

## АДАПТИВНЫЕ СИСТЕМЫ НЕЧЕТКОГО ВЫВОДА С ИММУННОЙ НАСТРОЙКОЙ

### Введение

В настоящее время наблюдается повышенный научный и практический интерес к методам интеллектуальной обработки информации в условиях нечеткости и неопределенности, ограниченности временных, материальных и трудовых ресурсов. Если использование искусственных нейронных сетей, эволюционных вычислений и нечеткой логики для этих целей достаточно проработано [1], то искусственные иммунные системы (ИИС) – это новая парадигма мягких вычислений, которая может интегрироваться с другими методами [2,3].

Несмотря на достоинства нечетких систем, они имеют недостатки, которые обусловлены необходимостью привлечения экспертов. Поэтому в настоящее время используются адаптивные системы нечеткого вывода (АСНВ), в которых параметры нечетких моделей подбираются в процессе обучения [4]. Основой АСНВ является база знаний, которая формируется на основе информации из обучающей выборки и представляет собой совокупность информации о множестве лингвистических переменных в виде соответствующих функций принадлежности (ФП) и о множестве правил нечеткого вывода.

Процесс построения АСНВ состоит из двух этапов: структурной адаптации и параметрической адаптации [4]. Структурная адаптация подразумевает генерацию базы нечетких правил вывода. На этапе параметрической адаптации производится настройка форм и параметров ФП нечеткой модели. Процесс построения АСНВ сводится к решению некоторого конечного множества оптимизационных задач, при этом вид оптимизационной функции зависит от данных обучающей выборки. Нахождение глобального экстремума такой функции традиционными методами оптимизации является сложной, а часто не решаемой задачей. Для этих целей могут использоваться эволюционные вычисления, случайный поиск, искусственные

иммунные системы и др. [5,6]. Поэтому разработка новых методов структурной и параметрической адаптации АСНВ с помощью ИИС является актуальной.

### 1. Постановка задачи

Представим АСНВ в виде кортежа:

$$AFIS = \langle \{X_i, y_i\}, RB, DB, I, G(RB), L(DB), F \rangle, \quad (1)$$

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

В качестве базовой структуры АСНВ взята модель Такаги-Сугено первого порядка [4]:

$$\text{ЕСЛИ } x_1 \text{ это } A_1 \dots \text{И... } x_m \text{ это } A_m \text{ ТО } y = p_0 + p_1 x_1 + \dots + p_m x_m; \quad (2)$$

где  $A_i$  и  $B$  – это нечеткие переменные и соответствующие им ФП  $\mu_A(x)$ ,  $\mu_B(y)$ , построенные в пространстве входных и выходных значений переменных. В работе используются гауссовы ФП вида

$$\mu(x) = \exp \left[ - \left( \frac{x - c}{\sigma} \right)^2 \right], \quad (3)$$

где  $c$  – центр нечеткого множества,  $\sigma$  отвечает за крутизну функции.

Для обучения нечеткой модели выбрана целевая функция:

$$\Phi(P) = \frac{1}{n} \sum_{j=1}^n [F(X_j, P) - y_j]^2 \Rightarrow \min_P \quad (4),$$

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. Необходимо произвести поиск минимума функции (4) в допустимом множестве изменения входных переменных  $x_i$ :  $x_i^{\min} \leq x_i \leq x_i^{\max}$ ,  $i = \overline{1, m}$ .

Минимизация (4) относится к классу безусловных задач глобальной оптимизации, решение которой представляет собой

трудную задачу. Развитие эволюционных вычислений ведется по пути создания новых методов, использующих возможности динамического изменения параметров алгоритмов оптимизации и различные варианты распараллеливания процессов обработки нечеткой информации. Таким требованиям удовлетворяют ИИС, которым присущи такие свойства как распознавание, самообучение, параллелизм, память, распределенное обнаружение, сетевая организация и др. [2].

## 2. Адаптация правил нечеткого вывода

Полное множество правил нечеткого вывода в АСНВ может быть достаточно велико. Для его сокращения необходимо выделить некоторое минимальное подмножество наблюдений, доминирующих над остальными правилами. Алгоритм формирования базы нечеткой базы знаний представляет собой итерационную процедуру последовательной идентификации наблюдений из обучающей выборки с помощью ИИС. Антигены представляют собой примеры обучающей выборки. Каждое антитело кодирует одно правило базы знаний. 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.

По результатам нечеткого вывода вычисляется аффинность каждого антитела популяции в соответствии с (4). В результате работы иммунного алгоритма лучшие по популяции антитела формируют популяцию клеток памяти, которая представляет собой базу правил. Для исключения избыточных и противоречивых правил выполняется супрессия популяции антител на основе теории иммунной сети, что приводит к существенному уменьшению правил в базе знаний. Критерием останова является достижение заданного порога аффинности, либо заданное количество поколений работы алгоритма. Результатом работы алгоритма является множество нечетких правил вида:

$$\begin{aligned}
R1: & \text{ IF } x_1 \text{ is } IFS_{11} \text{ ...AND... } x_n \text{ is } IFS_{1n} \text{ THEN } y = k_{10} + k_{11}x_1 + \dots + k_{1n}x_n; \\
R2: & \text{ IF } x_1 \text{ is } IFS_{21} \text{ ...AND... } x_n \text{ is } IFS_{2n} \text{ THEN } y = k_{20} + k_{21}x_1 + \dots + k_{2n}x_n; \\
& \dots \\
Rq: & \text{ IF } x_1 \text{ is } IFS_{q1} \text{ ...AND... } x_n \text{ is } IFS_{qn} \text{ THEN } y = k_{q0} + k_{q1}x_1 + \dots + k_{qn}x_n.
\end{aligned} \tag{5}$$

### 3. Адаптация функций принадлежности

Целью параметрической адаптации является поиск такой модели, с таким набором параметров, для которой качество будет наилучшим. В задаче параметрической адаптации нечетких моделей в роли антигена выступает обучающая выборка; в роли антител – параметры ФП вида (3) для входных переменных. Антитело представляет собой строку фиксированной длины

$$Ab = \langle c_{11}, c_{12}, \dots, c_{1m}, \dots, c_{n1}, c_{n2}, c_{nm}, \sigma_{11}, \sigma_{12}, \dots, \sigma_{1m}, \dots, \sigma_{n1}, \sigma_{n2}, \sigma_{nm} \rangle,$$

где  $c_{ij}, \sigma_{ij}$ ,  $i = \overline{1, n}$ ;  $j = \overline{1, m}$  – параметры гауссовых ФП вида (3) для  $n$  входных переменных, каждая из которых имеет  $m$  термов.

Исходный вектор параметров ФП генерируется случайным образом. На вход АСНВ 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 (4). 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.

### 4. Взаимодействие алгоритмов структурной и параметрической адаптации

Обобщенный алгоритм обучения АСНВ 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 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 которых задаются гауссовы ФП.

На этапе структурной адаптации формируется  $N$  наборов нечетких правил, в каждом поколении иммунного алгоритма происходит модификация популяции, вычисление приспособленности каждого антитела, ранжирование антител по степени аффинности в популяции, а также формирование базы правил, 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.

### 5. Экспериментальные исследования

Исследования проводились с целью восстановления следующих тестовых функций (ТФ):

$$F_1(x_1, x_2) = x_1^2 + x_2^2; \quad (6)$$

$$F_2(x_1, x_2) = 3(1 - x_1)^2 \exp(-x_1^2 - (x_2 + 1)^2) - 10 \left( \frac{x_1}{5} - x_1^3 - x_2^5 \right) \exp(-x_1^2 - x_2^2) - \frac{1}{3} \exp(-(x_1 + 1)^2 - x_2^2). \quad (7)$$

Отметим, что ТФ (6) является унимодальной, а ТФ (7) – мультимодальной. Обучающая выборка, состоящая из 441 примера, получена на интервале значений входных переменных  $[-1; 1]$  для ТФ (6) и  $[-3; 3]$  для ТФ (7). Были выбраны следующие параметры иммунного алгоритма: вероятность мутации – 0,3; максимальное количество поколений – 15 000. Эксперименты проводились с использованием разного количества ФП для каждой из двух входных переменных. В таблице 1 приведены данные по среднеквадратическому отклонению по каждому из экспериментов для ТФ (6) и (7).

Таблица 1

Результаты экспериментов		
Количество ФП	Тестовая функция (6)	Тестовая функция (7)
3	0,02	-
5	0,006	0,697
7	0,0012	0,68

Из таблицы видно, что использование большего количества функций принадлежности для каждой переменной позволяет повысить точность восстановления функции.

Настроенные ФП и восстановленные поверхности ТФ (6) и (7) при использовании пяти ФП представлены соответственно на рисунках 1 и 2.



Рисунок 1 - ФП и восстановленная поверхность ТФ (6)



Рисунок 2 - ФП и восстановленная поверхность ТФ (7)

Отметим, что при адаптации системы нечеткого вывода изменяются не только коэффициенты нечетких правил, но и количество правил нечеткого вывода за счет выполнения супрессии. При использовании пяти ФП для двух переменных максимальное количество правил вывода равно 25. Используя структурную оптимизацию для ТФ (6) и (7) было получено соответственно 19 и 23 правил вывода. Кроме того, процесс адаптации требует значительных временных затрат на выполнение 15 000 поколений. Поэтому с целью сокращения временных затрат в настоящее время проводятся исследования по распараллеливанию иммунного алгоритма обучения АСНВ на основе использования технологий MPI и OpenMP.

### Выводы

В работе рассмотрено решение актуальной задачи повышения качества обучения АСНВ на основе использования ИИС для настройки как параметров ФП, так и числа правил вывода. Проведенные экспериментальные исследования показали высокую эффективность применения ИИС для обучения АСНВ, которые описывают как унимодальные, так и мультимодальные нелинейные

функции. Осуществлена программная реализация предложенного иммунного алгоритма. Предложенный метод обучения АСНВ требует дальнейших исследований по распараллеливанию вычислительных процессов основе использования технологий MPI и OpenMP.

#### ЛИТЕРАТУРА

1. Андрейчиков А.В., Андрейчикова О.Н. Интеллектуальные информационные системы. – М.: Финансы и статистика, 2004. – 424 с.
2. Искусственные иммунные системы и их применение / Под ред. Д. Дасгупты. Пер. с англ. под ред. А.А. Романюхи. – М.: ФИЗМАТЛИТ, 2006. – 344 с.
3. De Castro L. N., Timmis, J. I. Artificial Immune Systems: A Novel Paradigm to Pattern Recognition // In Artificial Neural Networks in Pattern Recognition, SOCO-2002, University of Paisley, UK, 2002. – p. 67-84.
4. Борисов В.В., Круглов В.В., Федулов А.С. Нечеткие модели и сети. – М.: Горячая линия–Телеком, 2007. – 284 с.
5. L. N. D. Castro and F. J. V. Zuben, “Learning and optimization using the clonal selection principle,” IEEE Trans. Evolut. Comput., vol. 6, no. 3, 2002 – P. 239–251.
6. Кораблев Н.М., Овчаренко И.В. Сравнительный анализ иммунного и генетического алгоритмов в задачах оптимизации нелинейных функций // Бионика интеллекта, 2007. – № 2 (67). – С. 56-60.
7. 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.

Получено 11.03.2008 г.