

УДК 004.93



КЛАСТЕРНЫЙ АНАЛИЗ С ИСПОЛЬЗОВАНИЕМ ГИБРИДНОЙ МОДЕЛИ НА ОСНОВЕ ИСКУССТВЕННОЙ ИММУННОЙ СЕТИ

С.А. Зайцев¹, С.А. Субботин²¹ Запорожский национальный технический университет, г. Запорожье, zaitsev.serge@gmail.com² Запорожский национальный технический университет, г. Запорожье, subbotin@zntu.edu.ua

Проведен сравнительный анализ модели искусственной иммунной сети aiNet и модели расширяющегося нейронного газа в задаче кластер-анализа. Предложена гибридная модель искусственной иммунной сети на основе проанализированных моделей, позволяющая повысить скорость обучения сети. Проведены эксперименты, подтверждающие эффективность предложенной модели.

КЛАСТЕР-АНАЛИЗ, ИСКУССТВЕННАЯ ИММУННАЯ СЕТЬ, РАСШИРЯЮЩИЙСЯ НЕЙРОННЫЙ ГАЗ

Введение

Кластерный анализ является инструментом, позволяющим из выборки данных выделить скопления подобных наблюдений и обобщить их, заменив каждую группу компактно расположенных экземпляров эталоном кластера. Кластерный анализ находит широкое применение при построении диагностических и распознающих моделей, поскольку, с одной стороны, позволяет заменить обучающую выборку большой размерности множеством эталонов меньшей размерности, а, с другой стороны, результаты кластерного анализа позволяют представить в модели топологию обучающих данных (например, для нейро-нечетких моделей кластерный анализ позволяет выделить обобщенные правила, а также сформировать нечеткие термы).

Традиционно используемые методы кластер-анализа [1], как правило, сильно зависят от начального разбиения выборки (начальных значений координат центров кластеров) и количество кластеров должно быть известно заранее.

В качестве инструмента для решения задач кластер-анализа возможно использование искусственной иммунной сети (ИИС). Наиболее распространенной моделью ИИС является aiNet [2], которая автоматически определяет количество кластеров и выполняет своего рода компрессию при избыточном объеме входных данных. Тем не менее, для модели aiNet характерно слишком большое число управляющих параметров и высокие требования к вычислительным ресурсам [3]. Поэтому возникает необходимость разработки метода кластер-анализа на основе модели aiNet, свободного от отмеченных недостатков.

Применение метода расширяющегося нейронного газа [4] в кластерном анализе позволяет избежать этих недостатков. Данный метод не зависит от расположения начальных точек поиска, поскольку в его основе лежит вероятностный подход. Однако в методе расширяющегося нейронного газа отсутствует возможность динамического управления

параметрами, влияющими на скорость сходимости метода, что приводит к многократному перезапуску метода с целью нахождения оптимальной комбинации параметров и усложняет его использование в автоматизированных системах.

Перспективным направлением развития модели aiNet в задаче кластер-анализа является ее совмещение с методом расширяющегося нейронного газа. В частности, в гибридной модели целесообразным будет применение используемого в aiNet механизма адаптации к поступающим на вход сети данным и взятого из метода расширяющегося газа принципа определения области сети, которая, собственно, подлежит изменению в процессе адаптации.

Цель работы заключается в разработке метода кластер-анализа на основе гибридной модели ИИС, объединяющей высокую адаптивность модели aiNet и критерий отбора адаптируемой части сети метода расширяющегося нейронного газа, что призвано повысить скорость сходимости метода обучения ИИС и, соответственно, кластер-анализа.

1. Постановка задачи

В общем виде задача кластер-анализа выглядит следующим образом. Пусть X – множество объектов, Y – множество меток кластеров. Задана метрика – функция расстояния между двумя объектами $p(x, x')$, $x \in X$, $x' \in X$. Существует конечная обучающая выборка объектов $X^m = \{x_1, x_2, \dots, x_m\}$, $X^m \in X$. Необходимо разбить выборку X^m на непересекающиеся подмножества (кластеры) таким образом, чтобы каждый кластер состоял из объектов, близких по метрике p , а объекты разных кластеров существенно отличались. При этом каждому объекту $x \in X^m$ приписывается номер кластера $y \in Y$. Следует отметить, что рассматриваемые ниже методы лишь выделяют области кластеров, но не назначают им метки. Задача назначения меток кластерам является тривиальной и не рассматривается в данной статье.

2. Искусственная иммунная сеть

Ключевой идеей, лежащей в основе парадигмы иммунных сетей [5], является тот факт, что иммунная память формируется по причине взаимодействия иммунных клеток, которое происходит даже при отсутствии инородных антигенов. Воздействие одной иммунной клетки на другую может быть либо стимулирующим, либо подавляющим, при этом компоненты ИИС могут распознавать друг друга, а также быть распознанными другими компонентами.

ИИС aiNet можно представить в виде взвешенного графа (не обязательно полносвязного), узлы которого называют клетками, а ребра определяют связи между клетками. Каждому ребру графа соответствует некоторое числовое значение, называемое весом или силой связи. В терминах ИИС экземпляры обучающей выборки называются антигенами. Большинство моделей ИИС, в том числе и aiNet, не делают различий между В-лимфоцитами и антителами, а потому под антителом будем подразумевать узел иммунной сети.

Работа ИИС построена на постоянной адаптации структуры сети к поступающим на вход данным [6]. Принимая входное распределение как набор антигенов, сеть формирует иммунный ответ и создает множество антител, подвергая их мутации и отбору наилучших для дальнейшего использования. После обучения таким образом модель aiNet способна классифицировать поступающие на вход новые экземпляры, отсеивая по заданному порогу связи между антителами и выделяя тем самым группы антител, которые и представляют собой кластеры.

Метод обучения сети формирует иммунную память из множества клеток, способных распознавать экземпляры из обучающей выборки, и множества связей, представляющих структурную организацию данных. В конечном итоге сеть стремится снизить количество клеток в памяти и сделать их более специфичными, поэтому в таком случае сеть выполняет своего рода компрессию хранящейся в памяти информации.

В процессе обучения сети на вход модели поступают антигены, и сеть реагирует на них, вырабатывая иммунный ответ с помощью механизма клональной селекции. Для регуляции размера популяции клонов применяют подходы клональной супрессии и сетевой супрессии. Поскольку в качестве реакции на один и тот же входной вектор генерируется множество клонов, то часть из них будет реагировать друг на друга как на антигенные образцы. Для устранения таких клонов и обеспечения толерантности служит механизм клональной супрессии. В то же время, сетевая супрессия служит для подавления взаимного влияния клонов, произведенных в результате реакции различных антител на антигены.

Метод обучения модели aiNet включает следующие этапы:

1. Дана обучающая выборка антигенов Ag . Инициализировать иммунную память модели $M = \emptyset$. Для каждого антигена из выборки $ag_i \in Ag$, состоящей из n элементов, где $i = 1, \dots, n$, выполнять п. 1.1-1.10.

1.1. Вычислить аффинность антигена к каждому элементу из набора антител $ab_j \in Ab$, где $j = 1, \dots, m$; m – объем множества антител. Значение аффинности обратно пропорционально Евклидовому расстоянию между антигеном и антителом и вычисляется по формуле:

$$aff(ag_i, ab_j) = \frac{1}{\|ab_j - ag_i\|}.$$

1.2. Из набора антител Ab выбрать подмножество Ab^* , состоящее из q антител с наиболее высоким значением аффинности.

1.3. Сгенерировать множество клонов C из q антител пропорционально их уровню аффинности: чем выше значение аффинности антитела к антигену, тем большее количество клонов необходимо создать.

1.4. Клоны из множества C проходят этап управляемой мутации, результатом которого является множество мутировавших клонов C^* :

$$C_j^* = C_j + \alpha_j \cdot (ag_i - ab_j),$$

где α_j – коэффициент, определяющий степень мутации антитела ab_j . Степень мутации каждого клона обратно пропорциональна аффинности его родительской клетки к антигену.

1.5. Вычислить взаимную аффинность антигена ag_i к клонам антител из C^* по формуле:

$$d_{ij} = \frac{1}{\|C_j^* - ag_i\|}.$$

1.6. Отобрать некоторый процент δ клонов с наилучшей аффинностью d из C^* и поместить их в клональную память M_j .

1.7. Удалить из клональной памяти M_j те элементы, у которых аффинность d ниже некоторого порогового значения σ_d .

1.8. Произвести клональную супрессию – определить взаимную аффинность клонов по формуле:

$$s(ab_j, ab_k) = \|ab_j - ab_k\|,$$

где ab_j, ab_k – антитела из клональной памяти M_j .

1.9. Удалить те клоны, для которых значение аффинности s превышает заданный порог σ_d .

1.10. Добавить оставшиеся клоны в иммунную память $M = M \cup M_j$.

2. Определить взаимную аффинность каждой пары антител $s(ab_p, ab_r) = \|ab_p - ab_r\|$, где $p = 1, \dots, q$, $r = 1, \dots, q$.

3. Произвести сетевую супрессию — удалить те антитела, для которых аффинность s превышает порог σ_s .

4. Если критерий останова не достигнут — перейти к этапу 1, в противном случае — к этапу 5.

5. Останов.

Как видно из описания метода, на каждой итерации отбирается часть антител с наиболее высокой аффинностью к заданному антигену. Такие антитела подвергаются клонированию пропорционально значению аффинности. Затем клоны мутируют, и определенная их часть остается в иммунной памяти. При этом из сети удаляются клетки, чья взаимная аффинность превышает порог, тем самым регулируется размер популяции без существенного влияния на работу модели.

При использовании сетей aiNet на практике применяют следующие критерии останова:

- достижение максимального количества итераций;
- превышение максимальной популяции сети;
- возрастание ошибки на k последних последовательных итерациях.

Результатом обучения сети является набор антител, которые отображают внутреннюю структуру антигенов из обучающей выборки. С помощью обученной сети информацию о кластерах можно получить, проанализировав связи между антителами в сети. Количество кластеров можно изменять, варьируя порог отсечения связей между антителами в сети.

3. Расширяющийся нейронный газ

Метод расширяющегося нейронного газа представляет собой итеративный метод кластеризации с добавлением кластеров. Для заданного входного распределения (обучающей выборки) строится граф (сеть узлов), каждый узел которого описывает позицию экземпляра обучающей выборки в пространстве признаков. Метод расширяющегося нейронного газа является адаптивным, поскольку структура газа изменяется, реагируя на изменения во входных данных.

Ниже описан метод обучения модели расширяющегося нейронного газа. Изначально модель расширяющегося нейронного газа представлена в виде двух случайных узлов, соединенных связью с нулевым “возрастом”. Возраст определяется количеством итераций, прошедших с момента последнего взаимодействия узла сети с некоторым экземпляром из обучающей выборки.

1. Установить номер текущей итерации $N = 0$. Задать значения коэффициентов уменьшения ошибок α и β . Установить интервал добавления новых узлов в сеть λ . Построить сеть, содержащую два случайных узла с нулевой локальной ошибкой ϵ и нулевым возрастом a .

2. Из обучающей выборки получить вектор x , описывающий некоторый экземпляр.

3. Среди узлов сети найти два узла s и t , представленных векторами w_s и w_t соответственно, таким образом, чтобы расстояние $\|w_s - x\|$ было минимальным, а $\|w_t - x\|$ — вторым минимальным.

4. Увеличить локальную ошибку в узле s :

$$\epsilon_s = \epsilon_s + \|w_s - x\|^2.$$

5. Переместить узел s и все связанные с ним узлы по направлению к x следующим образом:

$$w_s = w_s + \epsilon_w \cdot (x - w_s),$$

$$w_n = w_n + \epsilon_n \cdot (x - w_n),$$

где n — узел, соседний с s , ϵ_w и ϵ_n — коэффициенты, определяющие расстояние, на которое смещаются узлы.

6. Увеличить возраст всех связей между узлом s и его соседними узлами.

7. Если узлы s и t соединены связью, то обнулить ее возраст $a_{\{s,t\}} = 0$, в противном случае — создать связь с нулевым возрастом между ними.

8. Удалить все связи, возраст которых превышает заданное пороговое значение a_{max} .

9. Удалить все узлы, не имеющие связей с соседними узлами.

10. Если порядковый номер текущей итерации N кратен λ , и при этом не достигнуто заданное максимальное количество узлов, то выполнить пп. 10.1-10.5, в противном случае — перейти к этапу 11.

10.1. Найти узел u с максимальным значением ошибки ϵ_u .

10.2. Среди связанных с u узлов найти узел v с наибольшим значением ошибки ϵ_v .

10.3. Создать узел r , описанный вектором w_r между узлами u и v :

$$w_r = \frac{(w_u + w_v)}{2}.$$

10.4. Создать связи между r и v , r и u . Удалить связь между u и v .

10.5. Согласно значению коэффициента α изменить значение ошибок в узлах u и v :

$$\epsilon_u = \epsilon_u - \alpha \cdot \epsilon_u,$$

$$\epsilon_v = \epsilon_v - \alpha \cdot \epsilon_v,$$

$$\epsilon_r = \epsilon_u.$$

11. Уменьшить значения ошибок каждого узла сети соответственно коэффициенту β :

$$\epsilon_j = \epsilon_j - \beta \cdot \epsilon_j,$$

где j — узел сети.

12. Если критерий сходимости не достигнут — увеличить номер итерации и перейти к этапу 2, в противном случае — перейти к этапу 13.

13. Останов.

В расширяющемся нейронном газе локальные ошибки нейронов накапливаются, в то время как

метод обучения приводит к минимизации этой ошибки. Для того, чтобы новые ошибки имели большее влияние на структуру газа, а также для снижения темпов роста локальной ошибки, на каждой итерации выполняется глобальное уменьшение ошибки пропорционально ее значению.

Изменение структуры газа осуществляется за счет перемещения отдельных узлов. На каждой итерации узел, наиболее близкий к входному вектору, а также его соседние узлы, перемещаются в направлении, снижающем ошибку. Все эти узлы перемещаются по направлению к входному вектору на некоторое расстояние, определяемое коэффициентами ϵ_w и ϵ_n . Фактически эти коэффициенты имеют наибольшее влияние на скорость сходимости метода обучения модели ИИС.

Целесообразно использовать такие значения ϵ_w и ϵ_n , чтобы коэффициент ϵ_w значительно превышал ϵ_n . Это обеспечит плавность и высокую скорость сходимости метода обучения. Малые значения этих коэффициентов снижают эффективность и скорость работы метода, а высокие приводят к построению модели, неустойчивой к выбросам.

В [7] было установлено экспериментально, что оптимальное значение коэффициента $\epsilon_w \approx 0.05$, а значение ϵ_n должно быть на пару порядков ниже. Однако более точные значения ϵ_w и ϵ_n зависят от входных данных конкретной решаемой задачи.

Еще одним важным управляющим параметром модели расширяющегося нейронного газа является частота добавления новых узлов. Из описанного выше метода видно, что узлы сети добавляются на каждой λ -ой итерации, т.е. через определенные фиксированные интервалы. Частота добавления новых узлов оказывает существенное влияние на производительность метода обучения. Занижен-

ные значения коэффициента λ приводят к резкому снижению ошибки в начале работы метода, поэтому на ранних итерациях узлы сети будут иметь меньше шансов для распространения, и модели потребуется больше времени для достижения требуемой структуры, чем при более высоких значениях λ . Низкое значение λ также приводит к формированию неактивных узлов – узлов, которые не способны адаптироваться к входным данным из-за большой отдаленности от них. Такие узлы не влияют на эффективность модели, но повышают её потребность в вычислительных ресурсах. С другой стороны, слишком большие значения λ снижают темпы роста модели, что приводит к медленной сходимости метода обучения.

4. Сравнительный анализ моделей aiNet и расширяющегося нейронного газа

В таблице приведены результаты сравнительного анализа моделей aiNet и расширяющегося нейронного газа.

Как видно из таблицы, обе модели поддерживают разнообразие в популяции за счет различных механизмов адаптации. Модели обладают подобным внутренним представлением данных и общей схемой работы, что определяет их способность к обобщению и устойчивость к шумам.

Однако имеются существенные отличия на этапах отбора узлов и их модификации. Отличия заключаются не только в количестве модифицируемых узлов за одну итерацию, но и в способе их модификации. Тот факт, что рассмотренная выше модель ИИС использует клональную селекцию для создания новых узлов, определяет более высокую скорость сходимости метода ее обучения. С другой стороны, накопление локальной ошибки в узлах

Таблица

Результаты сравнительного анализа моделей aiNet и расширяющегося нейронного газа

Характеристики	Искусственная иммунная сеть	Расширяющийся нейронный газ
Структура	Взвешенный граф	Взвешенный граф
Узлы	Антитела	Нейроны
Ребра	Сила связи антител (степень подобия)	Количество итераций, прошедших с момента взаимодействия соединенных узлов с экземпляром из обучающей выборки
Представление данных	Вектор вещественных чисел	Вектор вещественных чисел и накопленная локальная ошибка
Метрика	Евклидово расстояние	Евклидово расстояние
Механизм адаптации	Клональная селекция	Линейное перемещение узлов
Отбор узлов	Отбираются несколько антител с наибольшей аффинностью к антигену	Отбираются два узла: ближайший узел и ближайший из связанных с ним узлов
Динамика популяции	Удаляются клетки, обладающие низкой аффинностью к антигенам и высокой взаимной аффинностью (расположенные достаточно близко друг с другом)	Удаляются клетки без связей и связи после определенного периода неактивности
Инициализация	Несколько случайно расположенных узлов	Два случайно расположенных узла
Добавление элементов	Происходит путем клонирования существующих антител как реакция на антиген	На некоторых итерациях с заданным заранее интервалом добавляется один узел между двумя другими узлами с наибольшей локальной ошибкой

сети в модели расширяющегося нейронного газа служит своего рода “памятью” нейронов и позволяет принимать решения о модификации узлов с учетом их реакции на предыдущие итерации, что делает изменение структуры модели более “плавным”.

Исходя из этого, предлагается создать гибридную модель ИИС, использующую преимущества расширяющегося нейронного газа.

5. Гибридная модель ИИС

В предлагаемой авторами модели антитела характеризуются локальной ошибкой, изменяющейся всякий раз, когда антитело обладает достаточной аффинностью к некоторому антигену из обучающей выборки. Это позволит использовать значение локальной ошибки в качестве управляющего параметра на этапе клональной селекции, т.е. создавать популяцию клонов, основываясь не на аффинности антитела к текущему антигену, а на его локальной ошибке. Локальная ошибка аккумулирует в себе результат предыдущих взаимодействий антитела с антигенами, и высокое ее значение свидетельствует о том, что данное антитело находится в области с высокой концентрацией антигенов, а, следовательно, необходимо провести клональную селекцию для более точного покрытия этой области. С другой стороны, низкая локальная ошибка говорит о том, что в окрестности данного антитела либо находится небольшое количество антигенов, либо существует достаточное количество антител, чтобы их распознавать. Ниже приведен метод обучения гибридной модели.

1. Инициализировать иммунную память M двумя случайными антителами с нулевой локальной ошибкой.

2. Для каждого антигена из обучающей выборки $ag \in Ag$ выполнить п. 2.1-2.7.

2.1. Отобрать из иммунной памяти M некоторый процент δ антител Ab^* с наибольшей аффинностью к антигену ag .

2.2. Накопить для отобранных антител Ab^* локальную ошибку

$$\varepsilon_{ab} = \varepsilon_{ab} + \|ab - ag\|,$$

где $ab \in Ab^*$, ab – рассматриваемое антитело, ε_{ab} – его локальная ошибка.

2.2. Сгенерировать множество клонов C для каждого из отобранных антител Ab^* пропорционально их локальной ошибке. Антитела с большей локальной ошибкой произведут большее число клонов, вычисляемое по формуле:

$$N_C = N_{max} \cdot \left(1 - \frac{1}{\varepsilon_{ab}}\right),$$

где N_{max} – максимально возможное количество клонов одного антитела на одной итерации.

2.3. Клоны из множества C подвергаются мутации. Степень мутации также прямо пропорциональна локальной ошибке родительского антитела.

2.4. Выполнить клональную суппрессию и сетевую суппрессию, как описано выше в методе обучения ИИС (п. 1.5-1.9).

2.5. Оставшиеся после этапа суппрессии клоны C^* поместить в иммунную память $M = M \cup C^*$.

2.6. Установить уровень локальной ошибки полученных клонов C^* равным нулю.

2.7. Если не достигнут критерий останова – перейти к этапу 2, в противном случае – к этапу 3.

3. Останов.

Для антител с низкой локальной ошибкой (очень близких к текущему антигену) вполне возможно, что не будет произведено ни одного клона. Таким образом, когда все антитела будут достаточно близко находиться к антигенам из обучающей выборки, суммарная ошибка сети будет оставаться практически неизменной. Суммарная ошибка рассчитывается по формуле:

$$\varepsilon^* = \sum_{ab \in Ab} \varepsilon_{ab}.$$

Предлагается использовать это свойство в качестве критерия останова для приведенного выше метода обучения.

Рассмотрим влияние основных управляющих параметров метода на его работу. Под управляющими параметрами будем понимать количество антител, допускаемых к клонированию, максимальное количество клонов, максимальную степень мутации. Коэффициенты, отвечающие за проведение клональной и сетевой суппрессии подробно рассмотрены в [8] и не имеют специфического воздействия на предложенную модель.

Важно отметить, что количество антител, допускаемых к клонированию, должно превышать количество клонов, поскольку в противном случае на каждой итерации будут производиться новые антитела с нулевой ошибкой, которые не будут успевать ее накапливать. Большое значение δ целесообразно использовать на начальных итерациях метода, поскольку это приведет к быстрому распространению антител. В то же время, когда модель будет уже сформирована, отбор большого количества антител для клонирования дестабилизирует иммунную сеть и ухудшает ее характеристики.

Увеличить скорость работы метода обучения модели можно за счет изменения способа мутации клонов. Так, если мутирующие клоны расположены на одном отрезке, соединяющем родительское антитело и текущий антиген, то поведение модели очень напоминает расширяющийся нейронный газ. Если же клоны создаются в некотором радиусе от родительского антитела, и радиус зависит от степени мутации клонов, то модель имитирует поведение иммунной сети.

6. Эксперименты и результаты

Предложенный метод был программно реализован на языке Java. Разработанное программное обеспечение позволяет осуществлять разбиение

на кластеры множества входных данных. Помимо разделения на кластеры, программное обеспечение предоставляет в текстовом и графическом виде информацию о динамике локальной ошибки модели.

Предложенная модель тестировалась на синтетических выборках данных, взятых из каталога SPAETH (<http://people.sc.fsu.edu/~jburkardt/datasets/spaeth>). Оценивались такие параметры модели, как скорость обучения, динамика популяции, скорость снижения ошибки и точность работы. Выборки содержали небольшое число экземпляров (50-100), описанных векторами вещественных чисел. Большинство выборок содержали двумерные данные, однако экспериментально было установлено, что предложенный метод также хорошо работает при высоких размерностях данных.

На рисунке представлены графики динамики суммарной ошибки ϵ^* предложенной гибридной модели и модели расширяющегося нейронного газа.

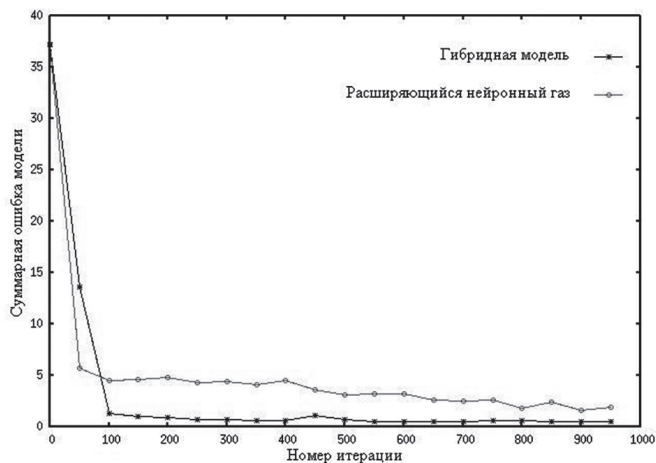


Рис. 1. Динамика суммарной ошибки гибридной модели и модели расширяющегося нейронного газа

Более низкие значения суммарной ошибки гибридной модели объясняются тем, что в ней минимизируется локальная ошибка с помощью механизма клональной селекции, но это не приводит к избыточному количеству клеток из-за механизмов супрессии, сокращающих популяцию.

Выводы

С целью решения актуальной задачи автоматизации кластер-анализа выборки данных разработано математическое обеспечение, позволяющее проводить кластеризацию на основе методов иммунокомпьютинга.

Научная новизна работы заключается в том, что впервые предложен метод кластеризации, использующий гибридную модель, основанную на модели ИИС aiNet и принципах расширяющегося нейронного газа, что позволяет повысить скорость сходимости метода обучения модели.

Практическая ценность работы заключается в том, что было разработано программное обеспе-

чение для проведения кластер-анализа с помощью предложенной гибридной модели ИИС.

Тестирование предложенной гибридной модели ИИС показало высокую скорость сходимости метода обучения модели, что позволяет рекомендовать ее использование для решения практических задач.

Дальнейшие исследования могут быть сосредоточены на анализе влияния вида мутации клонов антител на эффективность работы метода обучения модели ИИС.

Список литературы: 1. Jain A.K., Murty M.N., Flynn P.J. Data clustering: a review // ACM Computing Surveys. 1999. №31(3). P. 264-323. 2. Tang N., Rao Vemuri V. An artificial immune system approach to document clustering // Proceedings of the 2005 ACM symposium on Applied computing (2005). New York, USA: ACM, 2005. P. 918-922. 3. De Castro L. N., Von Zuben F.J. aiNet – an artificial immune network for data analysis // Data Mining: A Heuristic Approach. Eds. H. A. Abbass, R. A. Sarker, C. S. Newton. – USA, Miami: Idea Publishing Group, 2001. – P. 231-259. 4. Jirayusakul I A., Auwatanamongkol S. A supervised growing neural gas algorithm for cluster analysis // International Journal of Hybrid Intelligent Systems. 2007. №4(4). P. 217-229. 5. Jerne N.K. Towards Network Theory of the Immune System // Ann. Immunol. 1974. №125C. P. 373-389. 6. De Castro L.N., Von Zuben F.J. An evolutionary immune network for data clustering // Brazilian Symposium on Artificial Neural Networks: Proceeding of the IEEE SBRN (22-25 November 2000). Zurich: Springer-Verlag, 2000. P. 84-89. 7. Holmstrom J. Growing neural gas: experiments with GNG, GNG with utility and supervised GNG // Thesis: M.Sc. in Computer Science. – Sweden, Uppsala: Uppsala University, 2002. – 42 p. 8. De Castro L.N. The immune response of an artificial immune network (aiNet) // Proceedings of the 2003 Congress on Evolutionary Computation (8-12 December 2003). Chicago, USA: IEEE Press, 2003. P. 146-153.

Поступила в редакцию 8.06.2010.

УДК 004.93

Кластерний аналіз з використанням гібридної моделі на основі штучної імунної мережі / С. О. Зайцев, С. О. Субботін // Біоніка інтелекту: наук.-техн. журнал. – 2010. – № 3 (74). – С. 70–75.

Проведено порівняльний аналіз моделі штучної імунної мережі aiNet та моделі нейронного газу, що поширюється, в задачі кластер-аналізу. Запропоновано гібридну модель штучної імунної мережі на основі проаналізованих моделей, що дозволяє підвищити швидкість навчання мережі. Проведено експерименти, що підтверджують ефективність запропонованої моделі.

Табл. 1. Іл. 1. Бібліогр.: 7 найм.

UDC 004.93

Using a hybrid model based on the artificial immune network in cluster-analysis / S. A. Zaitsev, S. A. Subbotin // Bionics of Intelligence: Sci. Mag. – 2010. – № 3 (74). – P. 70–75.

The role of the artificial immune network model (aiNet) and growing neural gas model in cluster-analysis has been analyzed. A hybrid model based on the artificial immune network has been proposed, which allows to perform faster network training. The experiments have been carried to approve the efficiency of the suggested model.

Tab. 1. Fig. 1. Ref.: 7 items.