждой входной переменной область определения этих переменных разбивается на отрезки, на каждом из которых задается гауссова ФП.

Далее на этапе структурной адаптации формируется N наборов нечетких правил, в каждом поколении иммунного алгоритма происходит модификация популяции в соответствии с выбранной схемой применения иммунных операторов, вычисление приспособленности каждого антитела, ранжирование антител по степени аффинности в популяции, а также формирование базы правил вывода, на основе которой выполняется параметрическая адаптация. Иммунный алгоритм параметрической адаптации итерационно повторяется заданное число раз. В конце из полученной популяции выбирается наиболее приспособленное антитело, которое является результатом адаптации системы нечеткого вывода.

3. Адаптивные нечеткие нейронные сети

3.1. Архитектура нечетких нейронных сетей

Модели нечеткого вывода могут быть реализованы в виде нечетких сетей, по структуре идентичных многослойным нейронным сетям с прямым

распространением сигнала, элементы каждого слоя которой реализуют отдельный этап нечеткого вывода в нечеткой модели [1]. В настоящее время наиболее распространенной архитектурой является архитектура ANFIS [10].

Используемый класс нечетких нейронных сетей является функционально эквивалентным системе нечеткого вывода. Для устранения недостатков классических систем нечеткого вывода нечеткие нейронные сети создаются адаптивными, с коррекцией параметров нечетких правил и ФП.

Адаптивная нечеткая нейронная сеть с двумя входными переменными, каждая из которых представляется двумя ФП, и четырьмя нечеткими правилами вывода представлена на рис. 1.




Рис. 1. Архитектура нечеткой нейронной сети

Выходы нейронов первого слоя ($\mu_{A_i}(x_1)$ и $\mu_{B_i}(x_2)$, $i = 1, 2$) представляют собой значения гауссовых ФП, вычисленных в соответствии с (2). Нейроны второго слоя выполняют умножение входных сигналов и представляют вес правил: $w_i = \mu_{A_i}(x_1) \times \mu_{B_i}(x_2)$, $i = \overline{1, 4}$. В третьем слое i -й нейрон вычисляет отношение веса i -го правила к сумме весов всех правил: $\bar{w}_i = \frac{w_i}{\sum w_i}$, $i = \overline{1, 4}$. Функция активации нейронов четвертого слоя описывается как $\bar{w}_i f_i = p_i x_1 + q_i x_2 + r_i$, $i = \overline{1, 4}$, где $\{p_i, q_i, r_i\}$ – параметры i -го правила вывода Такаги-Сугено первого порядка. Единственный нейрон пятого слоя вычисляет общий выход как сумму входных сигналов: $F = \sum \bar{w}_i f_i$, $i = \overline{1, 4}$ [10].

Нейроны, обозначенные квадратами, являются адаптивными с настройкой параметров ФП в слое 1 (c и σ для гауссовой ФП (2)) и параметров нечетких правил в слое 4 ($\{p_i, q_i, r_i\}$).

3.2. Иммунный алгоритм адаптации нечетких нейронных сетей

В задаче обучения АННС в качестве антигена выступают примеры обучающей выборки. Каждое антитело кодирует параметры правил нечеткого вывода и ФП входных переменных:

$$Ab = \langle c_{11}, \dots, c_{1m}, \dots, c_{n1}, \dots, c_{nm}; \sigma_{11}, \dots, \sigma_{1m}, \dots, \sigma_{n1}, \dots, \sigma_{nm}; k_{10}, \dots, k_{1n}, \dots, k_{q0}, \dots, k_{qn} \rangle,$$

где c_{ij}, σ_{ij} , $i = \overline{1, n}$; $j = \overline{1, m}$ – параметры гауссовых ФП вида (2) для n входных переменных, каждая из

которых имеет m термов; k_{i_0}, \dots, k_{i_m} , $i = \overline{1, q}$; – коэффициенты q нечетких правил.

Такое представление параметров нечеткой нейронной сети в антителе позволяет одновременно выполнять настройку как параметров нечетких правил, так и параметров ФП. Популяция антител генерируется случайным образом, используется вещественное кодирование.

В АННС подставляются параметры, закодированные в антителе, и для значений входных переменных, закодированных в антигене, рассчитываются значения выходной переменной. Реализуется режим пакетного обучения, при котором значения параметров изменяются только после предъявления сети всех обучающих образов. Аффинность антитела определяется как среднеквадратическое отклонение реального выхода АННС от желаемого для всех антигенов в соответствии с (1). Результатом работы алгоритма будет антитело с минимальной по популяции аффинностью.

Алгоритм обучения нечеткой нейронной сети можно представить в виде следующей последовательности шагов:

1. Генерация начальной популяции антител Ab .
 2. Цикл для каждого антитела Ab_i :
 - 2.1 Параметры из антитела Ab_i подставляются в нечеткую нейронную сеть, вычисляется аффинность антитела к популяции антигенов Ag .
 - 2.2. Выбор n лучших антител для клонирования N раз.
 - 2.3. Клонирование, формирование популяции клонов C .
 - 2.4. Мутация популяции C , формирование популяции C^* .
 - 2.5. Вычисление аффинности популяции C^* к популяции антигенов Ag .
 - 2.6. Редактирование популяции антител.
 - 2.7. Замена d худших антител новыми антителами в популяции антител Ab .
 3. Проверка критерия останова. Если не достигнут – переход к шагу 2, в противном случае – переход к шагу 4.
 4. Конец.
- Результат – антитело с лучшей аффинностью, содержащее параметры правил нечеткого вывода и ФП входных переменных.

4. Экспериментальные исследования

4.1. Параметры иммунных алгоритмов

Параметры иммунных алгоритмов структурной и параметрической адаптации правил нечеткого вывода и обучения нечеткой нейронной сети определены предварительными экспериментами и приведены в табл. 1.

Размер популяции антител для структурной адаптации системы нечеткого вывода соответствует количеству примеров в обучающей выборке.

Количество антител для клонирования n влияет на скорость сходимости алгоритма. С увеличением данного параметра скорость сходимости алгоритма увеличивается, однако увеличивается и вычислительная сложность алгоритма.

Используется оператор пропорционального клонирования [5], который клонирует n антител пропорционально их аффинности:

$$N_c(Ab_i) = \begin{cases} \text{Min_}N_c, & \text{if } \text{Aff}(Ab_i) < \text{Max_Aff} * 0.3 \\ \text{MaxO } N_c, & \text{if } \text{Aff}(Ab_i) < \text{Max_Aff} * 0.7 \\ \text{Aff}(Ab_i) / \beta, & \text{в остальных случаях,} \end{cases} \quad (3)$$

где $\text{Min_}N_c$ и $\text{Max_}N_c$ – минимальное и максимальное количество клонов соответственно; $\text{Aff}(Ab_i)$ – значение аффинности антитела Ab_i ; Max_Aff – лучшее значение аффинности, полученное в текущем поколении; β – параметр, который может изменяться в процессе выполнения поколений.

Вероятность мутации влияет на скорость сходимости алгоритма. Большая вероятность мутации поддерживает разнообразие антител в иммунной системе на достаточно высоком уровне, делая случайные скачки по всей области поиска, и позволяет находить глобальный экстремум, не застревая в точках локального оптимума, однако большинство изменений могут привести к нефункциональным антителам с плохой аффинностью. Небольшая вероятность мутации позволяет иммунной системе исследовать локальную область вокруг антитела, делая небольшие шаги в поиске антител с лучшей аффинностью, ведущих к оптимальному значению.

Таблица 1

Параметры иммунного алгоритма

Параметр	Адаптивная система нечеткого вывода		Адаптивная нечеткая нейронная сеть
	Структурная адаптация	Параметрическая адаптация	
Размер популяции	121	15	15
Количество антител для клонирования	30	7	7
Минимальное количество клонов	5	5	5
Максимальное количество клонов	7	7	7
Максимальная вероятность мутации	0,3	0,3	0,3
Количество антител для редактирования	10	1	1
Коэффициент супрессии (порог сжатия сети)	0,001	-	-

нию, но скорость сходимости алгоритма уменьшится. Следовательно, механизм мутации необходимо регулировать в процессе работы иммунного алгоритма и для антител с улучшенной в результате мутации аффинностью необходимо уменьшать вероятность мутации в последующих поколениях работы иммунного алгоритма, чтобы не потерять полученные преимущества. Используется оператор обратно-пропорциональной мутации [5], согласно которому вероятность мутации обратно пропорциональна аффинности антитела:

$$p_m(Ab_i) = c * \frac{Aff(Ab_i) - Max_Aff}{Min_Aff - Max_Aff}, \quad (4)$$

где c – максимальная вероятность мутации i -го клона; $Aff(Ab_i)$ – значение аффинности антитела Ab_i ; Max_Aff – лучшее значение аффинности, полученное в текущем поколении; Min_Aff – худшее значение аффинности, полученное в текущем поколении;

При редактировании популяции антитела с худшей по популяции аффинностью заменяются случайно сгенерированными новыми антителами, что обеспечивает поддержку разнообразия в популяции.

Оператор супрессии удаляет похожие антитела, для того чтобы избежать избыточности и поддерживать разнообразие в популяции. Согласно теории иммунной сети оператор супрессии обеспечивает сжатие популяции путем связывания антител в зависимости от значения их аффинности относительно других антител популяции. Антитела с минимальной аффинностью могут быть удалены из популяции в соответствии с установленным порогом сжатия сети.

Критерием останова является достижение заданного количества поколений работы алгоритма.

4.2. Результаты экспериментов

Для оценки эффективности предложенных алгоритмов были проведены эксперименты с использованием тестовых функций, приведенных в табл. 2.

Отметим, что тестовая функция 1 является унимодальной, а тестовая функция 2 – мультимодальной. Обучающая выборка для тестовых функций сформирована в соответствии с диапазоном входных переменных и составляет 121 пример. По данным из обучающей выборки каждая тестовая функция восстанавливается с помощью адаптивной системы нечеткого вывода и адаптивной

нечеткой нейронной сети. Начальные значения параметров ФП устанавливаются таким образом, чтобы ФП были равномерно распределены по области определения функций. Эксперименты проводились с использованием разного количества лингвистических термов для каждой из двух входных переменных.

В табл. 3 приведены данные по среднеквадратическому отклонению по результатам 10 запусков алгоритма для тестовых функций 1 и 2.

Таблица 3

Результаты экспериментов

Количество лингвистических термов	Тестовая функция 1	Тестовая функция 2
Система нечеткого вывода		
3	0,2	0,69
5	0,051	0,082
7	0,012	0,05
Нечеткая нейронная сеть		
3	0,27	0,501
5	0,035	0,057
7	0,024	0,047

Из табл. 3 видно, что использование большего количества ФП для каждой переменной позволяет повысить точность восстановления функции.

Восстановленные поверхности и полученные ФП представлены на рис. 2 и 3. Алгоритм адаптации нечеткой нейронной сети позволяет достичь лучших результатов за счет одновременной настройки как параметров нечетких правил, так и параметров ФП. Однако при адаптации нечеткой нейронной сети структура базы правил задается строго фиксированной, так как при изменении количества правил необходимо изменять структуру нейронной сети.

При адаптации системы нечеткого вывода изменяются не только коэффициенты нечетких правил, но и количество правил нечеткого вывода за счет выполнения супрессии. Так, в адаптивной нечеткой нейронной сети количество правил для двух входных переменных с пятью ФП составляет 25 для обеих тестовых функций 1-2, в то время как для системы нечеткого вывода количество правил сокращается до 19 для тестовой функции 1 и – до 23 для тестовой функции 2.

Следует отметить, что процесс адаптации не-

Таблица 2

Тестовые функции	
	Тестовая функция
1	$F_1(x_1, x_2) = x_1^2 + x_2^2$
2	$F_2(x_1, x_2) = 3(1 - x_1)^2 \exp(-x_1^2 - (x_2 + 1)^2) - 10\left(\frac{x_1}{5} - x_1^3 - x_2^5\right) \exp(-x_1^2 - x_2^2) - \frac{1}{3} \exp(-(x_1 + 1)^2 - x_2^2)$

четкой нейронной сети требует значительных временных затрат на вычисление, что связано с длиной строки оптимизируемых параметров, представленных в антителе. Так, в случае, когда для лингвистической оценки входных переменных используется 3 терма, длина строки антитела составляет 39 параметров, в случае 5 термов – 95 параметров, в случае 7 термов – 175 параметров.

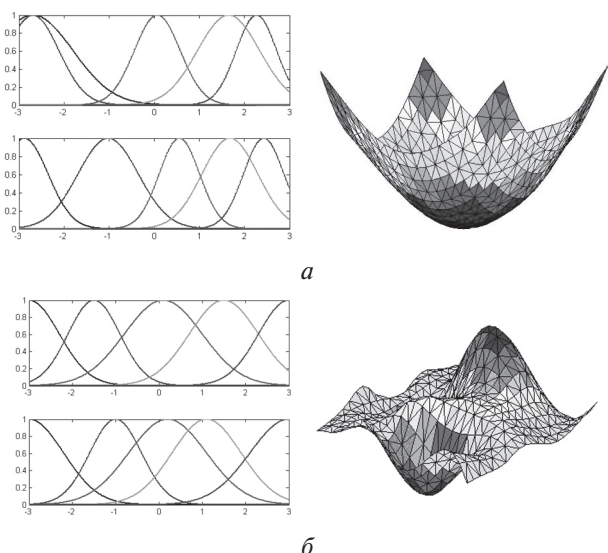


Рис. 2. Адаптивная система нечеткого вывода: настроенные ФП и восстановленная поверхность для тестовой функции 1 (а) и тестовой функции 2 (б)




Рис. 3. Адаптивная нечеткая нейронная сеть: настроенные ФП и восстановленная поверхность для тестовой функции 1 (а) и тестовой функции 2 (б)

Выводы

В работе рассмотрено решение задачи идентификации нелинейных объектов на основе использования искусственных иммунных систем. Предложены адаптивные нечеткие модели идентификации объектов, реализованные в виде системы нечеткого вывода и нечеткой нейронной сети с иммунной настройкой. В адаптивной системе нечеткого вывода реализованы процедуры структурной и параметрической оптимизации. В адаптивной нечеткой нейронной сети реализована одновременная параметрическая адаптация ФП и правил нечеткого вывода. Проведенные экспериментальные исследования на двух тестовых функциях показали эффективность применения искусственных иммунных систем для обучения адаптивных систем нечеткого вывода и нечетких нейронных сетей, описывающих нелинейные функции.

Список литературы: 1. Борисов В.В., Круглов В.В., Федюлов Ф.С. Нечеткие модели и сети. – М: Горячая линия. – Телеком, 2007. – 284 с. 2. Петров Е.Г., Новожилова М.В., Гребенник И.В. Методи і засоби прийняття рішень у соціально-економічних системах: Навч. посібн. / За ред. Е.Г. Петрова. – К., Техніка, 2004. – 256с. 3. Castro, P.A.D.; Camargo, H.A. «Learning and Optimization of Fuzzy Rule Base by means of Self Adaptive Genetic Algorithms», Proceedings of IEEE International Conference on Fuzzy Systems, Vol. 2, pp. 1037-1042. 4. Timmis J.I., Knight T., De Castro L.N., Hart E. An Overview of Artificial Immune Systems // Computation in Cells and Tissues: Perspectives and Tools for Thought, Natural Computation Series, Springer, 2004 – p. 51-86. 5. Castro, P.A.D.; Coelho, G. P.; Caetano, M. F.; Von Zuben, F. J. «Designing Ensembles of Fuzzy Classification Systems: An Immune-Inspired Approach», Proceedings of the 4th International Conference on Artificial Immune Systems (ICARIS), Lecture Notes in Computer Science, Springer-Verlag, Berlin, vol. 3627, pp. 469-482, 2005. 6. De Castro, L., Von Zuben, F.J.: Learning and optimization using the clonal selection principle. IEEE Transactions on Evolutionary Computation, Special Issue on Artificial Immune Systems 6. 239-251, 2002. 7. De Castro L. N., Von Zuben F. J. The Clonal Selection Algorithm with Engineering Applications // In Proceedings of GECCO'00, Workshop on Artificial Immune Systems and Their Applications, 2000. – p. 36-37. 8. L.N. de Castro and F.J. Von Zuben, «aiNet: an artificial immune network for data analysis,» in Data Mining: A Heuristic Approach, Chapter XII, H.A. Abbass, R.A. Sarker, and C.S. Newton, Eds. USA: Idea Group Publishing, 2001, pp.231-259. 9. Korablyov M.M., Ovcharenko I.V. Adaptation of fuzzy inference models using artificial immune systems // Advanced Computer Systems and Networks: Design and Application: Proceedings of the 3-rd International Conference ACSN-2007, Lviv. P. 89-91. 10. Jang J.-S. R. ANFIS: Adaptive-Network-Based Fuzzy Inference System // IEEE Trans. Systems & Cybernetics. - 1993. - Vol. 23. - P. 665 - 685. -1991.

Поступила в редколлегию 8.10.2008

УДК 004.89

Адаптивні нечіткі моделі ідентифікації нелінійних об'єктів на основі штучних імунних систем / М.М. Корабльов, І.В.Сорокіна // Біоніка інтелекту: наук.-техн. журнал. – 2008. – № 2 (69). – С. 125-131.

В роботі розглянуто задачу адаптації нечітких моделей ідентифікації нелінійних об'єктів за допомогою штучних імунних систем. Нечіткі моделі представлені у вигляді системи нечіткого виводу та нечіткої нейронної мережі. Процес адаптації полягає в оптимізації форми та параметрів функцій належності та параметрів і структури бази нечітких правил. Показано ефективність запропонованих імунних алгоритмів адаптації моделей нечіткого виводу.

Таб. 3. Іл.: 3. Бібліогр.: 10 найм.

UDK 004.89

Adaptive fuzzy models of nonlinear objects identification based on artificial immune systems / N.M. Korablev, I.V. Sorokina // Bionics of Intelligence: Sci. Mag. – 2008. – № 2 (69). – P. 125-131.

The given work considers the problem of adaptation of fuzzy models of nonlinear objects identification using artificial immune systems. Fuzzy models are represented in the form of fuzzy inference systems and fuzzy neural networks. The process of adaptation consists in adjustment of form and parameters of membership functions and parameters and structure of fuzzy rule base. The efficiency of proposed immune algorithms of fuzzy models adaptation is shown.

Tab. 3. Fig.: 3. Ref.: 10 items.