

ПРИМЕНЕНИЕ МОДИФИЦИРОВАННЫХ ИСКУССТВЕННЫХ ИММУННЫХ СЕТЕЙ ДЛЯ РЕШЕНИЯ ЗАДАЧ ГИДРОАКУСТИЧЕСКОГО ОБНАРУЖЕНИЯ

Введение

Передвижение кораблей и решение ими служебных задач связано с обеспечением корабля всеми видами наблюдения: визуальным, радиолокационным и гидроакустическим. Дистанция радиолокационного обнаружения зависит от технических параметров радиолокационной станции, высоты расположения антенны от водной поверхности, гидрометеорологических условий и радиолокационной наблюдаемости, площади отражающей поверхности объекта. Для малых и сверхмалых водных объектов последний фактор является определяющим. Известны случаи, когда в акватории Черного моря дальности гидроакустического обнаружения надводных объектов значительно превышали дальности их радиолокационного обнаружения, а в отдельных ситуациях наблюдение за полной надводной обстановкой может осуществляться только гидроакустическими средствами, например, при осуществлении контроля за антропогенным загрязнением. Своевременное обнаружение малых и сверхмалых быстроходных объектов – одна из актуальнейших задач, которая стоит перед гидроакустической службой корабля.

Проблема обнаружения морского динамического объекта с помощью гидроакустических средств предполагает решение следующих задач[1-4]:

- выделения сигнала от объекта в условиях действия изотропных и локальных помех;
- измерения параметров гидроакустического источника;
- классификации объекта по его гидроакустическим характеристикам и элементам движения.

Решение комплекса данных взаимосвязанных задач: обнаружения, измерения и классификации с учетом не стационарности морской внешней среды, недостоверности априорных сведений, неполноты и неточности оценок параметров также осложнено непредсказуе-

мым поведением наблюдаемого объекта.

Гидроакустические средства наблюдения за внешней обстановкой, применяемые для информационного обеспечения решения проблемы, фиксируют параметры первичного или вторичного акустических полей объекта на фоне изотропных, а также естественных или искусственных локальных полей. Проводимые ими измерения используются для оценки элементов движения объекта и его классификации.

Принципиальными компонентами таких вычислений являются нечеткие системы, искусственные нейронные сети (ИНС) и эволюционные вычисления, включающие, в частности, генетические алгоритмы. При описании информационных и процедурных элементов «мягких» вычислительных процессов положения теории нечетких систем позволяют формализовать неточность и неопределенность используемой информации, нейронные сети – организовать обучение в процессе выполнения вычислений и их высокопроизводительную реализацию, а генетические алгоритмы – обеспечить решение оптимизационных задач [5-6].

В настоящее время известны различные примеры использования различных систем для классификации гидроакустических сигналов, различающиеся как постановкой задачи распознавания, так и собственно реализацией классификатора гидроакустических сигналов. Особенно необходимо выделить использование нейроподобных сетей и нечетких классификаторов в рассматриваемой области [7-9].

Искусственные иммунные системы сравнительно новая проблемная область информатики, однако она не уступает нейронным сетям по своим возможностям в практической реализации.

2. Общая постановка задачи

Целью данной работы является исследование возможности использования искусственных иммунных систем для решения задачи распознавания гидроакустических сигналов на основе признаковых пространств, сформированных с помощью вейвлет-преобразований, и разработать метод автоматического распознавания гидроакустических сигналов в условиях ограничений на длительность обрабатываемых сигналов при частичной или полной априорной неопределенности сведений об их структуре.

3. Описание и представление признакового пространства

Данные состоят из звуковых записей полученных пассивного гидролокатора трех типов кораблей. Все три типа записей были разбиты на 150 множеств по 160 секунд. Для обучения использовалось по 100 примеров от каждого типа корабля и по 50 примеров для тестирования.

Отношение сигнала к шуму изменялся на более чем на 35 децибел. С помощью преобразования Фурье были исследованы фазо-частотные и амплитудно-частотные характеристики исследуемых сигналов (Рис.1)

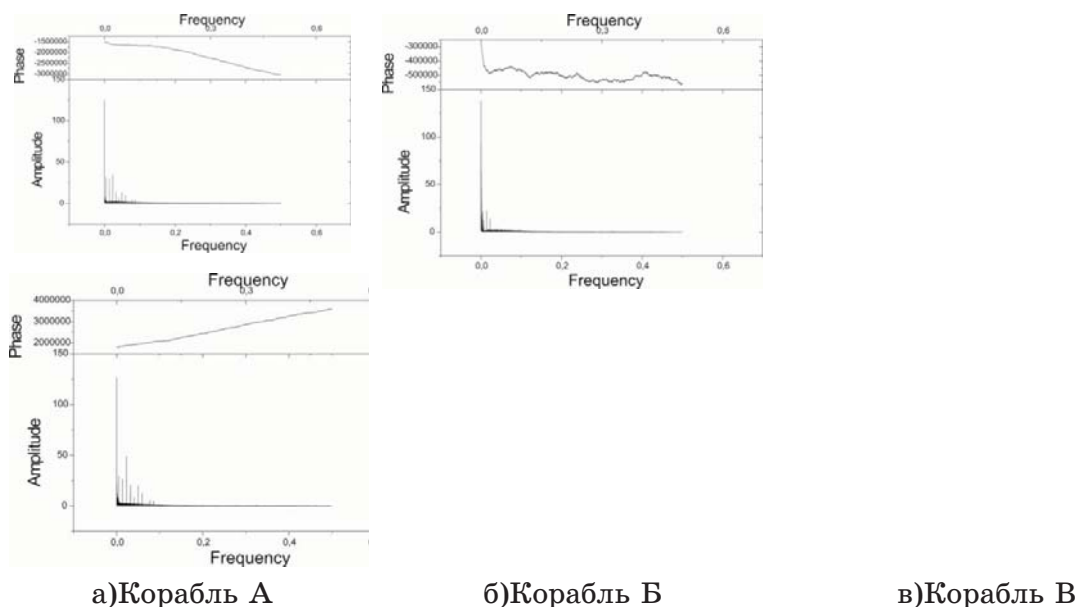


Рисунок 1 – Фазо-частотные и амплитудно-частотные характеристики гидроакустических сигналов

Важной задачей процесса распознавания является определение набора признаков Y_1, Y_2, \dots, Y_R , т.е. формирование признакового пространства таким образом, чтобы при минимально возможной размерности R обеспечить требуемую достоверность классификации. Применение для этих целей подходов, основанных на традиционном спектрально-временном анализе Фурье, связано с определенными трудностями: высокими требованиями к входному потоку по отношению сигнал/шум (ОСШ); недостаточной достоверностью классификации для многокомпонентных сигналов; наличием значительного объема реализаций.

Ранее нами в работе [10] было показано, что одним из информативных показателей для решения задачи распознавания гидроакусти-

ческого сигнала является показатель энтропии логарифма энергии и показатель энтропии Шеннона сигнала. Дополнительно использовались такие статистические показатели сигнала как: среднее абсолютное отклонение от среднего значения, среднеквадратичное отклонение от среднего и дисперсия сигнала. Энтропия является общей концепцией оценки информативности во многих областях, главным образом в обработке сигналов. В нашей работе для формирования признакового пространства использовалось два вида энтропии:

Энтропия Шеннона:

$$E1 = -\sum_i s_i^2 \log(s_i^2) \quad (1)$$

При соглашении, что $0 * \log(0) = 0$

И энтропия логарифма энергии:

$$E2 = \sum_i \log(s_i^2) \quad (2)$$

При соглашении, что $\log(0) = 0$

Где s_i - значение сигнала s .

На рисунках 3 и 4 показано усредненное значение энтропии Шеннона и энтропии логарифма энергии по всем обучающим и тестовым наборам данных.




Рисунок 2 – Энтропия Шеннона




Рисунок 3 – Энтропия логарифма энергии

Дополнительно для формирования признакового пространства в нашей реализации были использованы вейвлеты Габора. Расчет проводился в соответствии с методикой, описанной в работе [3], с помощью модифицированной нами программы [<http://www-isis.enst.fr/Applications/tftb/iutsn.univ-nantes.fr/auger/tftb.html>]. Для признакового пространства нами использовалось 24 вейвлет-коэффициента.

4. Модифицированная иммунная сеть для решения задач классификации

4.1. Общая постановка задачи распознавания гидроакустических сигналов

В общем случае распознавание представляет процесс отнесения исследуемого объекта, в данном случае радиосигнала, представленного совокупностью наблюдений, к одному из альтернативных классов. Процесс соотнесения объекта к классу базируется на существующих различиях некоторой упорядоченной совокупности признаков распознавания. Традиционно указанные признаки формируют на основе таких параметров сигналов, как длительность элементов модулирующей функции, число экстремумов огибающей сигнала, статистические характеристики количества переходов нулевого уровня, моменты высших порядков формы спектра, полученных в результате наблюдений [2]. Затем совокупность наблюдений представляется в виде матрицы

$$X_{pn} = \begin{pmatrix} x_{11} & x_{12} & \dots & x_{1i} & \dots & x_{1n} \\ x_{21} & x_{22} & \dots & x_{2i} & \dots & x_{2n} \\ \dots & \dots & \dots & \dots & \dots & \dots \\ x_{p1} & x_{p2} & \dots & x_{pi} & \dots & x_{pn} \end{pmatrix} \quad (3)$$

где n — количество наблюдений, используемых для распознавания, а каждый столбец

$X_i = (x_{1i}, x_{2i}, \dots, x_{pi})^T$, $i = 1, 2, \dots, n$ матрицы X_{pn} есть p -мерный вектор наблюдаемых значений p признаков X_1, X_2, \dots, X_p отражающих наиболее важные для распознавания свойства объектов. Набор признаков p , как правило, является одинаковым для всех распознаваемых классов s_1, s_2, \dots, s_k . Таким образом, рассматривается задача распознавания принадлежности наблюдаемого объекта к одному из конечного фиксированного числа классов s_1, s_2, \dots, s_k , описываемых одинаковым для всех классов набором признаков X_1, X_2, \dots, X_p . Различия между классами будут проявляться только в различии характеристик признаков у разных объектов. Тогда для любого набора признаков X_1, X_2, \dots, X_p можно задать правила, согласно которым любым двум классам s_1 и s_r ставится в соответствие вектор, состоя-

щий из q скаляров, называемых межклассовыми расстояниями и выражающих степень отличия у этих классов характеристик данных признаков.

$$D_{1r} = \begin{vmatrix} d_1^{1r} \\ \dots \\ d_q^{1r} \end{vmatrix} \quad (4)$$

Неотъемлемой частью процесса распознавания является определение набора признаков X_1, X_2, \dots, X_p , т. е. формирование признакового пространства таким образом, чтобы при минимально возможной размерности p обеспечить требуемую достоверность классификации. В соответствии с рассмотренным подходом к решению задачи распознавания важным моментом является выбор метода формирования признакового пространства.

4.2. Общие понятия об искусственных иммунных сетях

Применительно к задачам распознавания и классификации в качестве популяции антигенов иммунной сети выступает набор данных (векторов), которые нужно распознать. Назовем этот набор $X = (x_1, x_2, \dots, x_N)$. Каждый вектор $x_i, i = 1, \dots, N_p$ состоит из p элементов. Элементами вектора могут являться наборы переменных, атрибутов или характеристик распознаваемого объекта. Для количественного расчета обоих видов взаимодействия векторов распознаваемого объекта в теории искусственных иммунных систем используется понятие аффинности.

Определение 1. Под *аффинностью* будем понимать *меру взаимодействия* (или *силу связи*) соответствующих комплементарных участков антигена и антитела или двух антител, которая формально может быть представлена в виде одной из метрик (например, Евклидоваго расстояния), указывающей на степень подобия или различия между соответствующими атрибутами строк, такой что $S^P \times S^P \rightarrow \mathfrak{R}^+$.

В текущей реализации аффинность определяется между 0 и 1 включительно и вычисляется как Евклидово расстояние *векторов свойств* двух объектов. Таким образом, низкие значения аффинности указывают на сильную близость двух объектов. Так как каждый элемент данных x_i представляет собой p -мерный вектор, то для модели-

рования связей «антиген-антитело» и «антитело-антитело» все антитела должны быть также представлены в форме p -мерных строк или векторов.

Определение 2. Множество стереохимических взаимодействий или множество свойств антител, определяющих их межмолекулярную аффинность, будем называть *многомерным пространством форм P* .

При использовании пространства форм предполагается возможность полного описания обобщенной формы антитела при помощи строки параметров длины p . Если при этом предположить что и антиген в свою очередь имеет комплементарную антителу область, которую можно описать при помощи такого же количества параметров, то при объединении этих параметров в векторы, антитело (Ab) и антиген (Ag) могут таким образом быть представлены как точки в p -мерном Евклидовом пространстве.

Отображение множества форм во множество параметров решаемой задачи не имеет значения в вычислительном смысле и полностью определяется предметной областью использования ИИС. Каждое антитело способно распознавать не единственный антиген, а множество антигенов, чья форма дополнения (комплемент) находится внутри определенного объема в пространстве форм. Этот объем характеризуется параметром ε , называемым кросс-реактивным порогом.

Определение 3. *Кросс-реактивным порогом* называется область в многомерном пространстве форм, охватывающая антитело, внутри которой проявляется его активность по отношению к антигенам или другим антителам.

Определение 4. *Под уровнем гипермутации* будем понимать численное значение, используемое для определения числа клонов подвергнутых мутации данной клетки памяти, которые позволяет ввести в популяцию клетки.

Определение 5. *Искусственная иммунная сеть* представляет собой *полно связанный граф, состоящий из множества узлов* – клеток, сети (антител), и множества взвешенных ребер, которые устанавливают связи между клетками.




Рисунок 4 – Обобщенная схема алгоритма иммунной сети

Формально алгоритм иммунной сети можно представить следующим образом:

$$\text{immNET} = (X, C, M, N_C, D, S, n, \xi, \sigma_d, \sigma_s) \quad (5)$$

где X – набор данных, состоящий из N_p векторов размерности p ; C – матрица, содержащая все клетки (антитела) сети ($C \in \mathcal{R}^{N \times p}$) – популяция антител; M – матрица, состоящая из N клеток памяти ($M \subseteq C$); N_C – общее количество клонов, создаваемых стимулируемыми клетками в каждом поколении (при активации сети); D – матрица элементов d_{ij} **Ag-Ab** аффинностей; S – матрица элементов s_{ij} **Ab-Ab** аффинностей; n – количество лучших клеток, отбираемых из C для клонирования и мутации; ξ – процент улучшенных клеток, отбираемых из популяции клонов для последующей обработки; σ_d – пороговый коэффициент (кросс-реактивный порог) гибели клетки в зависимости от ее **Ag-Ab** аффинности; σ_s – пороговый коэффициент сжатия сети.

Значение весового коэффициента ребра отвечает аффинности связи клеток друг с другом. В иммунных сетях различают два вида аффинности:

- аффинность связи «антиген-антитело» (**Ag-Ab**) – степень расхождения;
- аффинность связи «антитело-антитело» (**Ab-Ab**) – степень подобия.

В целом, алгоритм искусственной иммунной сети представляет собой итерационную процедуру, которая может быть получена при реализации трех основных фаз:

1. *Созревание аффинности*: антигены (точки данных) представлены антителам, которые подвергаются гипермутации, для лучшего соответствия антигенам (взаимодействие антитела и антигена).

2. *Клональное расширение*: те антитела, которые сильнее стимулируются, т.е. лучше соответствуют образу, отбираются для дальнейшего клонирования и роста иммунной сети.

3. *Супрессия сети*: взаимодействие между антителами определяется количественно и если одно антитело распознает другое, то одно из них удаляется из пула клеток (взаимодействие антитела и антитела).

4.3. Принципы модификации иммунных сетей для решения задач классификации

Рассматривая вычислительные аспекты парадигмы иммунных систем, можно выделить следующие основные элементы, необходимые для проектирования их искусственных аналогов – искусственных иммунных систем (ИИС). Ими являются:

- множество способов представления компонентов системы (*S*);
- множество механизмов, позволяющих оценить взаимодействие индивидуумов с окружающей средой и друг с другом (*M*);
- процедуры адаптации, которые управляют динамикой системы, т.е. изменением ее состояния во времени (*A*).

Следовательно, в общем виде ИИС можно представить так:

$$\text{ИИС} = (S, M, A). \quad (6)$$

Способы представления позволяют создавать абстрактные модели иммунных органов, клеток или молекул; механизмы оценки, также называемые функциями аффинности, позволяют количественно оценить взаимодействия этих «искусственных иммунных органов», а процедуры адаптации, выраженные в виде множества общих алгоритмов достижения цели, управляют динамикой ИИС.

Для проектирования структуры ИИС зачастую применяются методы, активно используемые в других биологических вычислительных парадигмах таких как, например, нейронные сети и эволюционные алгоритмы. Набор оценочных функций, взятых из данных вычислительных парадигм, вполне может быть использован для оценки взаимодействия индивидуумов ИИС. В то же время, эволюционные алгоритмы хорошо подходят для управления изменением во времени состояний клеток и молекул, из которых состоит искусственная иммунная система. С учетом вышесказанного процесс построения ИИС можно разделить на два основных этапа:

- выбор подходящей формы представления индивидуумов и меры аффинности;

- применение любого из существующих алгоритмов (или нового алгоритма) для управления изменением состояний системы во времени.

Необходимо также отметить, что форма представления индивидуумов и мера аффинности полностью определяются предметной областью, в которой предполагается использовать ИИС и типом решаемой задачи. Поэтому общий поэтапный подход к разработке ИИС можно представить следующим образом (рис. 5).



Рисунок 5 – Основные этапы разработки искусственной иммунной системы

Основной целью изучения области применения ИИС является получение набора ключевых признаков (атрибутов) тех объектов или процессов, для изучения которых разрабатывается данная ИИС. Эти атрибуты выступают в роли аргументов задачи исследования. Система осуществляет поиск таких значений аргументов, которые бы в наибольшей степени удовлетворяли условиям задачи.

Таким образом, улучшить качество работы иммунной сети можно посредством изменения механизмов мутации и вычисления функции аффинности. В нашей работе предлагается обобщенная схема модификации алгоритма иммунной сети для решения задач классификации (Рис.6.).

В данной работе использовался классический вариант иммунной сети и вариант с модифицированными процедурами вычисления аффинности и операторов мутации (4-й вариант).

В данном варианте реализации искусственной иммунной сети модифицирован расчет аффинности между антителом и антигеном и процесс мутации. Модификация расчета аффинности позволяет более оптимально устанавливать значение аффинности для антитела и отбирать для дальнейшего клонирования только наилучшие индивидуумы. Модификация процесса мутации разрешает ускорить выполнение этой операции и вносит дополнительные функции управления точностью сходимости. Указанные модификации и некоторые другие составляющие процедуры описаны ниже:

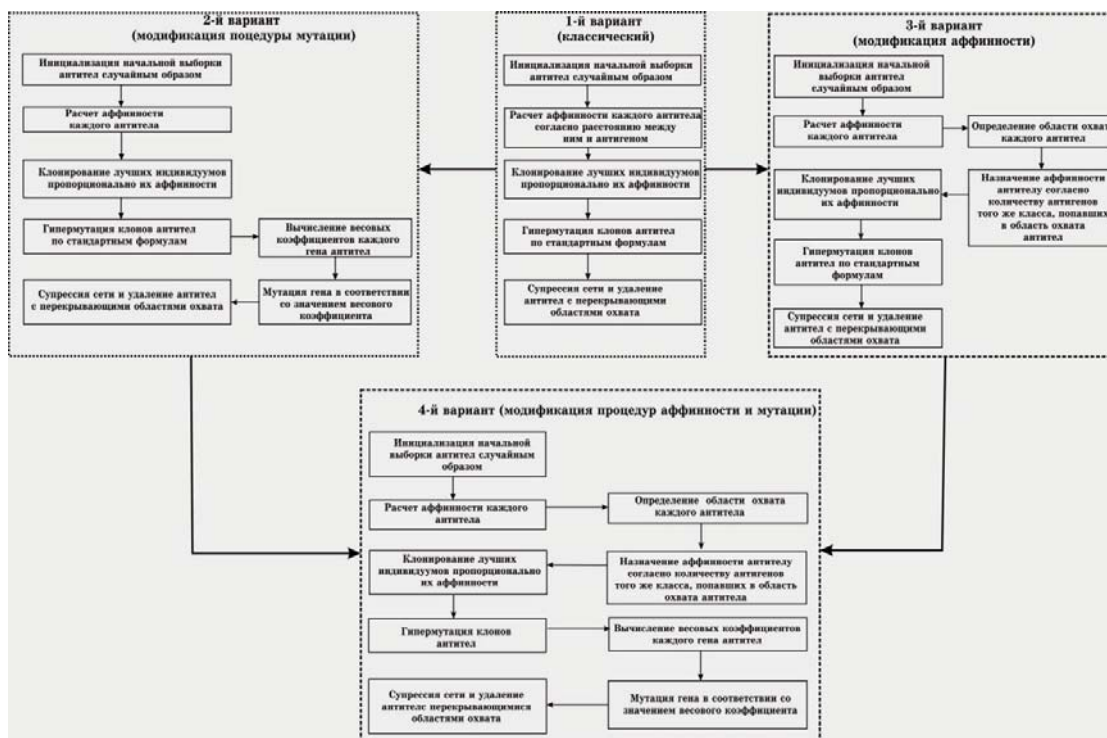


Рисунок 6 – Общая схема создания модифицированных алгоритмов иммунной сети для решения задач классификации

Поскольку аффинность Ag-Ab связана с расстоянием между ними, она может быть рассчитана через любой способ измерения расстояния между двумя строками или векторами. Итак, если даны координаты антитела $Ab = \langle Ab_1, Ab_2, \dots, Ab_i \rangle$, и антигена $Ag = \langle Ag_1, Ag_2, \dots, Ag_i \rangle$, то расстояние D между ними может быть определено как:

$$D = \sqrt{\sum_{i=1}^L (Ab_i - Ag_i)^2} \quad (7)$$

$$D = \sum |Ab_i - Ag_i|, \quad (8)$$

где (1) - формула Евклидоваго расстояния, (2) - формула Манхеттенского расстояния.

Аффинность рассчитывается по следующей формуле:

$$\text{Aff}_{ij} = \begin{cases} \frac{\text{Dist}_{ij} + \frac{n_j}{N_j}}{2}, & n_j = 0 \\ 0 & n_j > 0 \end{cases}, \quad (9)$$

где Aff_{ij} - аффинность между i -ым антителом и j -ым антигеном; Dist_{ij} - расстояние между i -ым антителом и j -м антигеном (нормированное от 0 до 1: 0 – максимально возможное расстояние, 1 – полное совпадение координат); n_j – количество антигенов, которые попали в область охвата i -ого антитела, в которых ключевой класс совпадает с j -ым антигеном; N_j – общее количество антигенов, в которых ключевой класс совпадает с j -м антигеном; n_j – количество антигенов, которые попали в область охвата i -ого антитела, в которых ключевой класс не совпадает j -м антигеном.

Общее количество клонов, сгенерированных для всех из n отобранных антител, устанавливается согласно формуле (3):

$$N_c = \sum_{i=1}^n \text{round}\left(\frac{\beta * N}{i}\right) \quad (10)$$

где N_c – общая сумма клонов, созданных для каждого из антигенов; β - множительный коэффициент; N – общая сумма антител; round – оператор, который округляет аргумент к ближайшему целому числу.

Для ускорения процесса гипермутации было предложено для каждого гена антитела установить весовой коэффициент:

$$\text{VS}[Ab_i] = \frac{1 - \left(\sum_{j=1}^L (Ab_j - Ag_j) - \sum_{k=1}^L (Ab_k - Ag_k) \right)}{1 - \sqrt{\sum_{j=1}^L (Ab_j - Ag_j)}}, \quad k \neq i \quad (12)$$

$$VS[Ab_i] = \frac{1 - \left(\sum_{j=1}^L |Ab_j - Ag_j| - \sum_{k=1}^L |Ab_k - Ag_k| \right)}{1 - \sum_{j=1}^L |Ab_j - Ag_j|}, \quad k \neq i \quad (13)$$

где $VS[Ab_i]$ – вес i -го гена антитела, Ab – антитело, Ag – антиген. Формула (4) используется в случае, если расстояние между антителом и антигеном рассчитывается на основе Евклидова расстояния, а формула (5), если расстояние рассчитывается на основе Манхэттенского расстояния (эти параметры задаются в настройках программы при запуске работы информационной системы [11]).

Формула, по которой осуществляется мутация антитела, имеет следующие варианты выбора:

Мутация с быстрой сходимостью (*МБС*):

$$c_j^* = c_j - \alpha(ab_i - c_j), \quad j = 1, \dots, |C| \quad (14)$$

Аффинность, пропорциональная мутации (*АПМ*):

$$c_j^* = c_j - \exp(-\alpha D^*), \quad j = 1, \dots, |C| \quad (15)$$

Соматическая мутация (*СМ*):

$$c_j^* = c_j + \exp(-\alpha D) * N(0, \alpha), \quad j = 1, \dots, |C| \quad (16)$$

где c_j – антиген, подвергнутый мутации,

α – коэффициент мутации,

$N(0, \alpha)$ – функция случайного распределения в диапазоне $(0, \alpha)$.

Более детально информационная система для решения задач классификации описана в работе [11].

5. Результаты экспериментальных исследований

Для оценки работы представленных модификаций разработанных алгоритмов иммунных сетей (Рис.7), были проведены сравнительные исследования. Каждый алгоритм тестировался по 10 раз. В таблице 1 приведены результаты тестирования (% правильного распознавания на тестовом наборе данных).

Были проведены сравнительные исследования качества классификации с другими известными иммунными системами и алгоритмами в программной среде WEKA (<http://www.cs.waikato.ac.nz/ml/weka>): Immunos-1, Immunos-2, Immunos-99[12], AIRS1, AIRS2[13-16], CLONALG[17-18], CSCA[19].

Таблица 1

Результаты тестирования на точность классификации разработанных алгоритмов

Виды алгоритмов	Расчет мутации и используемая метрика					
	Евклидовое расстояние			Манхеттенское расстояние		
	МБС (14)	АПМ (15)	СМ (16)	МБС (14)	АПМ (15)	СМ (16)
1.Классический	94,5%	95,0%	90,8%	87,0%	88,7%	87,3%
2. Модиф. мутация	95,7%	94,1%	92,5%	86,2%	89,2%	83,6%
3. Модиф. аффинность	96,4%	97,2%	94,7%	88,1%	87,4%	86,2%
4.Модиф. аффинность и мутация	98,5%	97,9%	97,1%	98,1%	97,6%	96,8%

Таблица 2

Результаты сравнительного тестирования современными иммунными алгоритмами на точность классификации

№ n/n	Алгоритмы	% правильно-го распознавания
1.	Модифицированный авторами алгоритм иммунной сети (аффинность и мутация)	98,5%
2.	Immunos-1	85,5%
3.	Immunos-2	86,1%
4.	Immunos-99	80,3%
5.	AIRS1	86,3%
6.	AIRS2	87,6%
7.	CLONALG	87,0%
8.	CSCA	98,6%

Выводы

В работе показаны результаты исследований применения разработанных авторами модифицированных иммунных сетей для решения задачи распознавания гидроакустических сигналов, на основе признаков пространств, сформированных с помощью вейвлет-преобразований. Разработан метод автоматического распознавания

гидроакустических сигналов в условиях ограничений на длительность обрабатываемых сигналов при частичной или полной априорной неопределенности сведений об их структуре на основе искусственных иммунных систем.

Полученные результаты дают полное описание разработанных авторами алгоритмов построения искусственных иммунных сетей для обнаружения гидроакустических сигналов. Рассмотренный вариант решения задачи обнаружения сигналов от локальных источников шумов на иммунносетевом базисе демонстрирует высокую эффективность применения искусственных иммунных сетей как аппроксимирующих моделей гидроакустических расчетов, использующих параллельно-распределенную организацию вычислений. Целесообразность их использования объясняется их высокой гибкостью, способностью осуществлять параллельный поиск, устойчивостью к шуму, ассоциативной памятью, самоорганизацией, структурной пластичностью и высокими адаптационными способностями.

В целом, иммунные сети являются весьма перспективным направлением для реализации в различных прикладных приложениях при решении задач распознавания образов.

ЛИТЕРАТУРА

1. S. Beck, L. Deuser, R. Still and J. Whiteley, "A Hybrid Neural Network Classifier of Short Duration Acoustic Signals," *Proc. IJCNN*, Seattle, July 1991.
2. W. W. Streilein, P. Gaudio and G. A. Carpenter, "A neural network for object recognition through sonar on a mobile robot," *Proceedings of the 1998 IEEE/ISIC/CIRA/ISAS Joint Conference*, Gaithersburg, Md: September, 1998, pp. 271-276.
3. R. Baran and J.P. Coughlin, "A neural network for target classification using passive sonar," *Proceedings of the Conference on Analysis of Neural Network Applications*, Fairfax, Virginia, 1991, pp. 188-198.
4. Y.D. Lin, *Real-time recognition of fish species using neural network analysis of acoustic signature*, Dissertation, Melbourne, Fl: Florida Institute of Technology, 1998.
5. Бобровский А.И., Ефимов В.В., Зайченко К.В., Кадашников С.К., Машошин А.И., Черныш В.В. Классификация гидроакустических

- сигналов с помощью нейроподобных сетей// Известия вузов. приборостроение, 1996, Т.39, №1 с. 49-56
6. А.С.Ермоленко, А.В.Рудинский, Ю.Л.Сиек “Мягкие измерения и вычисления в гидроакустических системах и вычисления в гидроакустических системах обнаружения морских объектов ” // Научная сессия МИФИ - 2002. Сборник научных трудов. - М., 2002. - Ч.2: Нейроинформатика-2002. 4-я Всероссийская научно-техническая конференция. - С. 171-178
 7. Степновский А., Мошинский М., Тран Ван Данг Применение адаптивного нечеткого классификатора с нечетким решающим деревом для описания морского дна// Акустический журнал, 2003, Том 49, №2, с.233-244
 8. Рудинский А.В., Ермоленко А.С., Сиек Ю. Л. "Нейросетевой алгоритм обнаружения гидроакустических сигналов" "Нейроинформатика - 2000", 2-я Всероссийская научно-техническая конференция, сборник научных трудов, часть 1, Москва, 2000г., с.268-275.
 9. Машонин А.И. Особенности синтеза алгоритмов классификации подводных объектов по их гидроакустическому полю// Акустический журнал. 1996. Т.42, №2, с.27-32
 10. Бабичев С.А., Литвиненко В.И., Баранов А.Н., Захаров А.М., Четырин С.П. Предобработка гидроакустического сигнала в системах классификации на основе вейвлет-анализа//Збірник наукових праць. Вип1(11).– Севастополь: Севастопольський ВМІ ім.. П.С.Нахімова. 2007.– С.133-140
 11. Литвиненко В.И., Дидык А.А., Захарченко Ю.А. Компьютерная система для решения задач классификации на основе модифицированных иммунных алгоритмов // ААЭКС 2008 №2 (22) с.66-73.
 12. Brownlee, J. Immunos-81. The misunderstood artificial immune system; Technical Report No. 3-01; Centre for Intelligent Systems and Complex Processes (CISCP), Faculty of Information and Communication Technologies (ICT), Swinburne University of Technology (SUT), Victoria, Australia: 2005.
 13. Watkins, A.; Timmis, J.; Boggess, L. Artificial immune recognition system (AIRS): An immune-inspired supervised learning algorithm. *Genet. Programm. Evolv. Mach.* 2004, 5, 291-317.
 14. Meng, L.; van der Putten, P.; Wang, H. A comprehensive benchmark of the artificial immune recognition system (AIRS). In *Ad-*

- vanced Data Mining and Applications, Proceedings, 2005; Vol. 3584, pp 575-582.*
15. Watkins, A. B. AIRS: A resource limited artificial immune classifier. Mississippi State University, 2001.
 16. Watkins, A. B. Exploiting immunological metaphors in the development of serial, parallel and distributed learning algorithms. University of Kent, Canterbury, UK, 2005.
 17. de Castro, L. N.; Von Zuben, F. J. The clonal selection algorithm with engineering applications. In GECCO-2000: Proceedings of the Genetic and Evolutionary Computation Conference, July 10-12, 2000, Las Vegas, Nevada, Whitley, D.; Goldberg, D.; Cantu-Paz, E.; Spector, L.; Parmee, I.; Beyer, H.-G., Eds. Morgan Kaufmann: San Francisco, CA, 2000; pp 36-37.
 18. de Castro, L. N.; Von Zuben, F. J. Learning and optimization using the clonal selection principle. *IEEE Trans. Evol. Comput.* **2002**, *6*, 239-251.
 19. Brownlee, J. Clonal selection theory & CLONAG. The clonal selection classification algorithm (CSCA); Technical Report No. 2-02; Centre for Intelligent Systems and Complex Processes (CISCP), Faculty of Information and Communication Technologies (ICT), Swinburne University of Technology (SUT), Victoria, Australia: 2005.